

Modelo de decisión espectral colaborativo
para redes de radio cognitiva

Modelo de decisión espectral colaborativo para redes de radio cognitiva

César Augusto Hernández Suárez
Danilo Alfonso López Sarmiento
Diego Armando Giral Ramírez



*Este libro está dedicado a todos aquellos que día tras día
luchan incansablemente por perseguir sus sueños.*

César Augusto Hernández Suárez

*Este libro está dedicado a mi familia, quienes a lo largo de la vida
me han brindado grandes y acertadas enseñanzas; son el motor que me
impulsó a alcanzar este sueño. Dios los bendiga siempre.*

Danilo Alfonso López Sarmiento

Este libro está dedicado a mi familia.

Diego Armando Giral Ramírez

Agradecimientos

A Dios por darnos la sabiduría necesaria para tomar las decisiones correctas, la fortaleza para no desfallecer ante las dificultades y la inteligencia para encontrar las soluciones que llevaron a feliz término este proyecto académico.

Finalmente, también queremos agradecer a nuestra muy querida Universidad Distrital Francisco José de Caldas por brindarnos el apoyo y el tiempo necesarios para ejecutar este proyecto, así como al Centro de Investigaciones y Desarrollo Científico por financiar con los recursos necesarios la divulgación y publicación de los resultados de investigación alcanzados en este proyecto.



UD
Editorial

E2
ESPACIOS

© Universidad Distrital Francisco José de Caldas
© Centro de Investigaciones y Desarrollo Científico
© César Augusto Hernández Suárez, Danilo Alfonso López
Sarmiento, Diego Armando Giral Ramírez

Primera edición, noviembre de 2020
ISBN: 978-958-787-245-3

Dirección Sección de Publicaciones
Rubén Eliécer Carvajalino C.

Coordinación editorial
Nathalie De la Cuadra N.

Corrección de estilo
Alejandro Merlano Aramburo

Diagramación y montaje de carátula
Diego Abello Rico

Imagen de carátula
Freepik, edición Diego Armando Giral Ramírez

Editorial UD
Universidad Distrital Francisco José de Caldas
Carrera 24 N.º 34-37
Teléfono: 3239300 ext. 6202
Correo electrónico: publicaciones@udistrital.edu.co

Catalogación en la publicación – Biblioteca Nacional de Colombia

Hernández Suárez, César Augusto
Modelo de decisión espectral colaborativo para redes de
radio cognitiva / César Augusto Hernández Suárez, Danilo
Alfonso López Sarmiento, Diego Armando Giral Ramírez. -- 1a.
ed. -- Bogotá : Universidad Distrital Francisco José de Caldas,
2020.
p. – (Espacios)

Incluye referencias bibliográficas.

ISBN 978-958-787-245-3

1. Redes de radio cognitivas 2. Espectro radioeléctrico – Fun-
damentos I. López Sarmiento, Danilo Alfonso II. Giral Ramírez,
Diego Armando III. Título IV. Serie

CDD: 537.534 ed. 23

CO-BoBN– a1062172

Todos los derechos reservados.
Esta obra no puede ser reproducida sin el permiso previo escrito de la
Sección de Publicaciones de la Universidad Distrital.
Hecho en Colombia

Contenido

Agradecimientos	9
Introducción	27
Objetivos del proyecto de investigación	30
Modelo de decisión espectral colaborativo	30
Metodología	31
Contribuciones	32
Organización	33
Financiamiento	34
Fundamentos teóricos	35
Radio cognitiva	35
Decisión espectral	43
Técnicas y algoritmos para la asignación espectral	57
Caracterización del arribo de los usuarios primarios	76
Caracterización del arribo de los usuarios secundarios	91
Trabajos relacionados	100
Caracterización de los usuarios primarios	107
Caracterización del usuario primario con <i>long short-term memory</i>	107
Caracterización del usuario primario con un modelo neurodifuso: <i>Anfis-grid</i> -FCM	119
Caracterización del usuario primario con SVM	129
Caracterización de los usuarios secundarios	149
Modelos reactivo y proactivo	149
Modelo MLPNN para la estimación del arribo del usuario secundario	150

Modelo de decisión espectral colaborativo	159
Selección del <i>software</i> y los equipos	159
Tipo de red	161
Captura y procesamiento de los datos de ocupación espectral	161
Nivel de tráfico	163
Módulo colaborativo: intercambio de información entre usuarios secundarios	165
Módulo de selección de la oportunidad espectral	166
Evaluación de los algoritmos de decisión espectral	180
Evaluación comparativa	231
Discusión	240
Modelo de decisión espectral colaborativo definitivo	242
Herramienta de simulación	245
Descripción general	245
Base de datos	246
Módulo colaborativo	248
Modelos disponibles	249
Estructura general de los modelos	249
Descripción de modelos	254
Movilidad espectral	273
Funciones <i>Data_Export</i> y <i>Figure</i>	274
Herramienta de simulación de <i>handoff</i> espectral desarrollada	275
Conclusiones	277
Contribuciones de la investigación	279
Investigación futura	280
Referencias	281

Figuras

Figura 1. Modelo de decisión espectral	31
Figura 2. Concepto de <i>oportunidad espectral</i>	37
Figura 3. Ciclo cognitivo	38
Figura 4. Clasificación de las técnicas de detección de espectro	39
Figura 5. Arquitectura de una CRN	40
Figura 6. Arquitecturas de red centralizada (a), descentralizada (b) y distribuida (c)	41
Figura 7. Marco de decisión del espectro	44
Figura 8. Caracterización del ambiente de radio	47
Figura 9. Clasificación de los algoritmos para la asignación de espectro	59
Figura 10. Número difuso triangular	67
Figura 11. Etapas que componen las redes de radio cognitiva	76
Figura 12. Contexto de la caracterización en la etapa de decisión espectral en redes de radio cognitiva	77
Figura 13. Representación gráfica de las redes neuronales tipo <i>long short-term memory</i>	79
Figura 14. Arquitectura LSTM utilizada para la caracterización de PU	
Figura 15. Estructura Anfis para la caracterización de PU	88
Figura 16. Red de radio cognitiva basada en infraestructura	92
Figura 17. Sistema de arribo reactivo de usuarios secundarios a la estación base	93
Figura 18. Sistema de arribo proactivo de usuarios secundarios a la estación base	95
Figura 19. Representación de la MLPNN para el conjunto de datos de la ecuación (77)	98

Figura 20. Resumen de algunas de las metodologías utilizadas en la caracterización del PU	104
Figura 21. Estrategias de ejecución de las solicitudes de SU	105
Figura 22. Diagrama de flujo para el entrenamiento de LSTM	107
Figura 23. Diagrama de flujo para discretización de datos espectrales	110
Figura 24. Representación del comportamiento histórico para 77 muestras	111
Figura 25. Topología de la red neuronal	112
Figura 26. Resultados de la etapa de entrenamiento (fase de aprendizaje de la red)	112
Figura 27. Resultados de la predicción	113
Figura 28. Porcentaje de acierto en la predicción para LSTM y Anfis	117
Figura 29. Coeficiente de correlación en la etapa de entrenamiento (modelamiento)	119
Figura 30. Muestra de niveles de potencia del usuario primario normalizados	120
Figura 31. Comparación entre la señal normalizada (superior) y la filtrada (inferior)	120
Figura 32. Sistema Anfis basado en el modelo Sugeno	121
Figura 33. Diagrama de bloques del algoritmo de predicción de usuarios primarios con Anfis-grid y Anfis-FCM	123
Figura 34. Entrenamiento del usuario primario en un canal GSM (modelado) con Anfis-grid-FCM	125
Figura 35. Validación del modelo Anfis-grid-FCM estimando una predicción futura de comportamiento del usuario primario para 500 datos	126
Figura 36. Entrenamiento del comportamiento del usuario primario en un canal GSM (modelado) con LSTM	127
Figura 37. Validación del sistema LSTM estimando una predicción futura de comportamiento del usuario primario para 50 datos	128
Figura 38. Diagrama de bloques del sistema de caracterización con SVM	130
Figura 39. Diagrama de flujo del primer algoritmo SVM-1	132
Figura 40. Diagrama secuencial del segundo SVM propuesto para usuarios primarios	135
Figura 41. Metodología seguida para estimar la ausencia o presencia de usuarios primarios	137
Figura 42. Diagrama de flujo del módulo encargado de extraer los datos del archivo capturado en Acrylic	138

Figura 43. Procesamiento de las secuencias a series temporales	138
Figura 44. Secuencia de pasos para modelar y predecir usuarios primarios con SVM	139
Figura 45. Compresión del volumen de datos para procesar en la etapa de entrenamiento y estimación del canal	140
Figura 46. Diagrama de flujo de creación de los ejemplos para modelar y estimar el uso del canal de un usuario primario	141
Figura 47. Comportamiento de un usuario primario en términos de emisión/no emisión para una canal en la banda Wi-Fi entregada por Acrylic	141
Figura 48. Comparación entre el comportamiento real y la predicción para el usuario primario en el canal evaluado sin la utilización de PCA	144
Figura 49. Comparación entre la actividad real del usuario primario y la estimada por la SVM-2 con PCA	147
Figura 50. Comparación entre la actividad real del usuario primario y la estimada por la SVM-2 según porcentajes de probabilidad	148
Figura 51. Evaluación del nivel de estimación del arribo de usuarios secundarios a la estación base con el modelo proactivo	150
Figura 52. Diagrama de entrenamiento del sistema MLPNN	151
Figura 53. <i>Software</i> de predicción de arribo de usuarios secundarios (generación del histórico)	153
Figura 54. Etapa de creación de las MLPNN especializadas	153
Figura 55. Fase de entrenamiento de la red neuronal	154
Figura 56. Fase de predicción de la red neuronal (con cálculo de probabilidad de una solicitud de QoS)	154
Figura 57. Distribución exponencial predicha para la variable <i>ancho de banda</i>	157
Figura 58. Configuración experimental para medir la ocupación espectral	161
Figura 59. Estructura propuesta para el algoritmo FAHP	173
Figura 60. TFN para la escala de importancia de FAHP	174
Figura 61. Esquema del algoritmo FFAHP propuesto	178
Figura 62. AAH en GSM para el algoritmo FFAHP	182
Figura 63. AAH en Wi-Fi para el algoritmo FFAHP	183
Figura 64. AAH en GSM para el algoritmo SAW	184
Figura 65. AAH en Wi-Fi para el algoritmo SAW	185
Figura 66. AAH en GSM para el algoritmo TOPSIS	186

Figura 67. AAH en Wi-Fi para el algoritmo TOPSIS	187
Figura 68. AAH en GSM para el algoritmo VIKOR	188
Figura 69. AAH en Wi-Fi para el algoritmo VIKOR	189
Figura 70. AAFH en GSM para el algoritmo FFAHP	192
Figura 71. AAFH en Wi-Fi para el algoritmo FFAHP	193
Figura 72. AAFH en GSM para el algoritmo SAW	194
Figura 73. AAFH en Wi-Fi para el algoritmo SAW	195
Figura 74. AAFH en GSM para el algoritmo TOPSIS	196
Figura 75. AAFH en Wi-Fi para el algoritmo TOPSIS	197
Figura 76. AAFH en GSM para el algoritmo VIKOR	198
Figura 77. AAFH en Wi-Fi para el algoritmo VIKOR	199
Figura 78. ABW en GSM para el algoritmo FFAHP	202
Figura 79. ABW en Wi-Fi para el algoritmo FFAHP	203
Figura 80. ABW en GSM para el algoritmo SAW	204
Figura 81. ABW en Wi-Fi para el algoritmo SAW	205
Figura 82. ABW en GSM para el algoritmo TOPSIS	206
Figura 83. ABW en Wi-Fi para el algoritmo TOPSIS	207
Figura 84. ABW en GSM para el algoritmo VIKOR	208
Figura 85. ABW en Wi-Fi para el algoritmo VIKOR	209
Figura 86. AAD en GSM para el algoritmo FFAHP	212
Figura 87. AAD en Wi-Fi para el algoritmo FFAHP	213
Figura 88. AAD en GSM para el algoritmo SAW	214
Figura 89. AAD en Wi-Fi para el algoritmo SAW	215
Figura 90. AAD en GSM para el algoritmo TOPSIS	216
Figura 91. AAD en Wi-Fi para el algoritmo TOPSIS	217
Figura 92. AAD en GSM para el algoritmo VIKOR	218
Figura 93. AAD en Wi-Fi para el algoritmo VIKOR	219
Figura 94. AAT en GSM para el algoritmo FFAHP	222
Figura 95. AAT en Wi-Fi para el algoritmo FFAHP	223
Figura 96. AAT en GSM para el algoritmo SAW	224

Figura 97. AAT en Wi-Fi para el algoritmo SAW	225
Figura 98. AAT en GSM para el algoritmo TOPSIS	226
Figura 99. AAT en Wi-Fi para el algoritmo TOPSIS	227
Figura 100. AAT en GSM para el algoritmo VIKOR	228
Figura 101. AAT en Wi-Fi para el algoritmo VIKOR	229
Figura 102. Modelo de decisión espectral colaborativo definitivo	243
Figura 103. Diagrama de bloques: descripción general	246
Figura 104. Flujo de datos	247
Figura 105. Entrada de la base de datos	247
Figura 106. Estructura colaborativa	248
Figura 107. Matriz de potencia segmentada	249
Figura 108. Modelos disponibles para predicción y movilidad espectral	250
Figura 109. Descripción general de las entradas de los modelos	250
Figura 110. Variable de entrada del módulo <i>ranking</i>	252
Figura 111. Algoritmos de <i>handoff models</i>	253
Figura 112. Etapas de los algoritmos para movilidad espectral	254
Figura 113. Datos de entrada y salida: movilidad espectral	255
Figura 114. Variables de entrada y salida del <i>ranking</i> de decisión espectral para movilidad espectral	256
Figura 115. Parámetros de salida de la evaluación de la movilidad espectral	257
Figura 116. Etapas del algoritmo de la cadena de Markov	258
Figura 117. Datos de entrada y salida: cadenas de Markov	258
Figura 118. Matriz de transición: cadenas de Markov	259
Figura 119. Algoritmo de evaluación: cadena de Markov	260
Figura 120. Equivalentes genéticos para una población específica	261
Figura 121. Diagrama de flujo del algoritmo genético	262
Figura 122. Etapas del algoritmo: algoritmos genéticos	263
Figura 123. Datos de entrada y salida: algoritmos genéticos	264
Figura 124. Algoritmo de evaluación: algoritmos genéticos	264
Figura 125. Etapas del algoritmo bayesiano ingenuo	265
Figura 126. Datos de entrada y salida: algoritmo bayesiano ingenuo	266

Figura 127. Algoritmo de evaluación del clasificador bayesiano ingenuo	267
Figura 128. Etapas del algoritmo de regresión logística	268
Figura 129. Datos de entrada y salida del algoritmo de regresión logística	269
Figura 131. Algoritmo de evaluación de la regresión logística	270
Figura 132. Etapas del algoritmo por series de tiempo	271
Figura 133. Datos de entrada y salida del algoritmo por series de tiempo	272
Figura 134. Algoritmo de evaluación del algoritmo por series de tiempo	273
Figura 135. Datos de entrada y salida: movilidad espectral	274
Figura 136. Interfaz de usuario del software Collaborative CRN	275

Tablas

Tabla 1. Análisis comparativo de las técnicas de asignación espectral	73
Tabla 2. Notaciones para el desarrollo del modelo matemático	81
Tabla 3. Casos de prueba para trazas de tráfico del usuario primario generadas mediante simulación	110
Tabla 4. Desempeño de la red LSTM en la caracterización de usuarios primarios	113
Tabla 5. Desempeño de la red MLPNN en la caracterización de usuarios primarios	114
Tabla 6. Rendimiento del algoritmo para flujos GSM	115
Tabla 7. Rendimiento del algoritmo para flujos Wi-Fi	115
Tabla 8. Nivel de potencia final, que representa la presencia o ausencia de un usuario primario	119
Tabla 9. Resultados encontrados con LSTM	127
Tabla 10. Resultados estadísticos de los sistemas Anfis y LSTM	128
Tabla 11. Matriz de clasificación para 1000 ejemplos	144
Tabla 12. Matriz de clasificación para 1000 ejemplos usando PCA	145
Tabla 13. Matriz de clasificación para 1000 ejemplos con estimación sin PCA	146
Tabla 14. Matriz de clasificación para 1000 ejemplos con estimación $l + 1000$ con PCA	146
Tabla 15. Resultados del entrenamiento para el caso de prueba de distribución exponencial	155
Tabla 16. Resultados de la predicción para el caso de prueba de distribución exponencial	155
Tabla 17. Resultados del entrenamiento para el caso de prueba de distribución <i>poisson</i>	155

Tabla 18. Resultados de la predicción para el caso de prueba de distribución <i>poisson</i>	155
Tabla 19. Resultados del entrenamiento para el caso de prueba de distribución uniforme	156
Tabla 20. Resultados de la predicción para el caso de prueba de distribución uniforme	156
Tabla 21. Especificaciones de los equipos para la monitorización del espectro	160
Tabla 22. Especificaciones del equipo de cómputo	160
Tabla 23. Especificaciones del clúster	160
Tabla 24. Configuración de los parámetros técnicos del analizador de espectro para GSM	162
Tabla 25. Umbral de decisión para la detección de usuarios primarios	164
Tabla 26. TFN y TFN recíproco para la escala de importancia de FAHP	173
Tabla 27. Matriz de juicios para los subcriterios de tiempo real	175
Tabla 28. Matriz de juicios para los subcriterios de mejor esfuerzo	175
Tabla 29. Pesos normalizados de los subcriterios de tiempo real	177
Tabla 30. Pesos normalizados de los subcriterios de mejor esfuerzo	177
Tabla 31. Métricas de evaluación utilizadas para los algoritmos FAHP y FFAHP	179
Tabla 32. Valores relativos de AAH para FFAHP	190
Tabla 33. Valores relativos de AAH para SAW	190
Tabla 34. Valores relativos de AAH para TOPSIS	191
Tabla 35. Valores relativos de AAH para vikor	191
Tabla 36. Valores relativos de AAFH para FFAHP	200
Tabla 37. Valores relativos de AAFH para SAW	200
Tabla 38. Valores relativos de AAFH para TOPSIS	201
Tabla 39. Valores relativos de AAFH para VIKOR	201
Tabla 40. Valores relativos de ABW para FFAHP	210
Tabla 41. Valores relativos de ABW para SAW	210
Tabla 42. Valores relativos de ABW para TOPSIS	211
Tabla 43. Valores relativos de ABW para VIKOR	211
Tabla 44. Valores relativos de AAD para FFAHP	220
Tabla 45. Valores relativos de AAD para SAW	220

Tabla 46. Valores relativos de AAD para TOPSIS	221
Tabla 47. Valores relativos de AAD para VIKOR	221
Tabla 48. Valores relativos de AAT para FFAHP	230
Tabla 49. Valores relativos de AAT para SAW	230
Tabla 50. Valores relativos de AAT para TOPSIS	230
Tabla 51. Valores relativos de AAT para VIKOR	231
Tabla 52. Evaluación comparativa por nivel de colaboración para AAH	231
Tabla 53. Evaluación comparativa por nivel de colaboración para AAFH	232
Tabla 54. Evaluación comparativa por nivel de colaboración para ABW	233
Tabla 55. Evaluación comparativa por nivel de colaboración para AAD	234
Tabla 56. Evaluación comparativa por nivel de colaboración para AAT	235
Tabla 57. Evaluación comparativa por escenario con colaboración de 10% y 100% para AAH	235
Tabla 58. Evaluación comparativa por escenario con colaboración de 10% y 100% para AAFH	236
Tabla 59. Evaluación comparativa por escenario con colaboración de 10% y 100% para ABW	237
Tabla 60. Evaluación comparativa por escenario con colaboración de 10% y 100% para AAD	238
Tabla 61. Evaluación comparativa por escenario con colaboración de 10% y 100% para AAT	239
Tabla 62. Evaluación comparativa global por EM	239
Tabla 63. Datos capturados	246
Tabla 64. Descripción de los parámetros de entrada iniciales	251
Tabla 65. Vectores para el análisis multicriterio	252
Tabla 66. Indicadores de predicción	260
Tabla 67. Equivalentes genéticos	261
Tabla 68. Formatos de los archivos exportados	274

Lista de siglas ---

AAD: retardo promedio acumulado
AAEH: *handoff* perfecto promedio acumulado
AAFH: *handoff* fallido promedio acumulado
AAH: *handoff* promedio acumulado
AAIH: *handoff* con interferencia promedio acumulado
AAPH: *handoff* sin interferencia promedio acumulado
AAT: *throughput* promedio acumulado
AAUH: *handoff* anticipado promedio acumulado
ABC: colonia artificial de abejas
ABW: ancho de banda promedio
AHP: *analytical hierarchical process*
AM: matriz de disponibilidad
Anfis: *adaptive neuro fuzzy inference system*
ANN: red neuronal artificial
ANS: puntaje promedio normalizado
AP: probabilidad de disponibilidad
AR: autorregresivo
Arima: autorregresivo integrado de media móvil
ARMA: autorregresivo de media móvil
BCL: lista de canales de respaldo
BE: mejor esfuerzo
BER: tasa de error de bit
BPTT: *backpropagation through time*
BS: estación base
BW: ancho de banda
CAP: punto de acceso cognitivo
CAR: Consejo de Administradores de Red

CBS: estación base central
 CCC: canal de control común
 CDB: base de datos central
 CDMA: acceso múltiple por división de código
 CHT: tiempo de retención del canal
 CR: radio cognitiva
 Crahn: redes de radio cognitiva *ad hoc*
 CRN: redes de radio cognitiva
 DC: criterios de decisión
 DOFDM: multiplexación por división de frecuencia ortogonal discontinua
 D-QDCR: reserva de canal dinámica distribuida basada en la calidad de servicio
 DSA: acceso dinámico al espectro
 Electre: *elimination and choice expressing the reality*
 EM: métrica de evaluación
 ETA: tiempo medio de disponibilidad
 EV: evaluación
 FAC: función de autocorrelación
 FACP: función de autocorrelación parcial
 FAHP: *fuzzy analytical hierarchical process*
 FCC: Federal Communications Commission
 FDMA: acceso múltiple por división de frecuencia
 FFAHP: *feedback fuzzy analytical hierarchical process*
 FTR: probabilidad de terminación forzosa
 GRA: *grey relational analysis*
 GSM: sistema global para las comunicaciones móviles
 HMM: modelos ocultos de Markov
 HT: tráfico alto
 IEEE: Instituto de Ingenieros Eléctricos y Electrónicos
 ITU: Unión Internacional de Telecomunicaciones
 LSTM: *long short-term memory*
 LT: tráfico bajo
 MA: media móvil
 MAC: control de acceso al medio
 Manet: redes móviles *ad hoc*
 MAPFF: *multivariable adaptive predictive feedback fuzzy*
 MAS: sistemas multiagente
 MCDM: toma de decisiones multicriterio

MEW: *multiplicative exponent weighting*
MT: tráfico medio
NTIA: Administración Nacional de la Información y las Comunicaciones
OFDM: multiplexación por división de frecuencia ortogonal
PCA: *principal component analysis*
PDA: asistente personal digital
PM: matriz de potencias
PM-HT: matriz de potencias de tráfico alto
PM-HT-EV: matriz de potencias de tráfico alto para evaluación
PM-HT-TR: matriz de potencias de tráfico alto para entrenamiento
PM-LT: matriz de potencias de tráfico bajo
PM-LT-EV: matriz de potencias de tráfico bajo para evaluación
PM-LT-TR: matriz de potencias de tráfico bajo para entrenamiento
PM-MT: matriz de potencias de tráfico medio
PM-MT-EV: matriz de potencias de tráfico medio para evaluación
PM-MT-TR: matriz de potencias de tráfico medio para entrenamiento
PPS: puntos por *span*
PPTS: *proactive predictive based on time series*
PU: usuario primario
QoS: calidad de servicio
RA: asignación aleatoria
RBW: resolución de ancho de banda
RIV: *ranking* del impacto de las variables
RRSS: fuerza relativa de la señal recibida
RSS: fuerza de la señal recibida
RSSI: indicador de fuerza de la señal recibida
RT: tiempo real
SA: asignación espectral
SAW: *simple additive weighting*
SH: *handoff* espectral
SINR: relación de señal a interferencia más ruido
SIR: relación de señal a interferencia
SMS: servicio de mensajes cortos
SNR: relación de señal a ruido
SO: oportunidad espectral
SU: usuario secundario
SVM: máquina de soporte vectorial

TDMA: acceso múltiple por división de tiempo

TFN: números difusos triangulares

TOPSIS: *technique for order preference by similarity to ideal solution*

TR: entrenamiento

TS: instante de tiempo

VIKOR: *multi-criteria optimization and compromise solution*

Wi-Fi: *wireless-fidelity*

WMC: *weighted markov chain*

Introducción

El crecimiento en el diseño de aplicaciones inalámbricas plantea nuevos desafíos en los futuros sistemas de comunicación; según Cisco (2017), el tráfico de datos móviles ha crecido 18 veces en los últimos 5 años y se espera que el tráfico total crezca 49 exabytes por mes en 2021 (Hernández, Márquez et al., 2017; Hernández, Pedraza et al., 2015; Kumar et al., 2016; Tahir et al., 2017; Wang y Liu, 2011). Lo anterior, junto con el hecho de que las políticas de asignación actuales son fijas y reguladas por el Estado (Cruz-Pol et al., 2018), ha generado que el espectro radioeléctrico presente problemas de escases. Sin embargo, los resultados de estudios realizados demuestran que ciertas bandas, como las de 50 a 700 MHz, están siendo subutilizadas, ya que sus ciclos útiles son prácticamente nulos, debido a que, en algunos casos, los tiempos de utilización espectral son inferiores al 10 % (Forero, 2012), en contraste con otras bandas, como las asignadas a la red celular, que actualmente se encuentran saturadas.

La radio cognitiva (CR), definida por la Unión Internacional de Telecomunicaciones (ITU) como una radio o sistema que detecta y está al tanto de su entorno y se puede ajustar de forma dinámica y autónoma de acuerdo con sus parámetros de funcionamiento de radio, plantea como solución el acceso dinámico al espectro (DSA) por medio de un uso oportunista e inteligente del espectro de frecuencia. Lo anterior permite que un usuario no licenciado —usuario de radio cognitiva o usuario secundario (SU)— pueda utilizar un canal de una banda licenciada disponible, pero deberá liberar dicho canal y buscar uno nuevo (también denominado *oportunidad espectral*, *hueco espectral* o *espacio blanco*) para continuar con su transmisión si el usuario licenciado —usuario primario (PU)— llega a ocuparlo, si la calidad del canal ocupado por el SU se degrada, si el SU interfiere al PU o si la movilidad del SU provoca que el PU quede fuera del área de cobertura; este mecanismo es denominado *movilidad espectral* o *handoff espectral* (SH) (Ahmed et al., 2016; Akyildiz et al., 2006; Akyildiz et al., 2008; Ozger y Akan, 2016; Tsiropoulos et al., 2016). Esto le confiere a la CR la capacidad de proveer un gran ancho de banda (BW) al SU a través de arquitecturas inalámbricas heterogéneas.

Las redes de radio cognitiva (CRN) imponen retos en la gestión del espectro disponible debido a su naturaleza fluctuante y a los requerimientos de calidad de servicio (QoS) de varias aplicaciones. Las cuatro principales funciones de la gestión del espectro son: detección de espectro, decisión de espectro, compartición de espectro y movilidad de espectro, de la cuales conforman el ciclo cognitivo (Akyildiz et al., 2008; Akyildiz et al., 2009). El ciclo cognitivo inicia con la detección del espectro, cuando los usuarios de radio cognitiva monitorizan el espectro para detectar las oportunidades espectrales (SO) a fin de no interferir con los PU. En la decisión de espectro, después de que las SO han sido identificadas, los SU deben seleccionar la más adecuada de acuerdo con sus requerimientos de QoS; para tomar esta decisión, se han desarrollado algoritmos que tienen en cuenta las características del canal de radio y el comportamiento estadístico de los PU, entre otros factores. Debido a que múltiples SU pueden intentar acceder al espectro, la función de compartición de espectro proporciona la capacidad de compartir este recurso con múltiples SU, coordinando sus transmisiones para evitar colisiones e interferencias. Finalmente, la movilidad espectral se da cuando el SU debe dejar el canal de frecuencia que está utilizando y continuar su comunicación en otra SO debido a la llegada de un PU, a que está interfiriendo con el PU o a la degradación de la calidad del canal (Akyildiz et al., 2009; Tsiropoulos et al., 2016).

La decisión del espectro es el núcleo de una CRN, pues, de forma eficiente y sin causar ningún tipo de interferencia, establece mediante un conjunto de técnicas el proceso para seleccionar la SO más adecuada de acuerdo con los requerimientos del SU y con las condiciones del ambiente de radio. Un incorrecto proceso de toma de decisiones afecta los parámetros de la red, como, por ejemplo, la tasa de cambios de canal, o *handoff* espectral; sin embargo, a pesar de su relevancia, no es una función tan explorada como la detección de espectro. Problema y motivación del proyecto de investigación

De acuerdo con investigaciones actuales (Ahmed et al., 2016; Akyildiz et al., 2006; Akyildiz et al., 2008; Akyildiz et al., 2009; Christian et al., 2012; Marinho y Monteiro, 2012; Rodríguez-Colina et al., 2011; Tsiropoulos et al., 2016; Wang et al., 2012; Wang y Wang, 2009), la decisión espectral es la característica clave para habilitar la transmisión continua de datos del SU, ya que a partir de esta se podría reducir el número de cambios de canal durante la transmisión de un SU, así como su latencia, lo que minimiza la degradación del canal (Christian et al., 2012). Actualmente existen varias propuestas de decisión de espectro, pero es importante analizar que la aplicación de un modelo de decisión espectral depende en gran medida de las características de la red del PU (Akin y Fidler, 2016; Liu y Tewfik, 2014; Rahimian et al., 2014).

Cuando no se selecciona adecuadamente la SO, es posible que la transmisión de datos deba pausarse, lo que provoca un aumento significativo en el retardo que incide de forma directa en el nivel de desempeño y QoS de la comunicación del SU (Akyildiz et al., 2009). De acuerdo con lo anterior, encontrar un canal con las características requeridas sobre el cual un SU pueda continuar su sesión de transmisión de datos es un asunto apremiante en movilidad espectral (Christian et al., 2012). La selección del canal depende de muchos factores, como su capacidad, su disponibilidad durante el SH y la probabilidad de que siga libre en el futuro, entre otros. Una pobre selección de canal puede causar múltiples SH y degradar, así, el desempeño de todo el conjunto. El enfoque más común para la selección de canal es usar una lista de canales de respaldo (BCL) (Christian et al., 2012; Pedraza et al., 2016).

Durante la última década, las investigaciones en CRN enfocaron sus esfuerzos en la función de detección del espectro, razón por la cual existen diversos desarrollos al respecto en la literatura actual (Al-Amidie et al., 2019; Ali y Hamouda, 2017; Bhowmik y Malathi, 2019; Youssef et al., 2018; Zhang et al., 2017). En comparación con la detección, la decisión de espectro (toma de decisiones) ha sido poco estudiada a pesar de su importancia en el mejoramiento del desempeño de las redes inalámbricas (Pinto y Correia, 2018; Rizk et al., 2018; Tripathi et al., 2019), por lo cual, dentro de las CRN, se requiere proponer metodologías que orienten sus objetivos al proceso de toma de decisiones.

El componente básico de una decisión cognitiva está en función del aprendizaje del ambiente, el razonamiento y la conciencia. Las técnicas de decisión deben buscar maximizar de forma global, o por lo menos local, el uso del espectro y los parámetros de funcionamiento (Tabassam y Suleman, 2012). Los modelos de toma de decisión cuentan con múltiples técnicas, algunas determinísticas y otras probabilísticas, y sus aplicaciones son diversas y abarcan grandes áreas de las ciencias. En redes de telecomunicaciones, las teorías de toma de decisión permiten solucionar problemas de asignación, pero, como muchas otras áreas de la ingeniería, esta se ve limitada por el sistema de aplicación. En el caso de las CRN, los modelos desarrollados orientan sus esfuerzos a solucionar problemas de arquitecturas centralizadas (Deng et al., 2018; Iftikhar et al., 2019; Salgado, Márquez et al., 2016; Tripathi et al., 2019), por lo que es necesario identificar modelos que mejoren el proceso de toma de decisiones para otro tipo de arquitecturas con infraestructura como las descentralizadas.

Las redes centralizadas son arquitecturas con infraestructura que operan bajo un coordinador central: la información observada por cada SU alimenta la base central de forma que esta pueda tomar decisiones para maximizar los parámetros de comunicación.

En las CRN, los SU deben tomar decisiones inteligentes en función de la variación del espectro y de las acciones adoptadas por otros SU; bajo esta dinámica, la probabilidad de que dos o más SU elijan el mismo canal es alta, especialmente cuando el número de SU es mayor que el número de canales disponibles; así, debido a la externalidad negativa de la red, cuantos más SU seleccionen el mismo canal, menor será la utilidad que cada SU obtendrá y el número de interferencias por el acceso simultáneo será mayor (Abbas et al., 2015). Para modelar la red bajo parámetros de tráfico realistas, es necesario tener en cuenta la colaboración entre SU.

El desafío consiste en realizar el proceso de toma de decisiones para una red de radio cognitiva descentralizada (DCRN) dotando a los nodos con la capacidad de aprender del entorno y proponiendo estrategias que les permitan a los SU intercambiar información de forma cooperativa o competitiva. De acuerdo con cada uno de los elementos y problemas expuestos, la pregunta de investigación planteada para este libro es: ¿cómo y en qué medida se puede mejorar el desempeño de las redes de radio cognitiva descentralizadas con un enfoque colaborativo entre usuarios secundarios?

Objetivos del proyecto de investigación

El objetivo general de esta investigación es desarrollar un modelo de decisión espectral colaborativo para mejorar el desempeño de las redes de radio cognitiva, por medio de los siguientes objetivos específicos:

- Adaptar e implementar los algoritmos colaborativos más relevantes en la literatura actual con aplicación en redes de radio cognitiva distribuidas.
- Diseñar un modelo colaborativo para seleccionar la mejor SO en redes de radio cognitiva.
- Evaluar y validar el modelo propuesto a través de simulaciones con datos de ocupación espectral reales y con su posterior confrontación con los modelos más relevantes.

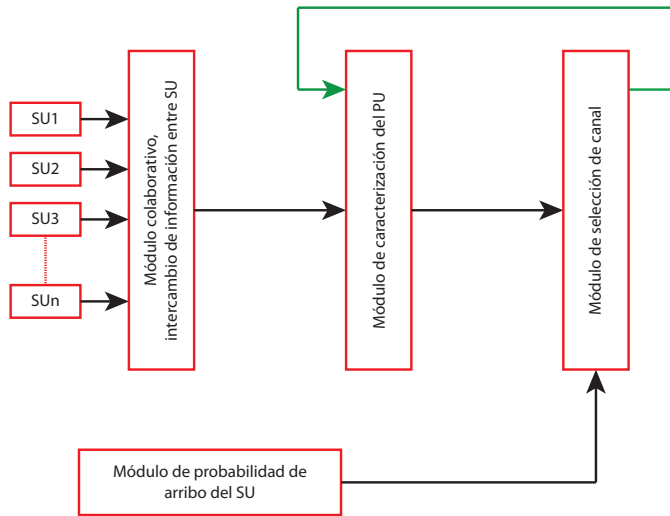
La validación del modelo de decisión espectral colaborativo propuesto se realizará a través de simulaciones y de su posterior confrontación con otros modelos. Esta simulación integra únicamente las características necesarias para evaluar el modelo propuesto.

Modelo de decisión espectral colaborativo

Este libro propone un modelo de decisión espectral colaborativo para la toma de decisiones multicriterio conformado por varios algoritmos híbridos y basado en cuatro módulos principales que se describirán en capítulos posteriores: 1) módulo colaborativo para el intercambio de información entre SU, 2) módulo de caracterización del PU, 3) módulo de probabilidad de arribo del SU y 4) módulo de selección de la SO

(figura 1). El modelo propuesto selecciona de forma dinámica e inteligente la mejor SO con base en los siguientes criterios de decisión (DC): probabilidad de disponibilidad (AP) del canal, tiempo estimado de disponibilidad (ETA) del canal, relación de señal a interferencia más ruido (SINR) y BW.

Figura 1. Modelo de decisión espectral



Fuente: elaboración propia.

Para evaluar el nivel de desempeño de los algoritmos desarrollados, se realiza un análisis comparativo entre estos y los algoritmos más relevantes en la literatura actual. A diferencia de los trabajos relacionados, la evaluación comparativa se validó a través de una traza de datos reales de ocupación espectral capturados en la banda de frecuencia del sistema global para las comunicaciones móviles (GSM) (Pedraza et al., 2016) y en Wi-Fi (Cardenas-Juarez et al., 2016) y que modelan el comportamiento real de los PU (Chen y Oh, 2016). En la evaluación de desempeño se tuvieron en cuenta dos tipos de red: GSM y Wi-Fi; dos clases de aplicaciones: tiempo real (RT) y mejor esfuerzo (BE); dos niveles de tráfico: tráfico alto (HT) y tráfico bajo (LT), y cinco métricas de evaluación (EM): número de *handoffs* promedio acumulado (AAH), número de *handoffs* fallidos promedio acumulado (AAFH), ancho de banda promedio (ABW), retardo promedio acumulado (AAD) y *throughput* promedio acumulado (AAT).

Metodología

El desarrollo de esta investigación se realizó secuencialmente a través de cuatro enfoques metodológicos: el primero, de tipo descriptivo, permitió detallar cada una de las características de las estrategias de interés; el segundo, de tipo analítico, permitió definir la influencia de cada modelo de interés en el desempeño de la movilidad es-

pectral; el tercero, de tipo predictivo, buscó aplicar soluciones de otras situaciones al contexto de interés, y el cuarto, finalmente, fue un enfoque experimental que permitió la realización de pruebas de comprobación y validez de los desarrollos efectuados (Hernández Sampieri et al., 2006).

La metodología se estructuró de la siguiente forma: primero, se realizó un estudio del estado del arte que permitió identificar los aspectos más importantes sobre el tema de decisión espectral en las CRN, así como sus algoritmos más relevantes en la literatura actual. Segundo, con base en este análisis, se diseñó una metodología para la evaluación del desempeño de la movilidad en redes móviles de CR. Tercero, se realizó la captura de datos de ocupación espectral reales tanto en la banda GSM como en la banda Wi-Fi, para analizar el comportamiento de dichas bandas y del PU. Cuarto, se realizó un procesamiento a los datos capturados para construir bases de datos de información organizada sobre el comportamiento del PU y sobre las características de los recursos espectrales de las bandas mencionadas; dichas bases de datos fueron clasificadas por tipo de red (GSM y Wi-Fi) y nivel de tráfico (HT y LT). Quinto, se determinaron los DC para la selección de las mejores SO y se calcularon los valores históricos de estos a partir de la información de las bases de datos, con lo que estas fueron complementadas. Sexto, se seleccionaron y desarrollaron los algoritmos de decisión espectral más relevantes en la literatura actual. Séptimo, se diseñaron y desarrollaron varios algoritmos para cada uno de los módulos del modelo de decisión espectral colaborativo. Octavo, con base en los resultados del desempeño de los algoritmos, se construyó el modelo de decisión espectral colaborativo propuesto. Noveno, con base en el análisis del estado del arte de las CRN, se diseñaron cinco EM para evaluar el desempeño de los algoritmos propuestos en esta investigación, así como los seleccionados de la literatura actual, y se propusieron ocho escenarios de evaluación considerando dos tipos de redes: GSM y Wi-Fi; dos clases de aplicaciones: RT y BE, y dos niveles de tráfico: HT y LT. Décimo, con base en toda la información anterior, se diseñó y desarrolló un simulador que permite evaluar cuantitativamente el desempeño de los algoritmos, considerando el comportamiento real del PU. Undécimo, con los resultados obtenidos a partir de los simuladores, se realizó una evaluación comparativa del desempeño de los algoritmos en cada una de las EM. Y duodécimo, según el análisis comparativo, se realizaron ajustes y modificaciones al modelo adaptativo multivariable diseñado.

Contribuciones

- Diseño y desarrollo de un modelo de decisión espectral colaborativo para mejorar el desempeño de las CRN.

- Evaluación y validación de los algoritmos de decisión espectral desarrollados, con datos de ocupación espectral reales capturados en una campaña de medición realizada en Bogotá, Colombia.
- Evaluación y validación de los algoritmos de SH desarrollados, en dos tipos de redes: GSM y Wi-Fi.
- Evaluación y validación de los algoritmos de SH desarrollados, con dos tipos de enfoque: RT y BE, de acuerdo con la clase de aplicación que puede ejecutar el SU.
- Evaluación y validación de los algoritmos de SH desarrollados, con dos niveles de tráfico de PU: alto y bajo.
- Evaluación y validación de los algoritmos de SH desarrollados, en ocho escenarios diferentes de evaluación: GSM-RT-LT, GSM-RT-HT, GSM-BE-LT, GSM-BE-HT, Wi-Fi-RT-LT, Wi-Fi-RT-HT, Wi-Fi-BE-LT y Wi-Fi-BE-HT.
- Evaluación y validación de los algoritmos de SH desarrollados, bajo cinco EM: AAH, AAFH, ABW, AAD y AAT.
- Determinación de cuatro DC seleccionados cuidadosamente mediante el método Delphi modificado, para elegir la mejor SO; todos los algoritmos desarrollados trabajaron con los mismos cuatro DC, y cada DC fue calculado a partir de los datos de ocupación espectral reales.
- Diseño y desarrollo de una herramienta de simulación novedosa para evaluar el desempeño de algoritmos de decisión espectral híbridos. Esta herramienta está basada en los datos de ocupación espectral reales y permite modificar varios parámetros de interés para analizar el desempeño de cada algoritmo bajo diferentes situaciones; entre estos parámetros, se destaca el nivel de colaboración entre SU, denominado “Collaborative CRN”.

Organización

El libro está estructurado de la siguiente manera: en el primer capítulo, se realiza una descripción de los fundamentos teóricos de la CR, la decisión espectral y los algoritmos de asignación espectral (SA), y se hace una revisión de la literatura actual sobre modelos de decisión espectral para CRN; en el segundo, se describe el módulo de caracterización del PU y sus resultados; en el tercero, se presenta el módulo de probabilidad de arribo del SU y sus resultados; en el cuarto, se describen el módulo de selección de la SO y el módulo colaborativo y se presenta el modelo de decisión espectral colaborativo propuesto; en el quinto, se describe el *software* desarrollado, y, finalmente, se presentan las conclusiones.

Financiamiento

El presente libro es producto de los resultados alcanzados en el proyecto de investigación “Modelo de decisión espectral colaborativo para mejorar el desempeño de las redes de radio cognitiva”, financiado por el Centro de Investigaciones y Desarrollo Científico de la Universidad Distrital Francisco José de Caldas.

Fundamentos teóricos

Este libro está enfocado en el área de la radio cognitiva (CR), y por tal razón, el presente capítulo está estructurado en seis secciones principales: la primera tiene por objetivo presentar los fundamentos de la CR; la segunda, mostrar los aspectos teóricos de la decisión espectral; la tercera, presentar los algoritmos más relevantes de la asignación espectral (SA); la cuarta, presentar una revisión de la literatura actual sobre los modelos de decisión espectral para redes de radio cognitiva (CRN); la quinta, mostrar algunas herramientas de simulación de handoff espectral (SH), y, finalmente, la sexta, revisar algunos trabajos relacionados con estos temas.

Radio cognitiva

Actualmente, las redes y aplicaciones inalámbricas en gran parte del mundo se han caracterizado por una política de asignación fija del espectro de radiofrecuencia regulada por el Estado. Esta asignación fija provoca que las frecuencias asignadas a servicios específicos estén prácticamente en desuso y no puedan ser aprovechadas por los usuarios secundarios (SU), incluso si estos no provocan ninguna interferencia (Ahmed et al., 2016; Akyildiz et al., 2008; Márquez et al., 2017).

Según estudios realizados por la Federal Communications Commission (FCC, 2003b), de Estados Unidos, y con base en las variaciones temporales y geográficas, se ha evidenciado que gran parte del espectro de radiofrecuencia asignado está siendo ineficiente e ineficazmente utilizado (Institute of Electrical and Electronics Engineers [IEEE], 2008); de hecho, mediciones actuales muestran que más del 70 % del espectro no está siendo utilizado (Hoven et al., 2005; Pedraza et al., 2016).

Esta utilización ineficiente y esporádica del espectro, junto con el incremento en su demanda, han hecho que se degrade la calidad de servicio (QoS) en varias redes y aplicaciones inalámbricas, como las comunicaciones móviles. Lo anterior ha motivado el desarrollo de investigaciones recientes que han encontrado en el acceso dinámico al espectro (DSA) la solución al problema, y la tecnología clave que permite materializar las técnicas de DSA es la CR (Akyildiz et al., 2008; Tsiropoulos et al., 2016).

El concepto de CR fue creado por Joseph Mitola III, en 2000, como

el punto en el cual las *personal digital assistant* (PDA) inalámbricas y las redes relacionadas son, en términos computacionales, lo suficientemente inteligentes con respecto a los recursos de radio y las correspondientes comunicaciones de ordenador a ordenador como para detectar las necesidades eventuales de comunicación del usuario, como una función del contexto de uso, y proporcionarle los recursos de radio y servicios inalámbricos más adecuados a ese mismo instante. (Mitola III, 2000, p. 1; traducción propia)

Sin embargo, varias entidades importantes han dado su punto de vista al respecto. Según la FCC (2003a), la CR


es una radio o sistema que detecta su entorno electromagnético de operación y puede ajustar de forma dinámica y autónoma sus parámetros de operación de radio para modificar la operación del sistema: maximizar el rendimiento, reducir la interferencia o facilitar la interoperabilidad. (Traducción propia)

Para la Unión Internacional de Telecomunicaciones (ITU), la CR es una radio o sistema que detecta y está al tanto de su entorno y que se puede ajustar de forma dinámica y autónoma de acuerdo con sus parámetros de funcionamiento de radio. De acuerdo con el Institute of Electrical and Electronics Engineers (IEEE, 2008), la CR “es un tipo de radio que puede detectar de forma autónoma y razonar sobre su entorno y adaptarse acorde a este”. Por último, según la FCC (2003b), la CR es una radio que “puede cambiar los parámetros del transmisor basada en la interacción con su entorno” (p. 5).

La CR tiene la capacidad de proveer un gran ancho de banda (BW) a usuarios móviles a través de arquitecturas inalámbricas heterogéneas, con las que aumenta significativamente la eficiencia espectral, debido a que permite que SU compartan el espectro con usuarios primarios (PU), de manera oportunista (Akyildiz et al., 2008), a partir de las oportunidades espectrales (SO) (figura 2); es decir, permite que los SU utilicen las porciones del espectro que no están siendo usadas en un momento dado (Delgado y Rodríguez, 2016; Ozger y Akan, 2016).

La figura 2 describe el concepto de SO a través de una gráfica en tres dimensiones cuyos ejes son la potencia, la frecuencia y el tiempo. Cada bloque gris de la figura es un PU haciendo uso de una porción del espectro de frecuencia, a un nivel de potencia y durante un determinado periodo de tiempo; sin embargo, existen porciones del espectro de frecuencia que no son utilizadas durante determinado intervalo de tiempo; dichos espacios son denominados SO y pueden ser aprovechados por los SU (Ozger y Akan, 2016).

Figura 2. Concepto de *oportunidad espectral*



Fuente: elaboración propia a partir de Akyildiz et al. (2009).

Características de la radio cognitiva

Las principales características de la CR, que le confieren todas las capacidades descritas anteriormente, son la capacidad cognitiva y la reconfigurabilidad.

Capacidad cognitiva

La capacidad cognitiva es la tecnología capaz de capturar la información de radiofrecuencia de su entorno para identificar los segmentos del espectro que no están siendo utilizados, para seleccionar el mejor espectro posible y para definir los parámetros de operación más adecuados, con el objetivo de evitar la interferencia entre usuarios (Pedraza et al., 2016).

Reconfigurabilidad

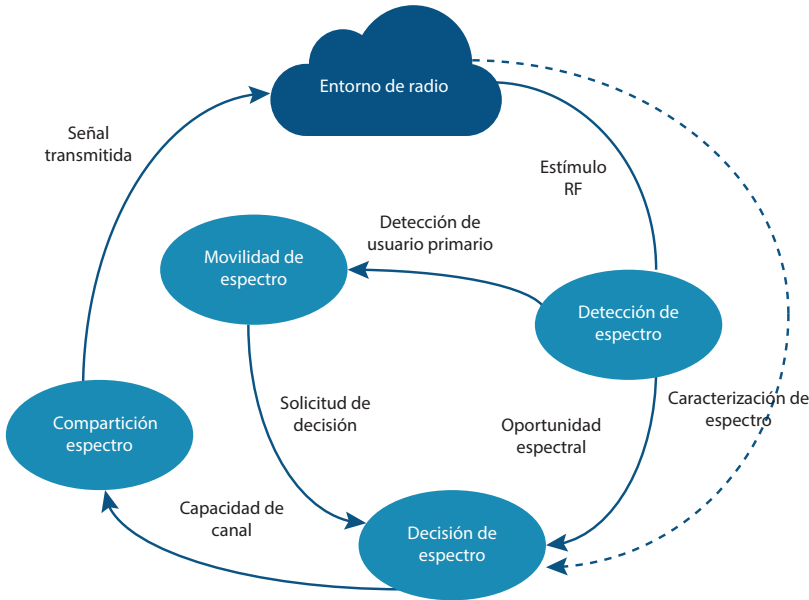
La reconfigurabilidad es la capacidad de cambiar, de forma dinámica, los diferentes parámetros de operación relacionados con la transmisión o la recepción, como la frecuencia, la potencia y la modulación, con miras a habilitar la radio para ser programada dinámicamente para transmitir y recibir en una gran variedad de frecuencias, en función del ambiente de radio, así como a usar diferentes tecnologías de acceso a la transmisión (Pedraza et al., 2016).

Gestión del espectro en radio cognitiva

Para que se pueda hacer uso del espectro de manera oportunista, las CRN trabajan con un modelo de gestión que se denomina *ciclo cognitivo* (figura 3). El modelo se caracteriza por cumplir cuatro funciones principales: detección de espectro, decisión de

espectro, movilidad de espectro y compartición de espectro. En la etapa de detección del espectro, los SU monitorean de manera continua el espectro para poder determinar las SO; en la segunda función, decisión de espectro, los SU deben seleccionar la SO más adecuada de acuerdo con sus requerimientos de QoS; en la tercera función, movilidad de espectro, los SU pueden tener que realizar el cambio de su frecuencia actual para continuar su comunicación en otro canal, debido a las siguientes causas: llegada de un PU, interrupción en la disponibilidad del canal, interferencia al PU, degradación de la calidad del canal, variación del tráfico y movimiento del SU; y en la cuarta y última función, compartición de espectro, el ciclo cognitivo proporciona la capacidad de compartir el recurso espectral con múltiples SU, coordinando sus transmisiones para evitar colisiones e interferencias, debido a que múltiples usuarios de CR pueden intentar acceder al espectro de manera simultánea (Pedraza et al., 2016; Ramzan et al., 2017).

Figura 3. Ciclo cognitivo

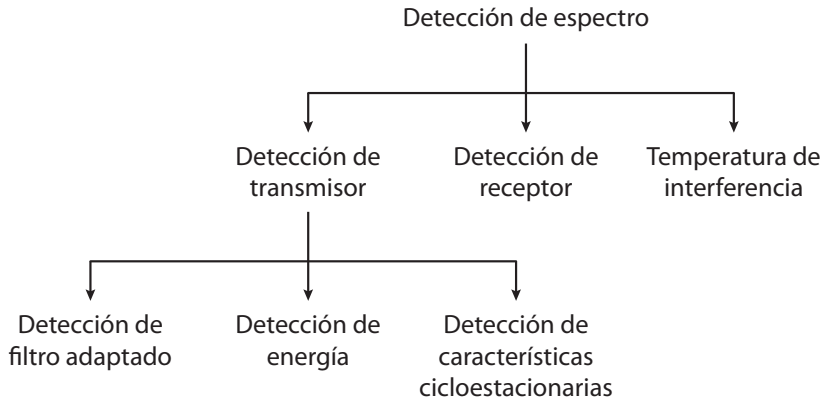


Fuente: elaboración propia a partir de Akyildiz et al. (2009).

Detección de espectro

La detección del espectro es la función encargada de identificar las SO. Los SU monitorean el espectro y capturan la información que permita determinar la disponibilidad de los canales. Actualmente, existen varias técnicas para monitorizar el espectro (figura 4), siendo la detección de energía la más básica (Hernández, Páez et al., 2017).

Figura 4. Clasificación de las técnicas de detección de espectro



Fuente: elaboración propia a partir de Akyildiz et al. (2009).

Decisión de espectro

La decisión de espectro o proceso de toma de decisiones determina cuál es el mejor canal de frecuencia entre los disponibles, según los requisitos de calidad de servicio de las aplicaciones (Alias y Ragesh, 2016; Hernández, Páez et al., 2017; Pedraza et al., 2016; Ramzan et al., 2017).

Compartición de espectro

Debido a que múltiples SU pueden intentar acceder al espectro, la función de compartición proporciona la capacidad de compartir este recurso e información con múltiples SU, coordinando sus transmisiones para evitar colisiones e interferencias. Las soluciones existentes para el uso compartido del espectro se pueden clasificar en función de la arquitectura (centralizada o descentralizada, o distribuida), de acuerdo con el comportamiento del acceso al medio (cooperativo o no cooperativo) y según la forma como se accede al medio (superpuesta o subyacente) (Lertsinsrubtavee y Malouch, 2016; Pedraza et al., 2016).


Movilidad de espectro

La movilidad espectral da lugar al concepto de *handoff espectral*, mediante el cual el SU cambia de una SO a otra. Durante un *handoff espectral* es inevitable que la comunicación se rompa temporalmente, y por eso resulta ser un aspecto clave en el desempeño de las CRN. La función de decisión espectral juega un papel muy importante para mejorar dicho desempeño, pues determina cuándo y dónde realizar un *handoff espectral* mediante un conjunto de reglas (Hernández, Páez et al., 2017; Hernández, Pedraza y Martínez, 2016; López Sarmiento et al., 2015; Oyewobi y Hancke, 2017).

Arquitectura de la radio cognitiva

El proceso de toma de decisiones en la CRN se clasifica según su arquitectura (figura 5).

Figura 5. Arquitectura de una CRN



Fuente: elaboración propia a partir de Masonta et al. (2013) y Pedraza et al. (2016).

Arquitectura centralizada

En las arquitecturas centralizadas existe un coordinador llamado *entidad central* (CE) o *estación base* (BS), que es el encargado de coordinar, asignar y tomar las decisiones de los canales (figura 6a). La BS cumple con la función de almacenar y procesar la información entregada por los PU y los SU (Ahmed et al., 2016). La desventaja de esta arquitectura radica en el hecho de que la destrucción del nodo central provoca una pérdida general del sistema.

En la arquitectura centralizada, la coordinación de los nodos entre sí se mantiene mediante la difusión de mensajes a través de un canal de control común (CCC) de coordinación del espectro, independiente del canal de datos. Cada usuario determina el canal que puede utilizar para la transmisión de datos, de tal manera que se evite la interferencia. En el caso de que la selección de canal no sea suficiente para evitar la interferencia, se implementa la adaptación de potencia. Las evaluaciones de estas alternativas revelan que el CCC mejora el rendimiento entre un 35 y un 160 % a través tanto de la frecuencia como de la adaptación de potencia (Akyildiz et al., 2006; Tsiropoulos et al., 2016).

Arquitectura distribuida

En la arquitectura distribuida las redes forman una malla (figura 6c), los nodos de cada subsistema comparten información entre sí, se pueden mover libremente y no existe un responsable en la coordinación global de los usuarios licenciados y no licenciados, lo que permite que este tipo de estrategias tenga una alta aplicación en redes en las que no es viable la implementación de infraestructura (Brik et al., 2005; Cao y Zheng, 2005; Krishnamurthy et al., 2005; Pedraza et al., 2016; Salgado, Mora et al., 2016); sin embargo, la desventaja de este modelo es su baja seguridad. Los protocolos


distribuidos, que no requieren infraestructura, son ampliamente utilizados en redes inalámbricas *ad hoc* (crahn) (Wang et al., 2016).

En la arquitectura distribuida, la coordinación entre nodos utiliza una reserva de canal dinámica distribuida basada en la QoS (D-QDCR). El concepto básico detrás de la D-QDCR es que una BS compite con su interferente BS de acuerdo con los requisitos de QoS de los usuarios para asignar una porción del espectro. Aquí, de forma similar al protocolo CCC, los canales de control y datos se separan (Akyildiz et al., 2006; Tsiropoulos et al., 2016).

Arquitectura descentralizada

Las redes descentralizadas son arquitecturas formadas por un conjunto de redes centralizadas y conectadas por enlaces adicionales que crean una malla, por lo que su estructura incorpora los atributos de las redes centralizadas y las distribuidas (figura 6b). Las arquitecturas descentralizadas cuentan con una infraestructura, su implementación es sencilla y tienen buenos niveles de seguridad, ausencia de sobrecarga de comunicación, menor retardo y baja complejidad, entre otras características (Darak et al., 2014). El enfoque descentralizado es una opción eficiente para redes de gran tamaño, además de que es la mejor alternativa para redes de seguridad pública y para servicios de redes sociales (Darak et al., 2017).

Figura 6. Arquitecturas de red centralizada (a), descentralizada (b) y distribuida (c)



Fuente: elaboración propia a partir de Baran (1964) y Pankratev et al. (2019).

Aplicaciones de la radio cognitiva

Con el objetivo de argumentar la relevancia de esta investigación, se podría mencionar la forma como sus resultados pueden impactar el campo de la información y las comunicaciones en cualquier región de aplicación, es decir, no solo en Bogotá, sino en toda Colombia y el mundo entero. Un ejemplo muy claro de esto son las redes *mesh*, las cuales han emergido como una tecnología con una muy buena relación

costo-beneficio; sin embargo, el incremento en la densidad de la red y el requerimiento de un alto *throughput* por parte de sus aplicaciones han degradado su QoS. Así, por un lado, con la CR es posible habilitar el acceso a un mayor segmento del espectro, y por otro, una red *backbone mesh* puede incrementar el área de cobertura basada en puntos de acceso cognitivos (CAP) (Akyildiz et al., 2006).

Asimismo, un desastre natural podría deshabilitar temporalmente o incluso destruir la infraestructura de las comunicaciones, por lo que se haría necesario establecer redes de emergencia, que requieren una gran cantidad de espectro para poder manejar el volumen de tráfico de video, voz y datos. Al respecto, la CR tiene la capacidad de proporcionar dicho espectro sin la necesidad de una gran infraestructura. Es así como la seguridad pública y las redes de emergencia también se pueden beneficiar de las ventajas de la CR (Akyildiz et al., 2006).

Otra de las potenciales aplicaciones de la CR son las redes militares, ya que le permite a la radio militar escoger arbitrariamente frecuencias, BW, modulaciones y codificaciones, adaptándose al ambiente de radio variable del campo de batalla (Akyildiz et al., 2006).

Como conclusión de este apartado, la reconfigurabilidad dinámica de cada uno de los parámetros de operación en una CRN puede garantizar integridad de la información, interoperabilidad, fiabilidad, flexibilidad, redundancia, escalabilidad, seguridad, eficiencia y acceso en todo tiempo y espacio, lo que beneficia significativamente el manejo de la información y las comunicaciones en Colombia.

Desafíos y futuras investigaciones en radio cognitiva

Los desafíos en cuanto a la CR pueden ser varios, debido a que se abarcan temas desde la monitorización del espectro hasta la toma de decisiones de movilidad en este, teniendo en cuenta esquemas de acceso al medio y el tipo de redes en las cuales interactúa la CR. Por lo tanto, en este apartado se describirán brevemente estos desafíos.

Monitorización del espectro

El proceso de monitorización o decisión no puede realizarse al tiempo que se envía la información entre SU, por lo que, si se requiere desarrollar acciones de monitorización, los usuarios deben detener las transmisiones, lo que afecta la eficiencia del espectro. Con base en esto, sería deseable desarrollar algoritmos de monitorización que reduzcan el tiempo que toman mientras mejoran la precisión en el proceso de detección de SO.

Espectro compartido

En trabajos realizados sobre CR muchas veces se hacen suposiciones; una de estas es que los SU conocen de antemano la localización y el nivel de potencia de la transmisión de los PU, lo cual permite realizar los cálculos de interferencia fácilmente; sin embargo, esta suposición no siempre es cierta para algunas CRN (Lertsinsrubtavee y Malouch, 2016).

Procesos de aprendizaje

Debido a las complejidades inherentes de la CR, sería deseable habilitar, en los dispositivos que hagan uso de esta, un proceso de aprendizaje que tenga en cuenta las decisiones tomadas en el pasado para mejorar tanto su comportamiento dentro de la red como sus decisiones futuras. El diseño de este tipo de algoritmos representa un gran desafío, debido a que se debe determinar qué mediciones son necesarias para desarrollar este proceso de aprendizaje (Delgado y Rodríguez, 2016).

Esquemas de control de acceso al medio

Aunque el grupo de investigación del estándar IEEE 802.22 está trabajando en el desarrollo de un protocolo de control de acceso al medio (MAC), otras investigaciones han desarrollado esquemas que no se adecúan al estándar. Por ejemplo, los esquemas MAC distribuidos para crahn no están del todo cubiertos.

Decisión espectral

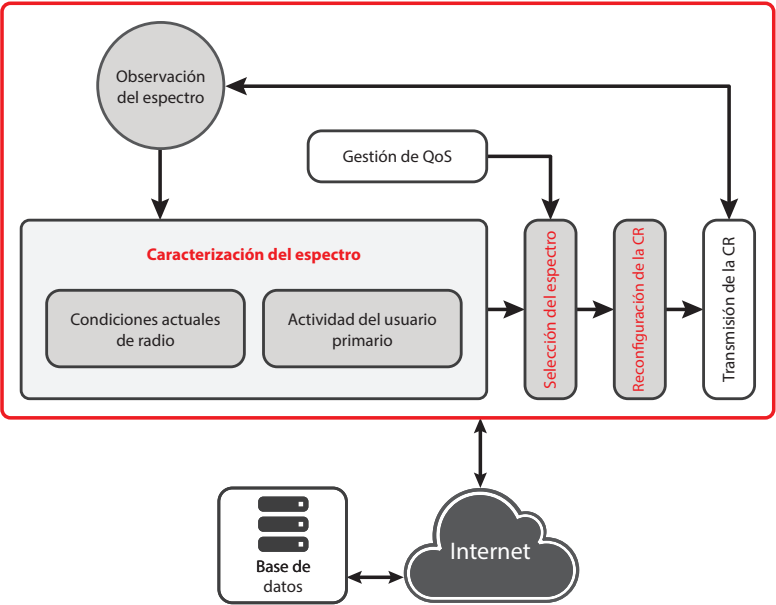
Después de realizar la detección del espectro, los SU deben decidir cuál es la mejor SO; este proceso debe satisfacer los requerimientos de calidad de servicio y, además, debe incluir como criterio de parametrización las acciones adoptadas por otros usuarios (Alias y Ragesh, 2016; Pedraza et al., 2016; Ramzan et al., 2017). Una inadecuada toma de decisiones afecta los parámetros de calidad del servicio: latencia, *throughput*, confiabilidad, señalización, interferencia, eficiencia energética, BW, relación de señal a interferencia más ruido (SINR) y tasa de error (Hernández, Páez et al., 2017; Hernández, Pedraza y Martínez, 2016; López Sarmiento et al., 2015; Oyewobi y Hancke, 2017). De acuerdo con lo anterior, la decisión espectral es una función clave en las CRN; sin embargo, no ha sido tan investigada en comparación con otras funciones del ciclo cognitivo (Akyildiz et al., 2008; Masonta et al., 2013).

La toma de decisiones es un proceso que busca seleccionar la mejor alternativa espectral entre un conjunto finito de posibilidades, lo que les permite a los SU generar una secuencia de acciones que conducirán al logro de sus objetivos (Rizk et al., 2018; Tripathi et al., 2019). Para realizar estructuras de decisión, es necesario implementar modelos con altos desafíos: los algoritmos deben ser escalables y eficientes debido a los altos volúmenes de información que se requieren para el entrenamiento y la

validación, a la complejidad de las tareas y a los estándares de evaluación mínimos de cada aplicación particular (Rizk et al., 2018).

La decisión espectral incluye tres funciones principales: caracterización del espectro, selección del espectro y reconfiguración. Como se muestra en la figura 7, una vez que los canales se identifican (utilizando sensores de espectro, bases de datos de geolocalización u otras técnicas), cada banda del espectro es caracterizada (actividad del PU) a partir de la base de observaciones locales y de la información estadística; culminada esta etapa, los SU proceden a seleccionar la banda espectral más apropiada, y a partir de la decisión tomada, reconfiguran sus parámetros de transmisión y continúan el envío de datos (López Sarmiento, 2017; Masonta et al., 2013).

Figura 7. Marco de decisión del espectro



Fuente: López Sarmiento (2017).

Caracterización del espectro

Para determinar la banda espectral más adecuada, en primer lugar, de acuerdo con las observaciones de la red, se requiere identificar las características de cada una de las bandas espectrales disponibles, teniendo en cuenta la intensidad de la señal recibida, la interferencia y el número de usuarios actuales. Adicionalmente, para realizar un correcto proceso de toma de decisiones, los SU deben observar la disponibilidad de espectro heterogéneo (los huecos espectrales), que varía con el tiempo y el espacio.

En general, la caracterización del espectro debe incluir tanto las condiciones actuales del entorno de radiofrecuencia como el modelo de las actividades del PU. La caracterización del entorno de radiofrecuencia es un proceso que implica identificación del canal, capacidad del canal, retardo de conmutación del espectro, interferencia del canal, tiempo de retención del canal (CHT), tasa de error del canal, ubicación del abonado y pérdida de trayecto.

La caracterización del espectro determina y describe el comportamiento de los canales, por lo que permite distinguir unos de otros, de acuerdo con su tráfico, ocupación y configuración. Dentro de las características de transmisión en un canal, existen parámetros que influyen en su comportamiento y que se deben tener en cuenta a la hora de seleccionar un canal. Por tal motivo, se deben estudiar estos factores con el fin de identificar algunos beneficios que permitan obtener una mejora en el desempeño de estas redes. Como ya se dijo, algunas características son (Masonta et al., 2013):

- Identificación del canal.
- Capacidad del canal.
- Retardo de conmutación del espectro.
- Interferencia del canal.
- CHT.
- Tasa de error del canal.
- Ubicación del abonado.

Identificación del canal

La utilización del canal por parte del PU es quizás el factor más importante, ya que define los espacios y tiempos libres en un canal para ser ocupados por un SU. Esta ocupación se realiza de manera aleatoria, debido a que los tiempos de utilización no son determinísticos, sino impredecibles, y varían en diferentes aplicaciones. Esta actividad de ocupación del canal puede ser modelada como un proceso estocástico aplicando técnicas de inteligencia artificial, como redes neuronales, modelos de Markov y máquinas de soporte vectorial (SVM) (Wang, Ghosh et al., 2011).

Capacidad del canal

Cada banda del espectro en un sistema de multiplexación por división de frecuencia ortogonal (OFDM) tiene un BW diferente, el cual está compuesto por varias subportadoras que estiman una capacidad normalizada del canal. Las investigaciones, en general, se han enfocado en estimar la capacidad de BW mediante el estudio de otros parámetros, como el nivel de interferencia, la tasa de error y la propagación (Lee y Akyildiz, 2011).

Se ha demostrado que el método tradicional de estimación de la capacidad del canal —utilizando la relación señal a ruido (SNR)— conduce a una decisión de espectro no óptima (Masonta et al., 2013).

Las capacidades de BW de un canal licenciado están limitadas por la entidad reguladora, lo que hace que el SU requiera analizar recursos cuando el BW del PU sea menor que el requerido por el SU. Al respecto, el BW no es utilizado en el modelo propuesto en este libro.

Retardo de conmutación del espectro

Esta característica nace como consecuencia de la intervención de un PU cuando el SU está operando en un canal licenciado; en ese momento, el SU debe detectar nuevos canales con diferentes frecuencias y conmutar reconfigurando sus parámetros de transmisión, pero ese proceso de conmutación toma un tiempo considerable que afecta el desempeño de las CRN (3GPP, 2011).

Con el fin de mejorar el rendimiento de retardo en CRN, el desafío que se presenta está en reducir el retardo de detección del canal, el tiempo que tarda el SU en configurar sus parámetros de transmisión y el tiempo que gasta en acceder al nuevo canal.

Interferencia del canal

La interferencia es la mayor consecuencia del proceso de interacción entre usuarios en una red. Al acceder al espectro, un SU puede afectar la señal al alterar los servicios del PU; por lo tanto, la interferencia está definida como la perturbación de la señal debido a la coexistencia entre PU y SU en un área de cobertura del PU (Amir et al., 2011).

Existen diferentes estudios para evitar interferencias entre PU y SU en áreas de cobertura específicas en las que es importante que el SU no transmita mientras exista presencia de un PU.

Tiempo de retención del canal

El CHT es importante al momento de modelar el acceso al canal, debido a que estudia los tiempos de activación y de inactividad de los PU y los SU, además de que permite acceder a canales ranurados regulando y sincronizando este acceso (Akyildiz et al., 2006).

Inicialmente, se estudian los tiempos de duración de activación de los usuarios y los tiempos en que el canal permanece libre; luego, se definen bloques de tiempo de tamaños similares que serán recursos libres para ser utilizados por los SU, y,

finalmente, se accede al canal que más se ajuste a las mediciones realizadas, lo que reduce interferencias en la interacción (Akyildiz et al., 2006).

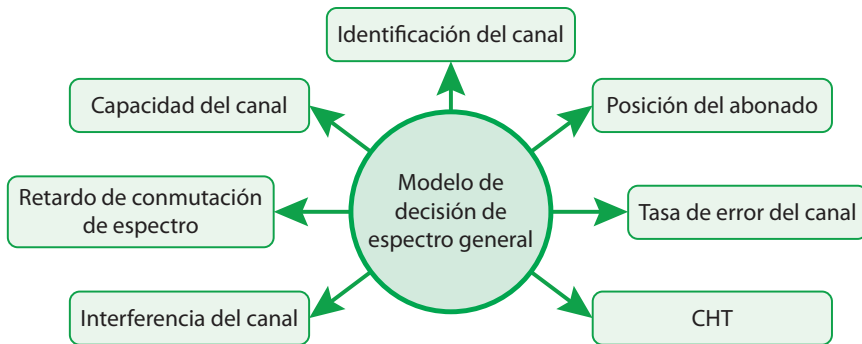
Tasa de error del canal

Este factor está directamente relacionado con el nivel de interferencia, el BW y la banda de frecuencia disponible, los cuales influyen directamente en la recepción o transmisión de errores de bit en un canal. Esta tasa de error de bit (BER) es indicada con la SNR (Matinmikko et al., 2008).

Ubicación del abonado

El SU, dentro de su funcionamiento y proceso de detección, debe obtener información geográfica y del ambiente de radiofrecuencia, mediante una función del sistema de posicionamiento global (GPS), para coordinar información entre los nodos o servidores centrales que identifiquen la ubicación de cada SU y para poder construir un mapa de actualización mundial. Este proceso permitirá predecir situaciones futuras de intervenciones de los PU (Azarfar et al., 2012).

Figura 8. Caracterización del ambiente de radio



Fuente: elaboración propia a partir de Masonta et al. (2013).

La figura 8 presenta una síntesis de los componentes que debe tener en cuenta un modelo de decisión de espectro para cumplir con el objetivo de acceder a este oportunamente. Aunque diseñar un modelo que evalúe todas las características puede ser robusto, complejo y computacionalmente poco eficaz, sí es misión del ingeniero idear un modelo que utilice las características principales y necesarias y que reduzca su tiempo de ejecución.

Selección del espectro-decisión del espectro

La decisión del espectro (proceso de toma de decisiones) determina cuál es el mejor canal de frecuencia entre los disponibles, según los requisitos de calidad de servicio

de las aplicaciones. Para esta función se han desarrollado algoritmos que tienen en cuenta las características del canal de radio y el comportamiento estadístico de los PU (Alias y Ragesh, 2016; Hernández, Páez et al., 2017; Pedraza et al., 2016; Ramzan et al., 2017).

Reconfiguración del canal de radio

En las redes inalámbricas tradicionales, los terminales de radio están configurados estáticamente para operar sobre canales de frecuencia predefinidos con parámetros y características preestablecidos del transceptor. Los canales de radio son capaces de adaptarse rápidamente a los cambios (Masonta et al., 2013).

La tarea de reconfiguración de la CR requiere una clara comprensión de cómo interactúan los parámetros de comunicación dentro de las diferentes capas de protocolo. Sin embargo, aunque estos sistemas pueden emplear técnicas adaptativas para ajustar diversos parámetros de transmisión, su arquitectura —basada en *hardware*— limita su flexibilidad para adaptarse al entorno externo (López Sarmiento, 2017).

Tipos de enfoque de la decisión espectral

Las CRN pueden operar de acuerdo con varios enfoques básicos, cada uno de los cuales presenta ventajas y desventajas frente a su enfoque opuesto. En esta sección se estudiarán el enfoque con infraestructura frente al enfoque *ad hoc*, el enfoque centralizado frente al distribuido, el enfoque de asignación única frente al multicanal, el de inclusión de modelos de PU y SU frente al de no inclusión y el de CCC dedicado frente al dinámico.

Enfoque con infraestructura vs. ad hoc

De acuerdo con la arquitectura de la red, las CRN pueden clasificarse en redes con infraestructura o en *crahn* (Ahmed et al., 2016; Akyildiz et al., 2006). Las CRN basadas en infraestructura tienen una entidad de red central similar a una BS en las redes celulares o a un punto de acceso en las redes inalámbricas de área local. Por otro lado, las *crahn* no tienen ninguna infraestructura, por lo que un SU se comunica con otro SU a través de una conexión *ad hoc*, en bandas espectrales tanto licenciadas como no licenciadas (Akyildiz et al., 2009).

En las redes con infraestructura, la información observada por cada SU alimenta la base de datos de la entidad central, de forma que esta pueda tomar decisiones inteligentes a fin de maximizar los parámetros de comunicación, como el *throughput*, el BW, la SINR y el balanceo de carga, entre otras, y eliminar o minimizar la interferencia hacia los PU (Akyildiz et al., 2009). En el caso de las *crahn*, los SU son responsables de tomar sus propias decisiones con base únicamente en observaciones locales, lo cual les impide realizar un uso eficiente de los recursos de la red entera.

Para compensar esta imposibilidad, los SU pueden hacer uso de esquemas de colaboración, en los cuales cada SU intercambia su información de observación del espectro local, lo que les permite tener un conocimiento aproximado de la red completa (Akyildiz et al., 2009).

Enfoque centralizado vs. distribuido

Si las CRN cuentan con infraestructura, pueden operar tanto con un enfoque centralizado como con uno distribuido. En el enfoque centralizado existe una entidad central encargada de coordinar las funciones necesarias para la decisión y asignación del canal de frecuencia durante una decisión espectral. Esta entidad central, también conocida como *estación base central* (CBS), cumple además con la función de almacenar y procesar la información del ambiente de radio y del espectro recibida por los SU periódicamente o por demanda (Ahmed et al., 2016; Tragos et al., 2013).

Debido a que la CBS tiene un nivel mucho más elevado de procesamiento y autonomía energética que los SU, desarrolla también funciones de monitorización del espectro de forma periódica. Esta información, junto con la proporcionada por los SU, actualiza dinámicamente la base de datos central (CDB). La CBS procesa periódicamente la información de la CDB y calcula valores estimados de algunos parámetros de interés del espectro, como la probabilidad de disponibilidad (AP), la SINR, el tiempo estimado de disponibilidad (ETA) y el BW de los canales, entre otros, los cuales permiten tomar decisiones más acertadas para la SA. Lo anterior libera a los SU de la carga computacional requerida para ejecutar un algoritmo robusto de SA.

La principal ventaja del enfoque centralizado es la observación y el conocimiento global de la red, lo cual permite maximizar el *throughput* de la red, minimizar la interferencia entre los SU, obtener una asignación multicanal justa y, en general, mejorar el nivel de desempeño de la red (Alnwaimi et al., 2011; Byun et al., 2008). Sin embargo, su mayor desventaja es la cantidad de información de señalización que se introduce a la red para coordinar los procedimientos de intercambio de información entre la CBS y los SU; además, si la CBS llegara a fallar, se perdería el control sobre la SA y se crearía un desequilibrio y un potencial caos en el sistema (Tragos et al., 2013).

En el enfoque distribuido, por su parte, no existe una CBS responsable de coordinar la SA a los SU. Por tanto, los SU toman decisiones por ellos mismos o de forma colaborativa, con otros SU vecinos, a través del intercambio de información y medidas dentro de un rango determinado (por ejemplo, 2-3 saltos). Lo anterior hace que el enfoque distribuido sea más flexible y eficiente que el enfoque centralizado, ya que puede adaptarse rápidamente a los posibles cambios o variaciones del ambiente de radio o de la red, pues solamente tendrán que hacer modificaciones e intercambiar información los SU del área afectada. Otra ventaja significativa del enfoque

distribuido es la baja información de señalización requerida, ya que solo los nodos vecinos intercambian información. Entre las desventajas de este enfoque se encuentra que las decisiones tomadas no son óptimas en razón de que los nodos solo tienen información de sus vecinos y no de la red completa, además del hecho de que es posible que la información intercambiada no sea suficiente (Tragos et al., 2013). Asimismo, la falta de un soporte centralizado no permite obtener información completa de la topología de la red, lo que provoca colisiones entre SU e interferencia al PU (Giupponi y Pérez-Neira, 2008). En conclusión, en lo que respecta a la SA, el enfoque distribuido puede tomar decisiones adecuadas en casos de baja carga de tráfico, pero para los casos contrarios, el enfoque centralizado toma mejores decisiones (Tragos et al., 2013).

Una solución híbrida entre el enfoque centralizado y el distribuido es el enfoque descentralizado (*cluster*), el cual intenta eliminar las desventajas de cada uno. La red es dividida en M *clusters*, cada uno con un enrutador principal (*cluster head*). Cada SU envía la información de espectro detectada a su correspondiente *cluster head*, y este se encarga de combinar la información completa y de generar un vector de SA final. Todos los *cluster heads* intercambian su respectivo vector, y de esta manera cada uno conoce el estado general de la red. Con la información completa de la red, cada *cluster head* decide qué canal de frecuencia asignar y transmite esta información a todos los demás *cluster heads* de la red. Este enfoque es más robusto contra fallas, hace un uso más eficiente del BW disponible, logra una mejor distribución de los usuarios —en *clusters*— y de la carga en múltiples canales y reduce la sobrecarga de información de control, ya que los mensajes se intercambian a nivel del *clúster* y no de la red completa (Alsarhan y Agarwal, 2009; Chen et al., 2007; Tragos et al., 2013).

Enfoque de asignación única vs. multicanal

El enfoque de asignación de canal único, como se hace tradicionalmente, consiste en la asignación de una frecuencia central y un BW específico alrededor de esa frecuencia, lo que implica que los canales sean contiguos en el espectro.

El caso de la asignación multicanal, por su parte, consiste en la agrupación de varios canales disponibles no adyacentes para formar un solo canal. Este enfoque permite aumentar el BW del SU aprovechando las SO con baja capacidad de canal. Una de las técnicas que permiten el acceso simultáneo a varios canales de frecuencia es la multiplexación por división de frecuencia ortogonal discontinua (DOFDM) (Chen et al., 2008), que posibilita un uso más eficiente del espectro, ya que aprovecha los canales que por sí solos no son adecuados debido a su restringido BW pero que, en conjunto con otros canales similares, pueden satisfacer los requerimientos de un SU. La asignación multicanal puede incrementar significativamente la capacidad de la red y la tasa de datos de los SU (Dadallage et al., 2016; Tragos et al., 2013).

Sin embargo, la asignación multicanal también tiene limitaciones, debido a que los transreceptores no pueden agregar canales de frecuencia que se encuentren muy distanciados entre sí; en otras palabras, el *span* de agregación no es ilimitado, ya que generalmente cada transreceptor tiene un *span* máximo especificado (por ejemplo, de 12 MHz). Esto significa que, si dos canales están separados por más de 12 MHz, no pueden unirse en un solo canal; por tanto, los algoritmos de SA deben evitar crear pequeños canales de frecuencia que posteriormente no puedan agregarse. También es necesario analizar que la utilización de múltiples canales por parte de un solo SU no deje sin SO a otros SU, por lo que el algoritmo de SA debería manejar alguna métrica de justicia para estos casos (Tragos et al., 2013).

Enfoque de inclusión de modelos de usuarios primarios y secundarios vs. no inclusión

De acuerdo con algunos trabajos (Akter et al., 2008; Chen y Oh, 2016; Csurgai-Horváth y Bitó, 2011; Rahimian et al., 2014; Rodríguez et al., 2015; Wu et al., 2016), la precisión y exactitud en el modelado de la actividad de los PU y los SU es relevante para lograr un buen desempeño en las CRN, pues permite asignar inteligentemente cada canal de frecuencia disponible, optimizar el uso del espectro, maximizar los parámetros de comunicación —la tasa de datos, el BW, la SINR y el balanceo de carga, entre otros— y eliminar o minimizar la interferencia entre PU y SU. Sin embargo, la validez de dichos modelos generalmente está restringida a un determinado tiempo y lugar para los cuales se diseñaron.

Una estrategia de SH reactiva provoca interferencia temporal con el PU, debido a que durante el tiempo que tome realizar la movilidad del SU coexistirán los dos en el mismo recurso espectral. Un buen modelo del PU puede evitar o minimizar esta interferencia, a través de una estrategia de SH proactiva (Wu et al., 2016). Sin embargo, el problema radica en que dichos modelos están basados en procesos estocásticos, que utilizan las observaciones pasadas del canal para predecir la disponibilidad del espectro futuro, lo que podría llevar a tener que hacer muchas conmutaciones de canal innecesarias si el modelo de predicción es imperfecto. Pero no solo el modelo de actividad del PU es relevante: Akter et al. (2008) proponen un modelo de predicción para la actividad del SU, debido a que en muchas oportunidades múltiples SU compiten por el mismo recurso de espectro, lo que degrada la QoS. A través de la implementación de un filtro de Kalman, se logró realizar una significativa estimación del número de SU en el futuro instantáneo.

Enfoque de canal de control común dedicado vs. dinámico

El CCC es uno de los requerimientos comunes en la SA en CRN, pues permite la coordinación entre SU para la asignación del canal. El CCC es un canal predefinido para el intercambio de información de señalización, control y espectro entre los SU

y puede ser global o local, dependiendo del operador de red (Kumar et al., 2016). A continuación, se presentan las ventajas y desventajas de tener un CCC dedicado o dinámico para la asignación del canal de frecuencia.

En la literatura son más los trabajos de investigación que defienden la necesidad de contar con un CCC dedicado (Ding et al., 2010; Kim et al., 2010; Ma et al., 2007), enfoque que se puede dividir en dos situaciones: 1) cuando el CCC y el canal de datos del SU son el mismo y 2) cuando el CCC se encuentra en un canal independiente del canal de datos del SU (Akyildiz et al., 2009). Cuando el canal de datos del SU y el CCC son el mismo, su utilización se comparte por periodos de tiempo fijos, no es necesario un transceptor adicional y no se requiere cambiar la frecuencia para recibir o transmitir los mensajes. Sin embargo, cuando sea necesario realizar un SH, el CCC desaparecerá. Aunque este enfoque proporciona una mayor eficiencia espectral al utilizar un solo canal de frecuencia, la cantidad de información del CCC reduce el *throughput* de la transmisión de datos del SU (Akyildiz et al., 2009).

Por otro lado, cuando el canal de datos del SU y el CCC son independientes, el CCC no se ve afectado por la realización de un SH; sin embargo, tener dos canales implica la necesidad de contar con un transceptor adicional y un incremento en el retardo. El CCC independiente puede ser global, si es el mismo para todos los SU en una CRN, o local, si es dedicado solamente a una pequeña área geográfica. En ambos casos, es necesario contar con un algoritmo de asignación de CCC que permita encontrar el canal óptimo del área geográfica de la CRN (Akyildiz et al., 2009).

Con respecto al enfoque del CCC dinámico, existen muy pocos trabajos (Almasaeid y Kamal, 2010; Kondareddy et al., 2008). Este enfoque, aunque hace un uso más eficiente del espectro, es vulnerable al problema del nodo escondido, que puede llevar a un decremento del nivel de conectividad; además, una selección dinámica de un CCC puede incrementar el nivel de retardo en la transmisión del SU (Tragos et al., 2013).

Criterios de decisión espectral

En la SA existen múltiples criterios que ayudan a tomar decisiones inteligentes. Sin embargo, cuántos y cuáles criterios utilizar depende del objetivo de cada toma de decisiones. Para realizar un análisis objetivo, se analizaron todas las variables que intervienen durante la toma de decisiones y que pueden afectar el desempeño de la red, a partir del análisis de cada una de las investigaciones consultadas sobre el tema de decisión espectral en CRN (Ahmed et al., 2014; Masonta et al., 2013; Tragos et al., 2013).

Estos criterios proporcionan la información necesaria para alimentar los algoritmos de toma de decisiones con base en los criterios de evaluación para la SA a los SU en las CRN. Además, varían de acuerdo con los objetivos de cada esquema de SH.

Calidad de servicio

La QoS es uno de los criterios más relevantes en los algoritmos de toma de decisión para la SA a los SU en las CRN, pues permite diferenciar entre aplicaciones sensitivas al retardo y aplicaciones no sensitivas al retardo; en otras palabras, permite clasificar las aplicaciones en tiempo real (RT) y mejor esfuerzo (BE). Con esta información, se puede tomar la decisión más adecuada en términos de las SO.

Las aplicaciones que no son sensibles al retardo pueden ser asignadas a SO con un nivel de disponibilidad intermedio, mientras que las aplicaciones sensibles al retardo pueden ser asignadas a SO con un nivel alto de disponibilidad, a través de estrategias proactivas que minimicen el valor del retardo global; aquí, el *throughput* resulta más relevante que la BER. Lo anterior permite mejorar la eficiencia espectral.

Calidad del enlace

La calidad del enlace es otro criterio importante que normalmente se refleja a través de la BER y la SNR, que afectan la QoS de la red. La calidad del enlace se trabaja a veces como relación señal a interferencia (SIR) o como SINR.

Tasa de error de bit

La BER es el número de bits recibidos que han sido alterados debido al ruido y la interferencia dividido por el número total de bits transmitidos durante un periodo de tiempo (Ahmed et al., 2014). La BER promedio del canal es un parámetro útil para estimar la caracterización del ambiente de radio en las CRN (Masonta et al., 2013). Asimismo, el nivel de BER está relacionado con el nivel de SNR, lo que causa que la energía por bit transmitido sea una métrica importante en la estimación del error (Matinmikko et al., 2008). Así, a mayor SNR, menor BER, aunque es importante tener en cuenta que un mayor nivel de SNR generalmente implica un mayor nivel de potencia, lo cual causa mayor interferencia al PU. Por tanto, es necesario estimar un nivel mínimo de SNR que garantice cierto nivel de BER pero que no perjudique la comunicación (Tragos et al., 2013).

Calidad del enlace de comunicación

En CRN, la calidad del enlace de comunicación puede variar dinámicamente en el tiempo y el espacio; por ello, es importante para el SU monitorizar y analizar periódicamente la calidad del canal que está siendo utilizado, por ejemplo, a través de la SNR. La SNR define la relación entre la potencia de la señal y la potencia del ruido. La calidad del enlace de comunicación es otro parámetro importante que afecta y refleja la QoS de la red. Usualmente, la fuerza de la señal recibida (RSS) y la SINR son consideradas similares, pero la RSS está más inclinada a proveer conectividad, y la SINR, a proveer QoS de la red (Ahmed et al., 2014).

Probabilidad de disponibilidad del canal

La disponibilidad de canal (AP) es un criterio que busca estimar la probabilidad de que un canal de frecuencia esté disponible. Algunos trabajos la expresan como *ocupación de canal*, en cuyo caso se busca estimar la probabilidad de que un canal de frecuencia esté ocupado. Este criterio es muy importante en la SA, ya que puede determinar las posibilidades de que una SO esté libre para ser utilizada por un SU. Su valor es proporcional a la media aritmética de las medidas de disponibilidad obtenidas anteriormente por cada canal. Aquí resulta interesante determinar el periodo de tiempo a partir del cual se debe actualizar el valor promedio de la disponibilidad por canal. Un análisis de la serie de tiempo para esta variable podría estimar un intervalo de confianza para el periodo de tiempo de actualización, lo que permite lograr una mejor eficiencia de energía al no tener que correr el algoritmo de estimación de disponibilidad de canal continuamente (Ahmed et al., 2016).

Tiempo estimado de disponibilidad del canal

El ETA es un criterio que busca determinar el valor promedio que un canal de frecuencia permanece disponible para un SU o un PU. A diferencia del criterio de la AP, en el que se determina la probabilidad de encontrar cierto canal libre, en el criterio de ETA se estima el tiempo medio durante el cual el canal permanece libre una vez está disponible. Estos dos criterios no son sustitutivos, sino complementarios, ya que dos canales pueden tener la misma probabilidad de disponibilidad pero contar con distribuciones de tiempo de disponibilidad distintas. Seleccionar un canal con un tiempo estimado de disponibilidad alto garantiza un menor número de SH. Al respecto, Pla et al. (2010) proponen un modelo markoviano para determinar la duración de las SO: una vez se ha modelado el tiempo ocioso del PU, se aplican técnicas de matriz analítica para determinar la duración de las SO para ser ocupadas por los SU. La principal desventaja de esta técnica radica en su complejidad.

Patrón de tráfico del usuario primario y el usuario secundario

No hay ninguna garantía de que el canal de frecuencia seleccionado esté disponible durante toda la comunicación, por lo que es beneficioso contar con un modelo que estime la actividad del PU en la CRN. En algunos trabajos se asume que se puede conocer el patrón de llegadas del PU, ya que no es aleatorio estadísticamente, debido a que depende del comportamiento humano. De esta forma se pueden estimar la AP y el ETA (Ahmed et al., 2016; Akyildiz et al., 2009; Christian et al., 2012; Wu et al., 2016).

Wang et al. (2010) exponen varios trabajos que argumentan que el comportamiento de ocupación de los canales exhibe patrones que pueden ser modelados estadísticamente; sin embargo, diferentes modelos pueden aplicarse a diferentes apli-

caciones de voz, video o paquetes de datos generales. Varios modelos asumen que la actividad del PU se puede modelar con interllegadas distribuidas exponencialmente (Chou et al., 2007; Kim y Shin, 2008; Lee y Akyildiz, 2008). En la investigación de Sriram y Whitt (1986), por ejemplo, el patrón de tráfico se modela como un proceso de dos estados *on-off*, nacimiento y muerte, con sus respectivas tasas de nacimiento y muerte. Por otra parte, otros modelan la actividad del PU a partir del tiempo entre arribos de paquetes, la longitud de los paquetes y la cantidad de paquetes.

Algunos trabajos se esfuerzan en modelar el comportamiento del PU en bandas específicas a partir de datos experimentales (Pedraza et al., 2014). Willkomm et al. (2008) utilizan medidas reales de una red celular para modelar las características del uso del espectro por parte del PU, análisis que muestra que el modelo de llegadas exponencialmente distribuidas es adecuado para capturar el tiempo de actividad del PU en llamadas no inalámbricas. En cuanto a las llamadas móviles, dicho modelo no resulta útil, siendo más efectivo el uso de un modelo de caminata aleatoria, aun en condiciones de tráfico alto. Hernández et al. (2009), por su parte, validaron el uso de series de tiempo —como los modelos autorregresivo (AR), de media móvil (MA) y autorregresivo integrado de media móvil (ARIMA)— en el modelamiento y predicción de tráfico en redes Wi-Fi, y obtuvieron un alto nivel de precisión en el pronóstico de rango corto. Li y Zekavat (2008) presentan un trabajo sobre la predicción del patrón de tráfico para CRN.

Wei et al. (2006) almacenan en un repositorio la información pasada y presente de interés para una CRN, incluyendo la información de localización y tráfico del SU y el PU. Al respecto, es importante validar la información almacenada para asegurarse de que no es obsoleta. Esta colección de datos debe ser estadísticamente analizada y usada para modelar la actividad del PU en un canal de frecuencia dado (Issariyakul et al., 2009). De acuerdo con el aprendizaje maquinal, los SU deberían ser hábiles para recordar las lecciones aprendidas en el pasado y para actuar rápidamente en el futuro (Marinho y Monteiro, 2012). Idealmente, el SU debería conocer el patrón de tráfico del PU y seleccionar la estrategia de *handoff* más adecuada. Asimismo, cuando el patrón de tráfico del PU cambie, el SU debería observar el cambio y adaptar una estrategia de *handoff* según el nuevo comportamiento (Akyildiz et al., 2009; Christian et al., 2012). Las estrategias de SH futuras deberían considerar un factor de aprendizaje.

Fecha y hora

La utilización del espectro depende del tiempo y del espacio. El criterio de fecha y hora puede brindar buena información para estimar el nivel de tráfico y congestión de la red a partir de las estadísticas de información pasada (Hernández et al., 2009; Hernández et al., 2013; Issariyakul et al., 2009; Wei et al., 2006; Zhang et al., 2016).

Una base de datos con estadísticas pasadas y recientes podría permitir estimar la disponibilidad y acceso al espectro con cierto nivel de precisión. Las series de tiempo son una herramienta muy útil en este contexto (Hernández et al., 2009).

Geolocalización

De acuerdo con la naturaleza de las redes inalámbricas, la disponibilidad de espectro cambia no solamente con el tiempo sino también con la movilidad espacial (Duan y Li, 2011; Zhang et al., 2016). Conocer la posición exacta de los SU y los PU es una ventaja en el momento de tomar decisiones para la SA. Esta información puede mejorar las estrategias para evitar la interferencia al PU y para reducir la tasa de SH, al determinar una distancia umbral a partir de la cual se deba realizar el cambio de canal. En zonas rurales, debido a la baja demanda de espectro, es posible utilizar un BW más amplio. Este conocimiento puede ser útil para futuras predicciones de SO y para la caracterización del ambiente de radiofrecuencia.

Capacidad del canal o ancho de banda disponible

Muchos trabajos se enfocan en parámetros como la tasa de datos, el retardo, el nivel de interferencia, la BER o la tasa de SH, los cuales son relevantes para la eficiencia espectral; sin embargo, la capacidad de canal es otra variable de interés en la SA, ya que algunas aplicaciones requieren un BW mínimo para mantener sus parámetros de banda (Kumar et al., 2016). En los sistemas de OFDM, cada banda espectral tiene un BW diferente que consiste en varias subportadoras (Masonta et al., 2013).

Fuerza de la señal recibida

También conocida como *indicador de fuerza de la señal recibida* (RSSI) y *fuerza relativa de la señal recibida* (RRSS), la RSS es un factor tradicional e importante para tomar decisiones de SH. La RSS provee información acerca del nivel de potencia que está siendo recibido por la antena, el cual decrementa cuando el usuario se aleja del punto de acceso actual de la red (Ahmed et al., 2014). Este criterio permite determinar el momento en el que se hace necesario realizar un cambio de canal.

Costo monetario

Las redes que funcionan sobre bandas de espectro licenciadas proveen ciertos servicios a los usuarios a cambio de un costo monetario que depende principalmente del recurso de BW y del tiempo durante el cual se utilice. Si dos redes proveen la misma QoS, la red con el costo más bajo será la preferida por los SU (Ahmed et al., 2014), debido a lo cual el valor del costo monetario es una variable de información de interés para el algoritmo de SA.

Preferencias de usuario

Las preferencias de los usuarios pueden ser definidas con base en la red escogida entre las disponibles para la ejecución de las aplicaciones y se pueden definir a partir de las prioridades asignadas a cada aplicación, las cuales pueden ser altas o bajas. Usualmente, los usuarios prefieren conexiones con alto BW, bajo costo y amplia cobertura, entre otras características (Ahmed et al., 2014). En la mayoría de los trabajos que analizan las preferencias de los usuarios, se usan funciones de utilidad que permiten describirlas y manipularlas matemáticamente para encontrar óptimos.

Seguridad de la red

La seguridad es uno de los aspectos más relevantes en la convergencia de redes, debido a que estas tienen sus propias opciones de seguridad. El proceso de SH requiere proveer seguridad y privacidad contra interceptaciones ilegales o ataques de denegación de servicio (Ahmed et al., 2014).

Técnicas y algoritmos para la asignación espectral

La SA y, por ende, la decisión espectral son un aspecto clave en las CRN para reducir la latencia, incrementar la tasa de datos, aumentar el BW, mejorar la capacidad y cobertura y optimizar el uso del espectro, garantizando la QoS necesaria para aplicaciones de RT y BE.

Seleccionar un canal con las características requeridas sobre el cual un SU pueda continuar su sesión de transmisión de datos es un asunto apremiante en las CRN (Christian et al., 2012). Una pobre selección de canal puede causar múltiples SH, lo que degrada el desempeño de todo el conjunto (Christian et al., 2012; Hernández, Salgado et al., 2015; Hernandez-Guillen et al., 2012).

Esta sección tiene por objetivo presentar una revisión de los algoritmos de SA más relevantes en CRN, así como su clasificación de acuerdo con la literatura actual, a partir del análisis de publicaciones recientes de corriente principal con sus respectivas citas, tratando de proveer un marco referencial completo de la literatura actual sobre estos algoritmos. Los principales resultados determinan la importancia de una SA inteligente, teniendo en cuenta la carga de tráfico, el comportamiento del usuario, los niveles de interferencia, la caracterización del espectro, el tipo de aplicación y la necesidad de contar con múltiples canales de frecuencia. Como conclusión, consideramos importante diseñar algoritmos adaptativos que permitan hacer un uso eficiente de las porciones disponibles del espectro licenciado.

Una vez que todas las SO se detectan y se caracterizan, se debe seleccionar la que más se acerque a los requerimientos para la transmisión, teniendo en cuenta los requisitos de QoS del usuario (que se deben conocer de antemano) y las características

del espectro. Con base en las necesidades de los usuarios, se puede determinar: la velocidad de datos, la BER aceptable, el retardo máximo permitido, el modo de transmisión y el BW para la transmisión. Entonces, puede ser elegido el conjunto de bandas del espectro apropiado, de acuerdo con las reglas de decisión y los algoritmos que evalúan las posibles soluciones. Zheng y Cao (2005) presentan cinco reglas para asignar espectro que se centran en la equidad y el costo de la comunicación; sin embargo, este método asume que todos los canales tienen una capacidad de rendimiento similar (Akyildiz et al., 2006). Lo ideal es ajustarse a los requerimientos que imponen las distintas aplicaciones. Kanodia et al. (2004), por su parte, proponen un protocolo de saltos de canal de frecuencia oportunista para la búsqueda de un canal de mejor calidad basada en la SNR.

Proponemos una clasificación que agrupa los algoritmos para la selección de las SO en cinco clases: 1) toma de decisiones multicriterio (MCDM), 2) algoritmos inteligentes, 3) técnicas de aprendizaje, 4) funciones de decisión y 5) estadísticos. La figura 9 describe los algoritmos más relevantes de cada clase de la clasificación propuesta.

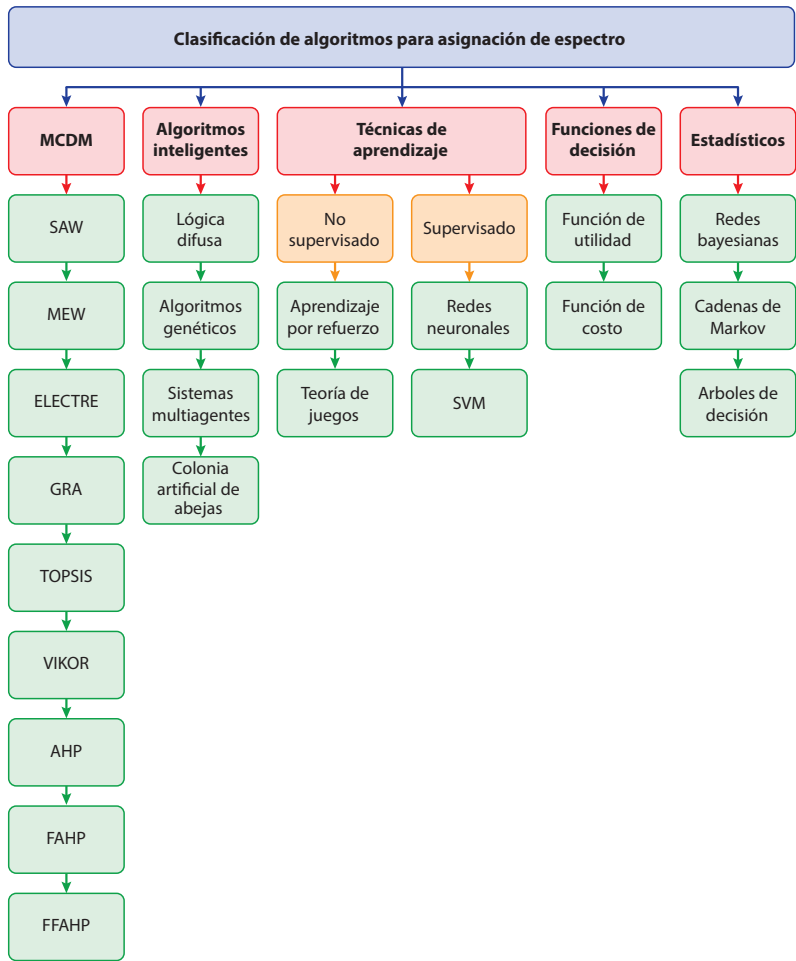
Algoritmo de asignación aleatoria

El algoritmo de asignación aleatoria (RA) es la forma más básica para la SA y la que peor desempeño provee, razón por la cual no se encuentra en la clasificación de la figura 9; sin embargo, ya que selecciona de forma completamente aleatoria las SO, se ha convertido en el punto de referencia más utilizado para contrastar y comparar los resultados obtenidos con otros algoritmos de SA propuestos en la literatura actual.

Algoritmos de toma de decisiones multicriterio

El problema de SA tiene múltiples variables por analizar para seleccionar una sola SO; por tanto, los algoritmos basados en MCDM son ampliamente usados en este tipo de problemas, en los que la relación entre los criterios de decisión (DC) es medida a través de pesos que son ajustados de acuerdo con los requerimientos del diseñador. Al cabo de un cierto número de iteraciones, el algoritmo determinará la mejor solución (Hernández et al., 2015a).

Figura 9. Clasificación de los algoritmos para la asignación de espectro



Fuente: elaboración propia.

Simple additive weighting

El algoritmo *simple additive weighting* (SAW) desarrolla una matriz de decisión conformada por criterios y alternativas (SO); para cada intersección de la matriz, el algoritmo asigna un peso de acuerdo con los criterios del diseñador, lo que permite establecer una calificación para cada una de las SO evaluadas y obtener, así, un *ranking* de todas las alternativas. La SO con mayor puntaje será la seleccionada (Hernández et al., 2015a; Ramírez Pérez y Ramos Ramos, 2010).

La alternativa A_i está definida por la ecuación (1) (Ramírez Pérez y Ramos Ramos, 2013):

$$u_i = \sum_{j=1}^M \omega_j r_{i,j} \quad \forall i \in 1, \dots, N \quad (1),$$

donde $r_{i,j}$ pertenece a la matriz y la suma de los pesos es 1.

Los pasos para desarrollar este algoritmo son: 1) identificar los objetivos y las alternativas, 2) evaluar las alternativas, 3) determinar los pesos de cada combinación, 4) adicionar los valores agregados según las preferencias y 5) analizar la sensibilidad (Hernández et al., 2015a; Hübner, 2007; Ramírez Pérez y Ramos Ramos, 2010, 2013).

En Hernández, Giral y Santa (2015) se utiliza un SAW para seleccionar la mejor SO en una banda de frecuencia del sistema global para las comunicaciones móviles (GSM), evaluando la cantidad de *handoffs* realizados y comparando los resultados con otros dos algoritmos de SA.

Multiplicative exponent weighting

El MEW, propuesto para SA por Stevens-Navarro y Wong (2006), es otro algoritmo MCDM muy similar al SAW. La principal diferencia es que en el MEW, en lugar de suma, hay multiplicación. En MEW, la calificación de las SO es determinada por el producto de los pesos de los DC.

El puntaje S_i de la SO i es determinado por la ecuación (2) (Hernández et al., 2015a; Hernández, Giral y Santa, 2015; Hübner, 2007; Ramírez Pérez y Ramos Ramos, 2010, 2013; Stevens-Navarro, Martinez-Morales et al., 2012; Stevens-Navarro y Wong, 2006):

$$S_i = \prod_{j \in N} x_{ij}^{w_j} \quad (2),$$

donde x_{ij} denota el criterio j de la SO i , w_j denota el peso del criterio j y $\sum_{j=1}^N w_j = 1$.

Es necesario tener en cuenta que, en (2), w_j es una potencia positiva para una métrica de beneficio y negativa para una métrica de costo. Debido a que la normalización de parámetros no es requerida (es opcional), el puntaje de la SO asignado por MEW no tiene una cota superior (Yoon y Hwang, 1995).

En Hernández et al. (2015b) se utiliza MEW para seleccionar la mejor SO en una banda de frecuencia de comunicaciones móviles, evaluando el nivel de *throughput* y el BW y comparando los resultados con otros dos algoritmos de SA.

Electre

El algoritmo electre (*elimination and choice expressing the reality*), propuesto inicialmente por Christian et al. (2012), es un MCDM que realiza comparaciones entre parejas de alternativas utilizando cada uno de los criterios por separado (Valenta et al., 2010). En general, electre utiliza un vector de criterios de referencia para ajustar los valores iniciales de los criterios de las alternativas antes de compararlas. El valor de cada uno de los criterios en la matriz de decisión se compara con el correspondiente valor de criterio de referencia X_j^{ref} . La diferencia entre los dos valores se calcula de acuerdo con la ecuación (3) (Stevens-Navarro, Martinez-Morales et al., 2012):

$$r_{ij} = |x_{ij} - x_j^{ref}| \quad (3).$$

Con el objetivo de comparar las alternativas espectrales, se introducen los conceptos de *concordancia* y *discordancia*, que son medidas de satisfacción e insatisfacción del algoritmo cuando una alternativa es comparada con otra. La alternativa con el valor más alto de concordancia neta y el valor más bajo de discordancia neta será la preferida (Stevens-Navarro, Martinez-Morales et al., 2012).

Grey relational analysis

El objetivo de este algoritmo [GRA] es establecer las redes candidatas y seleccionar las que tengan más alta puntuación de acuerdo con unos parámetros definidos. Para lograr esto, se establecen relaciones de Grey entre elementos de dos series: la primera contiene las mejores cualidades, mientras que la otra contiene entidades comparativas. Acá es parte importante el coeficiente de Grey, que se usa para describir las relaciones entre las series calculado a partir del nivel de similitud y variabilidad. (Stevens-Navarro, Martinez-Morales et al., 2012; véase también Hernández et al., 2015b; Hernández, Giral y Santa, 2015; Hernández, Páez et al., 2015; Hübner, 2007; Ramírez Pérez y Ramos Ramos, 2010, 2013; Stevens-Navarro y Wong, 2006)

En GRA, primero se genera el vector de referencia X_0 , de la matriz X , a través de la escogencia de los valores mínimos, para los costos, y los valores máximos, para los criterios de beneficios. Después, la secuencia de datos debe ser normalizada para X de acuerdo con tres situaciones: más grande el mejor, más pequeño el mejor o nominal el mejor. Luego, se calcula el coeficiente relacional de Grey [según la ecuación (4)]. (Hernández, Páez et al., 2015)

$$\gamma(x_0(i), x_j(i)) = \frac{\Delta_{min} + \zeta\Delta_{max}}{\Delta_{0,j}(i) + \zeta\Delta_{max}} \quad (4),$$

donde

$$\begin{aligned}\Delta_{0,j} &= |x_0(i) - x_j(i)|, \\ \Delta_{min} &= \min_{j \in N} \left\{ \min_{i \in M} \left\{ |x_0(i) - x_j(i)| \right\} \right\}, \\ \Delta_{max} &= \max_{j \in N} \left\{ \max_{i \in M} \left\{ |x_0(i) - x_j(i)| \right\} \right\},\end{aligned}$$

donde el coeficiente ζ que pertenece $[0,1]$ compensa el efecto de Δ_{max} , que generalmente es 0,5.

Finalmente, se calcula el grado relacional de Grey para cada una de las diferentes series de datos, como lo describe la ecuación (5), donde $\Gamma(x_o, x_i)$ representa el grado relacional de Grey para las j -ésimas alternativas:

$$\Gamma(x_o, x_j) = \sum_{i=1}^M \omega_i \gamma(x_o(i), x_j(i)) \quad (5),$$

donde ω_i es el peso de la importancia de los i -ésimos criterios.

En Hernández, Páez et al. (2015) se utiliza GRA para seleccionar la SO en el enlace ascendente de la banda de frecuencia GSM, evaluando el nivel de bloqueos de *handoff* y comparando los resultados con otros dos algoritmos de SA.

TOPSIS

El desarrollo del algoritmo TOPSIS (*technique for order preference by similarity to ideal solution*) se basa en la determinación de dos componentes: la solución ideal del sistema y la solución que no puede ser aceptada en ninguna situación. Para lograrlo, es necesario comparar los resultados obtenidos para determinar qué solución es lo más cercano posible a la ideal y cuál es la más lejana (la cual no será aceptada). Dicha métrica se obtiene a partir de la distancia euclidiana entre los criterios y los pesos (Hernández et al., 2015a; Ramírez Pérez y Ramos Ramos, 2010).

El procedimiento del algoritmo TOPSIS está descrito en Hernández et al. (2015a) y Ramírez Pérez y Ramos Ramos (2010, 2013). Inicialmente, se construye la matriz de decisión X y se normaliza usando el método de raíz cuadrada, como se observa en la ecuación (6):

$$\tilde{X} = \begin{pmatrix} \tilde{x}_{11} & \cdots & \tilde{x}_{1M} \\ \vdots & \ddots & \vdots \\ \tilde{x}_{N1} & \cdots & \tilde{x}_{NM} \end{pmatrix} = \begin{pmatrix} \omega_1 \tilde{x}_{11} & \cdots & \omega_M \tilde{x}_{1M} \\ \vdots & \ddots & \vdots \\ \omega_1 \tilde{x}_{N1} & \cdots & \omega_M \tilde{x}_{NM} \end{pmatrix} \quad (6),$$

donde ω_i es el peso asignado al criterio i y la suma de estos debe ser 1.

Luego, se determina la solución ideal y la peor solución, como lo describen las ecuaciones (7) y (8):

$$A^+ = \left\{ \left(\max_{j \in X^+} \tilde{x}_{ij} \right), \left(\min_{j \in X^-} \tilde{x}_{ij} \right) \right\} = \{ \tilde{x}_1^+, \dots, \tilde{x}_M^+ \} \quad (7);$$

$$A^- = \left\{ \left(\min_{j \in X^+} \tilde{x}_{ij} \right), \left(\max_{j \in X^-} \tilde{x}_{ij} \right) \right\} = \{ \tilde{x}_1^-, \dots, \tilde{x}_M^- \} \quad (8),$$

donde $i = 1, \dots, N$, y X^+ y X^- son el conjunto de beneficios y costos, respectivamente.

Posteriormente, para cada alternativa, se calcula la distancia euclidiana D , como se observa en las ecuaciones (9) y (10):

$$D_i^+ = \sqrt{\sum_{j=1}^M (\tilde{x}_{ij} - \tilde{x}_j^+)^2} \quad i = 1, \dots, N \quad (9);$$

$$D_i^- = \sqrt{\sum_{j=1}^M (\tilde{x}_{ij} - \tilde{x}_j^-)^2} \quad i = 1, \dots, N \quad (10).$$

Finalmente, las alternativas son organizadas en orden descendente de acuerdo con el índice de preferencia dado por la ecuación (11):

$$C_i^+ = \frac{D_i^-}{D_i^+ + D_i^-}, \quad i = 1, \dots, N. \quad (11).$$

En Vásquez et al. (2015) se utiliza TOPSIS para seleccionar la mejor SO evaluando el nivel de interferencia por canal adyacente y el número promedio de *handoffs* realizados; los resultados son comparados con otro algoritmo y sus respectivas versiones al combinarlos con tres algoritmos de predicción basados en series de tiempo.

VIKOR

“El método VIKOR [*multi-criteria optimization and compromise solution*] asume que cada alternativa es evaluada de acuerdo con cada función de criterio, y la clasificación puede ser desarrollada a través de la comparación de las medidas que estén más cercanas a la alternativa ideal” (Hernández, Páez et al., 2015; véase también Tanino et al., 2003; Vásquez et al., 2015). VIKOR fue desarrollado para lograr la optimización de sistemas complejos con múltiples criterios, y por tanto es hábil para determinar el compromiso en una lista de *ranking*, aun en presencia de criterios en conflicto, lo que lo hace un algoritmo adecuado para la toma de decisiones en la SA (Gallardo-Medina et al., 2009).

El algoritmo VIKOR sigue los pasos descritos en Hernández et al. (2015b), Hernández, Páez et al. (2015), Ramírez Pérez y Ramos Ramos (2010) y Stevens-Navarro, Martinez-Morales et al. (2012).

Para cada parámetro $j = 1, 2, 3, \dots, N$, se determina el mejor y peor valor, dados por las ecuaciones (12) y (13):

$$F_j^+ = \left\{ \left(\max_{i \in M} x_{ij} | j \in N_b \right), \left(\min_{i \in M} x_{ij} | j \in N_c \right) \right\} \quad (12);$$

$$F_j^- = \left\{ \left(\min_{i \in M} x_{ij} | j \in N_b \right), \left(\max_{i \in M} x_{ij} | j \in N_c \right) \right\} \quad (13),$$

donde N_b , que pertenece a N , es el conjunto de parámetros de beneficios y N_c , que pertenece a N , es el conjunto de parámetros de costos.

Luego, se calculan los valores de S_i y R_i para $i = 1, 2, 3, \dots, M$, como lo describen las ecuaciones (14) y (15):

$$S_i = \sum_{j \in N} w_j \frac{(F_j^+ - x_{ij})}{(F_j^+ - F_j^-)} \quad (14);$$

$$R_i = \max_{i \in N} \left[w_j \frac{(F_j^+ - x_{ij})}{(F_j^+ - F_j^-)} \right] \quad (15),$$

donde w_j es la importancia del peso del parámetro j .

Posteriormente, se calculan los valores de Q_i para $i = 1, 2, 3, \dots, M$, dados por la ecuación (16):

$$Q_i = \gamma \left(\frac{S_i - S^+}{S^- - S^+} \right) + (1 - \gamma) \left(\frac{R_i - R^+}{R^- - R^+} \right) \quad (16),$$

dónde $S^+ = \min_{i \in M} S_i$, $S^- = \max_{i \in M} S_i$, $R^+ = \min_{i \in M} R_i$, $R^- = \max_{i \in M} R_i$, y $0 \leq \gamma \leq 1$.

Dados los valores de Q para todos los i pertenecientes a M , se clasifican de mayor a menor las SO candidatas. Finalmente, la SO seleccionada está dada por el Q óptimo, como lo describe la ecuación (17):

$$A_{\text{VIK}}^* = \arg \min_{i \in M} Q_i^* \quad (17).$$

En Hernández, Páez et al. (2015) se utiliza VIKOR para seleccionar la mejor SO en el enlace ascendente de la banda de frecuencia GSM, evaluando el nivel de bloqueos de *handoff* y comparando los resultados con otros dos algoritmos de SA.

Analytical hierarchical process

AHP se basa en comparaciones sobre la importancia entre los criterios de decisión escogidos para la selección de una alternativa, siendo esta importancia una medida relativa más que un valor absoluto (Saaty, 1990).

En la metodología de diseño del algoritmo AHP, el primer paso es definir el problema, descomponiéndolo a su vez en objetivo, criterios y alternativas: el objetivo es la decisión que se ha de tomar, que para el presente trabajo corresponde a la selección de la mejor SO; los criterios son los factores que afectan la preferencia de una alternativa, y las alternativas son todas las SO, de las cuales hay que escoger solo una. El segundo paso es la construcción de la jerarquía de acuerdo con la definición del problema, y el tercer paso es la realización de las matrices de juicios, las cuales corresponden a evaluaciones comparativas que definen el nivel de importancia relativa entre cada combinación posible de parejas de criterios —ecuación (18)—.

$$A = [a_{ij}]_{n \times n} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix} \quad (18),$$

donde $i = j = 1, 2, \dots, n$ corresponde al número de criterios.

En el cuarto paso se procede a calcular los pesos normalizados para cada criterio, como lo describe la ecuación (19) (Hernández et al., 2015a):

$$r = [r_1, r_2, \dots, r_n] \text{ con } r_i = \frac{v_i}{\sum_{j=1}^n v_j} \quad (19),$$

donde r es el vector de valores propios, r_1, r_2, \dots, r_n es el valor de los pesos de cada subcriterio, V_i es la media geométrica de la fila i y V_j es la media geométrica de la columna j .

Finalmente, en el quinto paso se evalúa la validez del algoritmo AHP a través del índice de consistencia, como se muestra en la ecuación (20) (Miranda, 2001). De acuerdo con Saaty (1990), si el índice de consistencia es menor que 0,1, el desarrollo del algoritmo es satisfactorio.

$$CI = \sqrt{\frac{\sum_{i=1}^n \sum_{j=1}^n (\ln a_{ij} - \ln \frac{v_i}{v_j})^2}{\frac{(n-1) \times (n-2)}{2}}} \quad (20),$$

donde CI es el índice de consistencia, n es el número de subcriterios y a_{ij} es el valor del elemento de la fila i y la columna j .

En Hernández et al. (2015a) se utiliza AHP para seleccionar la mejor SO en la banda de frecuencia GSM, calculando el desempeño del algoritmo con base en cinco métricas de evaluación (EM) y comparando los resultados con otros cinco algoritmos de SA.

Algoritmos inteligentes

La inteligencia artificial tiene como objetivo hacer que las máquinas realicen tareas de una manera similar a un experto. La máquina inteligente percibirá la toma de decisiones y, así, maximizará su propia utilidad (Woods, 1986). De esta forma, la máquina tendrá que prever los principales desafíos, como la deducción, el razonamiento y la representación de las problemáticas, para finalmente dar solución a los problemas como fuente de entradas principales de estudio (Abbas et al., 2015).


En relación con la CR, los principales retos para las subáreas de la inteligencia artificial son la detección de la frecuencia disponible de radio; la calidad del canal de comunicación; el reconocimiento, la predicción y la anticipación en la toma de decisiones, y, por último, pero no menos importante, la decisión sobre la asignación de recursos para el ajuste de errores de transmisión y recepción de datos (Abbas et al., 2015).

Lógica difusa

La lógica difusa está basada en la teoría de conjuntos difusos, que fue propuesta por Zadeh (1965). Un conjunto difuso es definido por una función de membresía que mapea elementos a grados de membresía dentro de un cierto intervalo, el cual usualmente es $[0,1]$: si el valor es cero, el elemento no pertenece al conjunto; si es uno, pertenece completamente al conjunto, y si es una cantidad intermedia, el elemento tiene cierto grado de pertenencia al conjunto (Patil y Kant, 2014). Los números difusos triangulares (TFN) son ampliamente usados como funciones de membresía debido a su eficiencia computacional.

Los TFN pueden ser denotados como (l,m,u) , donde los parámetros l , m y u representan el límite más bajo, el valor modal y el límite más alto, respectivamente, como se observa en la figura 10 y en la ecuación (21).

Figura 10. Número difuso triangular



Fuente: elaboración propia a partir de Cho y Lee (2013).

$$\mu_A(x) = \begin{cases} 0, & x < l, \\ (x-l)/(m-l), & l \leq x \leq m, \\ (u-x)/(u-m), & m < x \leq u, \\ 0, & x > u, \end{cases} \quad (21).$$

La lógica difusa es una herramienta particularmente apropiada para tomar decisiones en situaciones en las que las entradas disponibles son, en general, inciertas e imprecisas o cualitativamente interpretadas. Además, también puede transformar información cualitativa y heterogénea en valores de membresía homogéneos, los cuales pueden ser procesados a través de un conjunto de reglas de inferencia difusa apropiadas (Giupponi y Pérez-Neira, 2008).

La lógica difusa resulta ser una posición relativa desde el observador principal; sin embargo, las conclusiones de la técnica están respaldadas por métricas iniciales que describen el conjunto de valores admisibles de una muestra. De esta manera, la lógica difusa, aunque con una tasa de estudio aleatoria, permite obtener valores diferentes a los supuestos de *verdadero* o *falso* (Gavrilovska et al., 2013).

Asimismo, esta técnica proporciona al sistema razonamiento aproximado mediante conjuntos de reglas, y tiene la capacidad de obtener condiciones de incertidumbre mediante la predicción de consecuencias, además de que puede adaptarse a nuevas situaciones (Abbas et al., 2015; Dadios, 2012; Gavrilovska et al., 2013).

Diferentes investigaciones han aplicado la teoría de lógica difusa en la CR para resolver los problemas en la asignación del BW, estudiando de antemano la interferencia y la administración de la energía como métodos de evaluación en la correcta SA

(Abbas et al., 2015; Hernández, Salgado et al., 2015; Matinmikko et al., 2013). No obstante, diferentes estudios han detallado tópicos como la inferencia difusa centralizada, que asigna los BW correspondientes a la intensidad de tráfico y la prioridad del servicio. Así pues, esta última detalla cómo los SU tienen que presentar solicitudes de BW al administrador primario de la red (Abbas et al., 2015). Del mismo modo, el administrador analiza el tráfico desde la cola y verifica los retardos producidos por la demora en la transmisión de paquetes. En otras palabras, se determina la latencia para el acceso a SU (Abbas et al., 2015).

Algoritmos genéticos o evolutivos

Su principal campo de acción se encuentra inmerso en la optimización y búsqueda de soluciones y están inspirados en la evolución genética y la selección natural de las especies (Goldberg y Holland, 1988). Los algoritmos evolutivos hacen parte de las ciencias de la computación y su principal enfoque está determinado en la inteligencia artificial. Siguiendo la terminología de la teoría de la evolución, es común encontrar definiciones de los cromosomas y las funciones de aptitud como descriptores de un algoritmo genético: los cromosomas son representaciones abstractas de las soluciones candidatas, y la función de aptitud está estrechamente relacionada con el objetivo del algoritmo para los procesos de optimización (He et al., 2010).

La ventaja de utilizar algoritmos genéticos para solucionar el problema de optimización de la SA en CR es que pueden manejar restricciones y objetivos de forma arbitraria; por ejemplo, las soluciones ineficientes son simplemente descartadas por el algoritmo. En Del Ser et al. (2010) se utiliza la técnica de búsqueda de armonía para encontrar la asignación de canal óptima. El algoritmo genético construye un vector de asignación de canales (llamados *armonías*): inicialmente, se realizan combinaciones y mutaciones de forma inteligente, y posteriormente, en la evaluación, se almacenan las mejores armonías (Tragos et al., 2013).

Sistemas multiagente

Los MAS se consideran una entidad inteligente y consciente del entorno capaz de actuar hábilmente y de generar comunicación de forma independiente. Los MAS están relacionados con el ambiente, los objetivos, otros agentes y las diferentes relaciones entre estas entidades, por lo que son rápidos, confiables y flexibles (Abbas et al., 2015; Ferber, 1999; Wooldridge, 2009).

Trigui et al. (2012) introdujeron un concepto novedoso para direccionar el “espectro de transición” en CR, lo que les permite a los terminales cambiar a una banda espectral que ofrezca mejores condiciones mediante una negociación usando MAS. Por su parte, Mir et al. (2011) usaron MAS para compartir dinámicamente el

espectro en CR. De acuerdo con sus necesidades, los SU cooperan y se comunican con los PU para compartir el espectro.

Colonia artificial de abejas

La ABC está compuesta por tres grupos: “abejas empleadas”, “abejas exploradoras” y “abejas observadoras”. Su objetivo es determinar la ubicación de las mejores fuentes de alimento. Para esto, las abejas empleadas buscarán las fuentes de alimento, y si la cantidad de néctar de la nueva fuente es mayor que la de una anterior, aquellas memorizarán la nueva posición y se olvidarán de la anterior. Así, las abejas empleadas son iguales al número de fuentes de alimento; las abejas observadoras comparten la información de las fuentes de alimento, y las abejas exploradoras buscan nuevas fuentes de alimento al abandonar la propia (Ahmed et al., 2016; Tragos et al., 2013).

Según Cheng y Jiang (2011), el problema de SA se resuelve utilizando el algoritmo ABC: la ubicación de una abeja o espectador representa una posible asignación de canal, y la cantidad de néctar es la utilidad que se maximiza.

Técnicas de aprendizaje

El aprendizaje autónomo tiene por objetivo principal el autoaprendizaje computacional, en el que las técnicas de análisis pueden ser programadas de forma autónoma a través de la inducción del conocimiento, donde la información objeto de estudio está disponible a partir de grandes conjuntos de datos dispuestos a ser analizados para la consecución objetiva de resultados (Abbas et al., 2015).

Aprendizaje no supervisado

El aprendizaje no supervisado puede ser adecuado para las CR que operen en entornos desconocidos de radiofrecuencia (Jayaweera y Christodoulou, 2011). Para este caso, los algoritmos de aprendizaje sin supervisión autónoma permiten la exploración de las características del entorno y realizan acciones por sí mismos, sin tener ningún conocimiento previo (Jayaweera y Christodoulou, 2011). Sin embargo, si la CR tiene información previa sobre el medio ambiente, puede aprovecharla mediante el uso de técnicas de aprendizaje supervisado (Bkassiny et al., 2013).

Aprendizaje por refuerzo

El aprendizaje por refuerzo es una técnica que permite a un agente modificar su comportamiento mediante la interacción con su entorno (Sutton y Barto, 1998). Este tipo de aprendizaje puede ser utilizado por los agentes para aprender de forma autónoma y sin supervisión. En este caso, la única fuente de conocimiento es la retroalimentación que un agente recibe de su entorno después de ejecutar una acción. Dos características principales caracterizan el aprendizaje por refuerzo: 1) ensayo y error, y 2) recompensa retardada. En cuanto al ensayo y error, se supone que un agente no tiene

ningún conocimiento previo sobre el medio ambiente y ejecuta acciones ciegamente con el fin de explorar el entorno, y la recompensa retardada, por su parte, es la señal de realimentación que un agente recibe del entorno después de la ejecución de cada acción (Bkassiny et al., 2013).

El aprendizaje por refuerzo ha sido incorporado en la CR y específicamente en las telecomunicaciones móviles. En Abbas et al. (2015) se muestra la capacidad de implementar un sistema de errores y recompensas en función de cada decisión, lo que optimiza el desempeño en la toma de decisiones para la administración del espectro electromagnético.

Teoría de juegos

La teoría de juegos es una herramienta matemática que pretende modelar el comportamiento de entidades racionales en un entorno conflictivo (Fudenberg y Tirole, 1991). En las comunicaciones inalámbricas, la teoría de juegos se ha aplicado a las redes de comunicación de datos para modelar y analizar el encaminamiento y la asignación de recursos en entornos competitivos (Bkassiny et al., 2013).

Esta teoría es utilizada como una herramienta en la toma de decisiones donde varios jugadores se enfrentan a una serie de situaciones en las que deben tomar medidas que en la mayoría de los casos pueden afectar los intereses de los otros (Abbas et al., 2015). Una ventaja clave de la aplicación de soluciones de teoría de juegos a los protocolos de CR es la reducción de la complejidad de los algoritmos de adaptación en grandes redes cognitivas (Bkassiny et al., 2013). En la literatura actual, Ji y Liu (2007), Nisan et al. (2007) y Zhao et al. (2009) han realizado estudios sobre la aplicación de la teoría de juegos en la CR.

Aprendizaje supervisado

El aprendizaje supervisado se usa cuando los datos de entrenamiento están etiquetados, es decir, cuando se conoce información *a priori* acerca del ambiente. Algoritmos de entrenamiento, como los árboles de decisión, las redes neuronales, las máquinas de soporte vectorial y el razonamiento basado en casos, funcionan bien para esta situación, aunque sus fortalezas, limitaciones, desafíos y aplicaciones referentes a la CR difieren (Abbas et al., 2015).

Redes neuronales

Las redes neuronales se asemejan al cerebro en dos aspectos (Haykin, 1998): 1) el conocimiento es adquirido por la red de su entorno a través de un proceso de aprendizaje, y 2) las fuerzas de conexión interneuronas, conocidas como *pesos sinápticos*, se utilizan para almacenar el conocimiento adquirido. Dos de las principales capacidades y ventajas de las redes neuronales es que incluyen el modelado de

comportamientos no lineales y que cuentan con capacidad de adaptación ante cambios pequeños, y su principal desventaja es la necesidad de realizar un entrenamiento bajo diferentes condiciones del entorno (Bkassiny et al., 2013).

Taj y Akil (2011) presentan una metodología para predecir el comportamiento del espectro. En su investigación, la actividad del PU es modelada a través de una serie de tiempo caótica multivariable que se convierte en una entrada a la red neuronal, y esta predice la evolución de la serie de tiempo para decidir si el SU puede ocupar una SO determinada (Bkassiny et al., 2013).

Máquina de soporte vectorial

Las SVM son el conjunto de algoritmos que tienen la capacidad de aprender bajo la supervisión de un agente de *software*. Su principal modo de operación se da en función de la regresión y la clasificación en el aprendizaje. Esta técnica es utilizada para llegar a márgenes de clasificación en un conjunto de datos, por lo que su principal objetivo consiste en establecer un modelo de predicción en el que una entrada incierta pueda ser identificada en una categoría u otra (Abbas et al., 2015; Bkassiny et al., 2013; Dadios, 2012; Del Ser et al., 2010; Ferber, 1999; Fudenberg y Tirole, 1991; Goldberg y Holland, 1988; Han et al., 2012; He et al., 2010; Ji y Liu, 2007; Matinmikko et al., 2013; Mir et al., 2011; Nisan et al., 2007; Sutton y Barto, 1998; Taj y Akil, 2011; Trigui et al., 2012; Wooldridge, 2009; Zhao et al., 2009).

En la literatura actual, Petrova et al. (2010) y Xu y Lu (2006) han realizado estudios sobre la aplicación de las SVM en la CR.

Funciones de decisión

En las redes heterogéneas con facilidades de acceso ubicuo, los procesos de decisión y selección se hacen más complejos debido a que las diferentes tecnologías de acceso, por lo general, ofrecen diferentes características. De acuerdo con esto, la SA llega a ser un problema con múltiples parámetros que incluyen complejos *trade-offs* entre criterios contradictorios. En estos casos resulta útil la aplicación de funciones de beneficio o costo (Ahmed et al., 2014).

Función de beneficio o utilidad

La función de utilidad tiene por objetivo maximizar la satisfacción del usuario de acuerdo con ciertos parámetros y restricciones. En la SA y la gestión de decisiones, la utilidad mide el nivel de satisfacción del usuario en cuanto a un conjunto de características de una red inalámbrica, incluyendo los parámetros de recursos asignados (Ahmed et al., 2014). Ormond et al. (2006), por ejemplo, examinan el nivel de satisfacción del usuario mediante el empleo de una función de utilidad para aplicaciones de BE.

Función de costos

La función de costos, a diferencia de la función de utilidad, busca minimizar el costo de ciertos parámetros teniendo en cuenta las restricciones del caso. En una SO, el costo total se calcula mediante la suma de los costos de los parámetros de interés, como la QoS, el BW, el retardo y la AP, entre otros (Ahmed et al., 2014). En Wei et al. (2008) se presenta una aplicación de la función de costo.

Algoritmos estadísticos

Existe otro tipo de técnicas que también se han utilizado para la SA en CRN y que están basadas fundamentalmente en conceptos de estadística y probabilidad: las redes bayesianas, las cadenas de Markov y los árboles de decisión.

Redes bayesianas

Las redes bayesianas son “modelos probabilísticos gráficos” que dependen de la interacción de diferentes nodos para generar aprendizaje en cada uno de estos; el enfoque bayesiano es una técnica de aprendizaje probabilístico que provee inferencias exactas y estima modelos de probabilidad completa en los que el conocimiento *a priori* o los resultados son usados para construir un modelo actualizado (Bolstad, 2007; Yonghui, 2010).

Por ejemplo, Jiang et al. (2014) usan un “enfoque cooperativo” para estimar el estado de un canal, por medio del aprendizaje bayesiano, para resolver el problema de la detección multicanal.

Cadenas de Markov

Los modelos de Markov son usados para modelar procesos aleatorios que cambian de un estado a otro en el tiempo y en los que el estado futuro depende del estado presente; dichos estados son visibles para el observador, en contraste con los modelos ocultos de Markov (HMM), en los que los estados no son visibles (Fraser, 2008). Estas cadenas generan “secuencias de observaciones” entre transiciones de estado, ya sea en el tiempo o en el espacio, con probabilidades fijas. El estado actual depende de los eventos previos, y sus sucesivas estructuras determinan el éxito del proceso. A la cadena de Markov puede asignársele un solo paso o puede ser extendida a las probabilidades asociadas a cada una de las transiciones dependientes en múltiples eventos que la preceden (Abbas et al., 2015).

Yifei et al. (2013) usaron la toma de decisiones de Markov para el DSA en CRN. Además, usaron el modelo HMM en un canal inalámbrico y predijeron el estado del canal; las decisiones estuvieron basadas en la sensibilidad espectral, la selección de canal, la modulación, los esquemas de codificación y la potencia transmitida. Por su parte, Pham et al. (2014) utilizaron HMM en el SH para que el SU estudiara el

comportamiento del PU y pudiera predecir su futuro comportamiento para asegurar la transmisión.

Árboles de decisión

Los árboles de decisión son un modelo que predice el valor de una “clase objetivo” basada en una diversidad de variables de entrada. En un árbol de decisión, cada nodo tiene un “criterio”, cada “rama” representa el “resultado de una prueba” y cada “hoja” contiene información de la “etiqueta de clase” (Abbas et al., 2015; Ahmed et al., 2014; Bkassiny et al., 2013; Bolstad, 2007; Cheng y Jiang, 2011; Del Ser et al., 2010; Ferber, 1999; Fraser, 2008; Fudenberg y Tirole, 1991; Gavrilovska et al., 2013; Goldberg y Holland, 1988; Han et al., 2012; Haykin, 1998; He et al., 2010; Ji y Liu, 2007; Jiang et al., 2014; Matinmikko et al., 2013; Mir et al., 2011; Nisan et al., 2007; Ormond et al., 2006; Petrova et al., 2010; Pham et al., 2014; Safavian y Landgrebe, 1991; Sutton y Barto, 1998; Taj y Akil, 2011; Trigui et al., 2012; Wooldridge, 2009; Xu y Lu, 2006; Yifei et al., 2013; Yonghui, 2010; Zhao et al., 2009).

Análisis comparativo de las técnicas y los algoritmos de *handoff*

La tabla 1 resume el análisis comparativo de las diferentes técnicas para la SA en CRN, en términos de fortalezas y limitaciones.

Tabla 1. Análisis comparativo de las técnicas de asignación espectral

Algoritmo	Fortalezas	Limitaciones
MCDM	Simplicidad, fácil implementación y respuesta rápida.	No hay una metodología analítica para estudiar su convergencia.
Lógica difusa	Decisiones rápidas basadas en reglas predefinidas y técnicas de aprendizaje que pueden mejorar la calidad de las decisiones.	Funcionalidad limitada, ya que las reglas son predefinidas; necesita un gran número de reglas para considerar todos los parámetros.
Algoritmos genéticos	Optimización multiobjetivo y configuración dinámica con los cambios del entorno.	Requieren conocimiento previo del sistema; el proceso para encontrar una solución óptima es lento.
MAS	Adecuado para problemas con múltiples jugadores; aprendizaje y cooperación.	La complejidad y el costo computacional pueden llegar a ser altos.
ABC	Búsqueda de soluciones en paralelo.	Requiere conocimiento previo del sistema y una función de aptitud.
Aprendizaje por refuerzo	Aprendizaje autónomo usando retroalimentación y autoadaptación progresiva en tiempo real.	Necesita reglas de derivación para lograr exactitud.

Algoritmo	Fortalezas	Limitaciones
Teoría de juegos	Reduce la complejidad de la adaptación, brinda soluciones por medio de múltiples agentes y cuenta con enfoque cooperativo y no cooperativo.	Requiere conocimiento previo de diferentes parámetros del sistema y que los datos de entrenamiento estén etiquetados.
Redes neuronales	Tienen habilidad para adaptarse a los cambios menores, son excelentes para clasificación y pueden identificar nuevos patrones.	Dependiendo del tamaño de la red, el entrenamiento puede ser lento; tienen poca capacidad para generalizar; pueden sufrir de sobreentrenamiento, y requieren datos previos.
SVM	Capacidad de generalizar; robustez contra el ruido de entrada y otros casos, y, en comparación con las redes neuronales, mejor desempeño con poco entrenamiento.	Requiere que los datos de entrenamiento estén etiquetados; hay que tener previo conocimiento del funcionamiento del sistema, y se vuelve complejo a medida que el problema es más grande.
Funciones de utilidad y costo	Permiten encontrar óptimos con múltiples parámetros y restricciones.	Requieren que todos los parámetros estén modelados con una función analítica.
Redes bayesianas	Se basan en modelos probabilísticos.	Requieren conocimiento previo del sistema y presentan complejidad computacional.
Modelos de Markov	Se basan en modelos estadísticos, son fácilmente escalables y pueden predecir con base en la experiencia.	Requieren conocimiento previo del sistema y presentan complejidad computacional.
Árboles de decisión	Simplicidad y toma de decisiones mediante las configuraciones de sus ramas.	Requieren conocimiento previo del sistema, pueden sufrir sobreentrenamiento y requieren que los datos de entrenamiento estén etiquetados.

Fuente: elaboración propia a partir de Bkassiny et al. (2013), He et al. (2010), Tragos et al. (2013) y Yifei et al. (2013).

Desafíos de investigación en la asignación espectral

Existen varios temas de investigación abiertos que necesitan ser estudiados para el desarrollo de la SA; algunos de ellos se mencionan a continuación (Akyildiz et al., 2006).

Modelo de decisión multivariado

La SNR no es suficiente para caracterizar las bandas espectrales en las CRN, pues muchos otros parámetros de caracterización del espectro afectan la calidad. Por lo

tanto, la manera de combinar estos parámetros de caracterización del espectro para el modelo de decisión del espectro sigue siendo una cuestión abierta.

Algoritmos adaptativos

Para desarrollar soluciones eficientes en la SA, es necesario desarrollar algoritmos que logren adaptarse a diversas condiciones y escenarios, con el objetivo de satisfacer los requisitos de un entorno altamente dinámico. Todos los algoritmos hasta ahora vistos se centran en un escenario y una red estáticos y en tratar de encontrar una solución óptima de acuerdo con algunos criterios (Tragos et al., 2013).

Selección multicanal

En las CRN se pueden utilizar simultáneamente múltiples bandas del espectro para la transmisión, y estas no tienen que ser contiguas para que un SU pueda enviar paquetes. Esta transmisión sobre múltiples bandas muestra menos degradación de calidad durante el SH que la transmisión convencional, sobre una sola banda del espectro (Akyildiz y Li, 2006). Por ejemplo, si un PU aparece en una banda del espectro en particular, el SU tiene que desalojar solo esa banda y puede mantener la comunicación en el resto de las bandas de espectro, por lo cual la degradación de la QoS puede ser mitigada (Dadallage et al., 2016).

Adicionalmente, la transmisión en múltiples bandas del espectro permite un menor consumo de energía en cada una de estas, y, como resultado, se consigue tener menos interferencias con los PU en comparación con la transmisión en una única banda del espectro (Akyildiz y Li, 2006). Por estas razones, el esquema de gestión del espectro debe tener la capacidad de toma de decisión para múltiples bandas. Sin embargo, la forma de determinar el número de bandas del espectro y cómo seleccionar el conjunto de bandas apropiadas siguen siendo temas de investigación abiertos en CRN.

Selección cooperativa del espectro

El enfoque cooperativo tiene más ventajas que el enfoque no cooperativo. En la detección de espectro cooperativa, el SU vecino comparte su información de detección con el objetivo de aprovechar la diversidad espacial. Un desafío en la selección de espectro cooperativa es cómo combinar la información de los usuarios cooperativos mientras se realiza la transmisión (Masonta et al., 2013).

Selección de espectro en redes heterogéneas

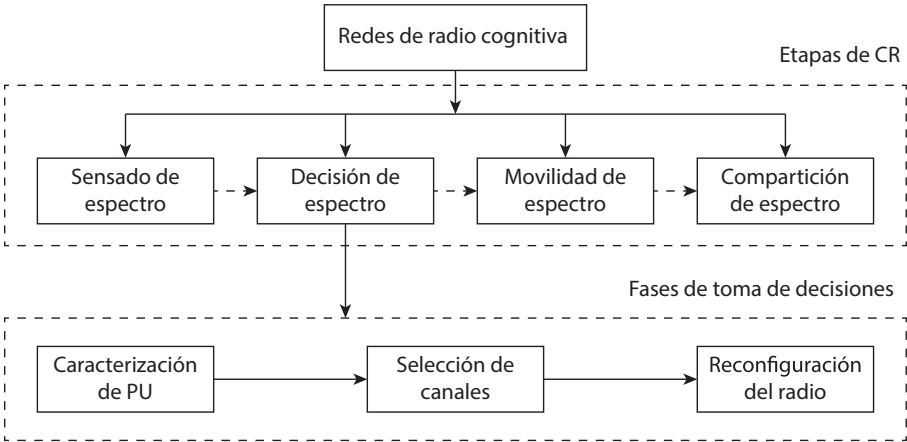
En una determinada CRN puede haber requerimientos de QoS heterogéneos y el espectro disponible puede presentar fluctuaciones y cualidades variables. En las redes de tráfico heterogéneas, un desafío consiste en seleccionar las bandas de frecuencia apropiadas para satisfacer los requerimientos de QoS de cada SU (Masonta et al., 2013).

Caracterización del arribo de los usuarios primarios

Avances recientes en el área de las comunicaciones inalámbricas, como el DSA, prometen la generación de nuevas metodologías que permitirán resolver algunos de los principales problemas a los que se enfrentan hoy en día las tecnologías de acceso inalámbrico (figura 11). Uno de estos avances tiene que ver con la asignación de la porción del espectro radioeléctrico útil (licenciado y no licenciado), que facilita la conexión de dispositivos con baja probabilidad de errores. En la actualidad, la distribución de ese rango de frecuencias es controlada por las entidades gubernamentales de cada país, donde a cada operador de telecomunicaciones se le asigna de manera individual y fija un rango de frecuencias en forma de licencias renovables.

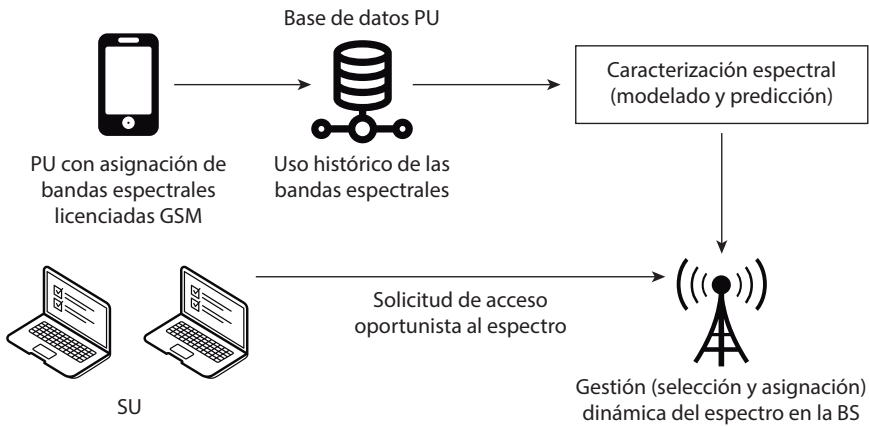
La BS de la CRN (figura 12) puede decidir sobre el mejor o los mejores canales para los SU, teniendo en cuenta la actividad del PU. En este contexto, el éxito en la selección de canales dependerá de qué tan confiable es el algoritmo de pronóstico para detectar la presencia/ausencia del usuario licenciado; si el porcentaje de predicción es alto, el funcionamiento del sistema será óptimo, ya que la probabilidad de asignar espectro erróneamente será muy baja y evitará colisiones entre el PU y los SU; por el contrario, si la estimación no es acertada, el sistema no funcionará adecuadamente y la cantidad de interferencias producidas volverá inviable la implementación de las redes inalámbricas cognitivas.

Figura 11. Etapas que componen las redes de radio cognitiva



Fuente: elaboración propia.

Figura 12. Contexto de la caracterización en la etapa de decisión espectral en redes de radio cognitiva



Fuente: elaboración propia.

Dar una solución adecuada al problema de caracterización implica la posibilidad de aprovechar las habilidades de aprendizaje autónomo de la inteligencia artificial; en este sentido, la pregunta que se plantea es: ¿la implementación del modelo de aprendizaje LSTM (*long short-term memory*) como predictor permite mejorar el porcentaje de acierto para detectar la presencia o ausencia de PU en bandas espectrales?

Las habilidades de aprendizaje —mediante la inclusión de conexiones *peephole* (Graves, 2012)—, de almacenamiento de patrones durante el entrenamiento de la red y de acceso a la información por largos periodos de tiempo en las celdas de memoria de LSTM pueden ser aplicadas al comportamiento caótico de señales PU para estimar más acertadamente su patrón de aparición en las bandas espectrales asignadas. Es claro que, a pesar de la existencia de varias propuestas para la modelización de la actividad del PU, es importante seguir buscando la forma de minimizar el porcentaje de error en esta predicción, pues esto redundará, a su vez, en la optimización de la fase de toma de decisiones espectrales en CR; allí se centra el presente capítulo de investigación.

Caracterización del usuario primario con *long short-term memory*

Realizar predicciones con un alto grado de precisión es bastante beneficioso para la planificación y control en muchos campos de investigación y desarrollo, pero dicho grado de exactitud en las estimaciones trae consigo un alto nivel de dificultad (Salgado, 2014); sin embargo, existen técnicas de predicción prometedoras y aplicables a CR, basadas en inteligencia artificial, con capacidad para proporcionar conciencia, razonamiento y aprendizaje adicional (He et al., 2010), características capaces de interactuar entre sí y que, por tanto, benefician la capacidad de autonomía de las redes


de radio cognitiva y elevan su rendimiento con un bajo nivel de dificultad y adecuado a las necesidades de aprendizaje autónomo de CR, como es el caso de LSTM.

La estimación futura del estado del canal en las bandas GSM y Wi-Fi (desde la perspectiva del PU) se abordó para este caso específico como un problema de predicción de series binarias, a partir de la conversión de los niveles de potencia (dBm) —capturados y entregados por el analizador espectral— a valores discretos y utilizando un sistema neuronal recurrente basado en *deep learning*. Inicialmente, se define el concepto teórico de LSTM, se describe la forma como se modela la señal PU de entrada al sistema y se analiza la estructura en capas de la red LSTM, y posteriormente se construye el modelo matemático que explica el sistema LSTM y se describe la interacción existente entre las neuronas de entrada, las celdas de memoria y las neuronas de salida durante el proceso de entrenamiento o aprendizaje.

LSTM

Las redes neuronales artificiales tradicionales no poseen la capacidad de almacenar información, para lo cual es necesario modificar su topología creando estructuras recurrentes que retroalimentan la neurona y permiten el almacenamiento de información; a estas estructuras se las conoce como *neuronas recurrentes*. La unión de un conjunto de estas neuronas es denominada *red neuronal recurrente* (RNN) y permite preservar estados subsecuentes entre diferentes intervalos de tiempo cuyos parámetros son compartidos entre las múltiples partes del modelo, lo que permite una mejor generalización (Veeriah et al., 2015). Uno de los problemas de las RNN consiste en el *long-term dependency*, que plantea la necesidad de no siempre estudiar todo un histórico para desempeñar una tarea actual, lo que implica que estas redes neuronales solo almacenan la información aprendida en el pasado y no están en la capacidad de almacenar nueva información a corto plazo. Las LSTM pueden ser explícitamente diseñadas para evitar el problema de *long-term dependency*, es decir, para que recuerden la información por largos periodos de tiempo, pero también para que aprendan nueva información en el presente. Los bloques LSTM contienen celdas de memoria que permiten recordar un valor por una arbitraria longitud de tiempo y usarlo cuando sea necesario; además, tienen una capa de olvido que puede borrar el contenido de la memoria cuando no es útil. Todos los componentes son construidos para funciones diferenciables y entrenadas durante el proceso *backpropagation* (Wang et al., 2015). La estructura de una LSTM puede ser representada como se muestra en la figura 13, donde la celda de memoria es simbolizada por la letra *C*; la capa de olvido, por la letra *o*; la capa de entrada, por la letra *e*, y la capa de salida, por la letra *s*.

Figura 13. Representación gráfica de las redes neuronales tipo *long short-term memory*



Fuente: Yao et al. (2015).

Modelado de la señal de entrada y las capas del sistema LSTM

La señal de entrada discreta representa la presencia (1) o ausencia (0) de un PU dentro de la banda espectral durante un tiempo T , de acuerdo con la ecuación (22), y, a partir de dicha secuencia binaria, el predictor está entrenado para pronosticar el estado del canal no solo en la siguiente ranura de tiempo, sino en posteriores instantes, según el historial de comportamiento del PU en el canal.

$$X_0^T = [x_0, x_1, x_2, x_3, \dots, x_T] \quad (22),$$

donde (x_0^T) es la señal de entrada discretizada.

Determinar el número exacto de neuronas para la solución del problema es particularmente difícil. Una red neuronal muy pequeña no puede aprender a solucionar el problema de forma correcta, pero una red muy grande generará un sobreajuste

(es decir, el problema se particulariza, mas no se generaliza) (Kwok y Yeung, 1997); además, se debe considerar que a mayor número de capas y neuronas, el tiempo de entrenamiento se hace mayor y se utiliza una mayor cantidad de recursos. En este caso particular, ya que se ajusta al problema en cuestión, se utilizó la técnica de optimización numérica, basada en la regla de la pirámide geométrica, útil cuando el número de neuronas de la capa de entrada es mayor que el de la capa de salida (Masters, 1993). Debido a que se debe dividir el número de neuronas de la capa de entrada n veces por una potencia de 2 hasta que se obtenga 1, se llega a la ecuación (23):

$$1 = \frac{Co}{2^n} \Leftrightarrow n = \lceil \log_2(Co) \rceil \quad (23),$$

donde Co corresponde al número de neuronas de la capa de entrada y n es al número de capas existentes.

De la ecuación (23) se puede intuir que el número de capas crece de forma controlada a medida que aumenta la cantidad de neuronas en la entrada. En razón a que en el diseño se optó por el desarrollo de una aplicación de *software* dinámica (cuya red neuronal LSTM es variable y dependiente de la secuencia de entrada), el número total de neuronas (N) que componen una topología de red se obtiene de la ecuación (24):

$$N = \sum_{i=0}^{Co} \left[\frac{Co}{2^i} \right] \quad (24).$$

Aproximando la serie anterior, se llega a la ecuación (25):

$$N \approx Co \left(2 - 2^{-Co} \right) \quad (25).$$

Tomando el Co de la ecuación (25) como un número muy grande, se puede suponer que el número total de neuronas tiende a:

$$\lim_{Co \rightarrow \infty} Co \left(2 - 2^{-Co} \right) = 2Co = \infty \quad (26).$$

La ecuación (26) indica que, a medida que aumenta el número de neuronas en la capa de entrada, el número total de neuronas corresponde aproximadamente al doble.

Modelo de funcionamiento del sistema LSTM

El modelo LSTM puede considerarse como un aproximador diferenciable de funciones que usualmente se entrena con el gradiente descendente (Graves, 2012), y aunque

originalmente se empleó una forma truncada del *backpropagation through time* (BPTT) para aproximar el gradiente del error (Hochreiter y Schmidhuber, 1997), en la investigación se hizo uso del cálculo con BPTT sin truncamiento, a partir de lo planteado por Graves (Graves y Schmidhuber, 2005). El funcionamiento de la red neuronal LSTM se describe en las ecuaciones (27)-(52), que hacen uso de las notaciones establecidas en la tabla 2, las cuales son congruentes con Graves (2012).

Tabla 2. Notaciones para el desarrollo del modelo matemático

Concepto	Bloque de memoria	Input gate	Forget gate	Output gate	Celda de memoria
Subíndice	i	l	\emptyset	w	c
Entrada	x_i	a_l^t	a_{\emptyset}^t	a_w^t	a_c^t, s_c^t
Salida	b_i	b_l^t	b_{\emptyset}^t	b_w^t	$b_c^t = b_w^t (s_c^t)$
Número de unidades	I	No aplica	No aplica	No aplica	C
Función de activación	No aplica	f sigmoide	f sigmoide	f sigmoide	f (in-cell) h (sal-cell)

Fuente: elaboración propia.

Ecuaciones forward pass

Para las tres compuertas de la celda (entrada, olvido y salida), las funciones de propagación a_l^t , a_{\emptyset}^t y a_w^t (Graves, 2012) no solo consideran la suma ponderada de las entradas actuales, sino también las salidas en el tiempo inmediatamente anterior de los bloques en la capa oculta y de los estados de las otras celdas del mismo bloque (salvo en la compuerta de salida, porque ahí se requiere del estado actual de las celdas). En este sentido, las ecuaciones (27)-(32) (Graves, 2012) resultan del análisis del bloque LSTM (figura 14) para cada una de las compuertas y la celda de memoria que conforman el modelo. Se debe tener en cuenta, para la interpretación de las ecuaciones, que w_{ij} hace referencia al peso de la conexión desde la unidad i hasta la unidad j ; que la secuencia de entrada a la red LSTM para la unidad j en el tiempo t se representa como a_j^t ; que la activación de la unidad j en el tiempo t se indica como b_j^t ; que el subíndice c identifica las celdas de memoria; que los pesos de las celdas c para cada una de las compuertas de entrada, olvido y salida se denotan como w_{cl} , $w_{c\emptyset}$ y w_{cw} ; que s_c^t es el estado de la celda c en el tiempo t ; que f es la función de activación de las compuertas, y que g y h son las funciones de activación de las celdas de entrada y salida, respectivamente.

Input gate:

$$a_l^t = \sum_{i=1}^L w_{il}^t x_i^t + \sum_{h=1}^H w_{hl}^t b_h^{t-1} + \sum_{c=1}^c w_{cl}^t s_c^{t-1} + \theta_l \quad (27),$$

donde a_l^t es la función de propagación de la compuerta de entrada (l) en el tiempo t , w_{il}^t es el peso de la conexión de la unidad i a la unidad l en el tiempo t , x_i^t es el vector de entrada i para el modulo LSTM en el tiempo t , w_{hl}^t es el *peephole weight* para la función de activación h en la compuerta de entrada l , b_h^{t-1} corresponde a la salida de la celda h en el tiempo $t-1$, w_{cl}^t es el *peephole weight* de la celda c para la compuerta de entrada, s_c^{t-1} es el estado de la celda c en el tiempo $t-1$ y θ_l es el sesgo (bias).

$$b_l^t = f(a_l^t) \quad (28),$$

donde b_l^t representa el módulo de activación (función sigmoide) para a_l^t .

Forget gate:

$$a_{\emptyset}^t = \sum_{i=1}^L w_{i\emptyset}^t x_i^t + \sum_{h=1}^H w_{h\emptyset}^t b_h^{t-1} + \sum_{c=1}^c w_{c\emptyset}^t s_c^{t-1} + \theta_{\emptyset} \quad (29),$$

donde a_{ϕ}^t es la función de propagación de la compuerta de olvido (ϕ) en el tiempo t .

$$b_{\phi}^t = f(a_{\phi}^t) \quad (30),$$

donde b_{ϕ}^t es la función de activación de a_{ϕ}^t en el tiempo t (asúmase que $\Phi = \phi$).¹

Output gate:

$$a_w^t = \sum_{i=1}^L w_{iw}^t x_i^t + \sum_{h=1}^H w_{hw}^t b_h^{t-1} + \sum_{c=1}^c w_{cw}^t s_c^{t-1} + \theta_w \quad (31);$$

$$b_w^t = f(a_w^t) \quad (32),$$


donde a_w^t es la función de propagación de la compuerta de salida (w) en el tiempo t , y b_w^t es la función de activación de la compuerta de salida a_w^t en el tiempo t .

Para describir el comportamiento de la celda, se deben tener en cuenta dos elementos: el primero es la función de propagación a_c^t , que depende no solo de las entradas actuales, sino de las salidas en el tiempo inmediatamente anterior de los demás

¹ La definición de las variables y sus respectivos subíndices se puede obtener de manera similar a la descripción hecha para la ecuación (27), tomando como referencia la tabla 2 y las consideraciones previas de este ítem.

bloques en la capa oculta, y el segundo es el estado de la neurona s_c^t , que indica si esta está conservando la información u olvidándola y que depende de la salida de la *forget gate* y de la *input gate*.

Figura 14. Arquitectura LSTM utilizada para la caracterización de PU



Fuente: elaboración propia a partir de Palangi et al. (2016).

La salida de la neurona b_c^t indicará si se generó nuevo aprendizaje o si se conserva la información almacenada. Teniendo claro lo anterior, a partir de lo mostrado en la figura 14, se concluye que el estado y la salida de la celda están dados por las ecuaciones (33)-(35) (Graves, 2012):

Estado de la neurona:

$$a_c^t = \sum_{i=1}^L w_{ic}^t x_i^t + \sum_{h=1}^H w_{hc}^t b_h^{t-1} \quad (33),$$

donde a_c^t es el vector de entrada para la celda LSTM c en el tiempo t , L es el número de unidades del bloque de memoria y H es el número de celdas en las capas ocultas de la red.

$$s_c^t = b_o^t s_c^{t-1} + b_l^t g(a_c^t) \quad (34),$$

donde g es la respuesta a la salida de la función *tangh*.

Salida de la neurona:

$$b'_c = b'_w h(s'_c) \quad (35),$$

donde h es la función de activación para la salida de la celda de memoria.

Ecuaciones backward pass

Para obtener las ecuaciones *backward pass*, se hace uso del método BPTT (Graves, 2012), que implica la utilización de la regla de la cadena para calcular las derivadas de los errores a la salida de los componentes de un bloque LSTM. Definiendo las salidas *input gate*, *output gate* y *forget gate* como δ'_j , estas pueden ser representadas como se describe en la ecuación (36):

$$\delta'_j = \frac{\partial E}{\partial a'_i}, j \in \{l, \emptyset, w\} \quad (36),$$

donde δ'_j , en este caso, hace referencia a la variación del error E en función del estado del bloque de memoria i en el tiempo t (a'_i).

Además, definiendo la salida de la celda (ϵ'_c) y el estado de la celda (s'_c), se tienen las ecuaciones (37) y (38):

$$\epsilon'_c = \frac{\partial E}{\partial b'_c} \quad (37),$$

donde b'_c es la salida de la celda de memoria en el tiempo $t=\xi$.

$$\epsilon'_s = \frac{\partial E}{\partial s'_c} \quad (38).$$

Definiendo E —en las ecuaciones (37) y (38)— como la función de pérdida (error) y partiendo del hecho de que se desea establecer cómo varía el error al hacer modificaciones en los pesos, a partir de la regla de la cadena —ecuación (39)— se tiene:

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial a_i} \frac{\partial a_j}{\partial w_{ij}} = b_i \frac{\partial E}{\partial a_i} \quad (39),$$

donde b_i es la salida del bloque de memoria.

De la ecuación (39) es claro que el objetivo es calcular $\frac{\partial E}{\partial a_j}$, pero, teniendo en cuenta que para el caso de LSTM existen cuatro tipos de a , —la *output gate* ($\frac{\partial E}{\partial a_o}$), las *cells* ($\frac{\partial E}{\partial a_c}$), la *forget gate* ($\frac{\partial E}{\partial a_f}$) y la *input gate* ($\frac{\partial E}{\partial a_i}$)—, estas se pueden definir como se muestra en las ecuaciones (40)-(43) (Graves, 2012):

$$\frac{\partial E}{\partial a_w^t} = \sum_{c=1}^c \frac{\partial E}{\partial b_c^t} \frac{\partial b_c^t}{\partial b_w^t} \frac{\partial b_w^t}{\partial a_w^t} = \frac{\partial b_w^t}{\partial a_w^t} \sum_{c=1}^c \frac{\partial E}{\partial b_c^t} \frac{\partial b_c^t}{\partial b_w^t} \quad (40),$$

donde $\frac{\partial E}{\partial a_c^t}$ es la derivada parcial del error E para la compuerta de entrada.

$$\frac{\partial E}{\partial a_c^t} = \frac{\partial E}{\partial s_c^t} \frac{\partial s_c^t}{\partial a_c^t} \quad (41),$$

donde $\frac{\partial E}{\partial a_c^t}$ es la derivada parcial del error E para la celda de memoria.

$$\frac{\partial E}{\partial a_{\emptyset}^t} = \sum_{c=1}^c \frac{\partial E}{\partial b_c^t} \frac{\partial b_c^t}{\partial b_{\emptyset}^t} \frac{\partial b_{\emptyset}^t}{\partial a_{\emptyset}^t} = \frac{\partial b_{\emptyset}^t}{\partial a_{\emptyset}^t} \sum_{c=1}^c \frac{\partial E}{\partial b_c^t} \frac{\partial b_c^t}{\partial b_{\emptyset}^t} \quad (42),$$

donde $\frac{\partial E}{\partial a_{\emptyset}^t}$ es la derivada parcial del error E para la compuerta de olvido.

$$\frac{\partial E}{\partial a_l^t} = \sum_{c=1}^c \frac{\partial E}{\partial s_c^t} \frac{\partial s_c^t}{\partial b_l^t} \frac{\partial b_l^t}{\partial a_l^t} = \frac{\partial b_l^t}{\partial a_l^t} \sum_{c=1}^c \frac{\partial E}{\partial s_c^t} \frac{\partial s_c^t}{\partial b_l^t} \quad (43),$$

donde $\frac{\partial E}{\partial a_l^t}$ es la derivada parcial del error E para la *input gate*.

Teniendo en cuenta que la sumatoria se hace sobre c , pues el modelo se desarrolla en un único bloque (que posee C celdas en su interior), al calcular las derivadas respectivas se encuentran las descripciones matemáticas mostradas en la ecuación (44) (Graves, 2012).

$$\begin{aligned} \frac{\partial s_c^t}{\partial b_l^t} &= g(a_c^t) & \frac{\partial s_{\delta}^t}{\partial b_{\delta}^t} &= s_c^{t-1} & \frac{\partial b_c^t}{\partial b_w^t} &= h(s_c^t) \\ \frac{\partial b_0^t}{\partial a_{\delta}^t} &= f'(a_{\emptyset}^t) & \frac{\partial s_c^t}{\partial a_c^t} &= b_l^t g'(a_c^t) & \frac{\partial b_l^t}{\partial a_l^t} &= f'(a_l^t) \\ & & \frac{\partial b_{iv}^t}{\partial a_w^t} &= f'(a_w^t) & & \end{aligned} \quad (44).$$

A partir del análisis matemático aplicado, se llega a las ecuaciones *backward pass* —ecuaciones (45)-(48)— (Graves, 2012):

Output gate:

$$\delta_w^t = \frac{\partial E}{\partial a_w^t} = f' \left(a_w^t \right) \sum_{c=1}^c \epsilon_c^t h \left(s_c^t \right) \quad (45),$$

donde δ_w^t es la variación del error para la compuerta de entrada (en dicho bloque de memoria), y de manera análoga aplica para δ_c^t , δ_ϕ^t y δ_l^t en las ecuaciones (46)-(48):

Cell:

$$\delta_c^t = \frac{\partial E}{\partial a_c^t} = \epsilon_s^t b_l^t g' \left(a_c^t \right) \quad (46).$$

Forget gate:

$$\delta_\phi^t = \frac{\partial E}{\partial a_\phi^t} = f' \left(a_\phi^t \right) \sum_{c=1}^c \epsilon_s^t s_c^{t-1} \quad (47).$$

Input gate:

$$\delta_l^t = \frac{\partial E}{\partial a_l^t} = f' \left(a_l^t \right) \sum_{c=1}^c \epsilon_s^t g \left(a_c^t \right) \quad (48).$$

Nótese que las ecuaciones (45)-(48) dependen de los términos ϵ_c^t y ϵ_s^t , por lo que es necesario determinar la forma como el error se afecta al hacer cambios tanto en las salidas de las celdas como en sus estados.

En este caso, es necesario tener presente que el error es una función cuyas variables son las K salidas generadas por los H bloques de la capa oculta; es más, para un bloque fijo, la salida resultante en un tiempo t afectará a las K unidades de la capa de salida (en el instante t) y a la próxima entrada de cada uno de los H bloques en la capa oculta. Por lo anterior, ϵ_c^t puede ser definida a partir de la ecuación (49):

$$\epsilon_c^t = \frac{\partial E}{\partial b_c^t} = \sum_{k=1}^K \frac{\partial E}{\partial a_k^t} \frac{\partial a_k^t}{\partial b_c^t} + \sum_{h=1}^H \frac{\partial E}{\partial a_h^{t+1}} \frac{\partial a_h^{t+1}}{\partial b_c^t} \quad (49),$$

y la salida de la celda queda como se describe en la ecuación (50):

$$\epsilon_c^t = \sum_{k=1}^K \frac{\partial E}{\partial a_k^t} w_{ck} + \sum_{h=1}^H \frac{\partial E}{\partial a_h^{t+1}} w_{ch} \quad (50),$$

donde $\frac{\partial a_k^t}{\partial b_c^t} = w_{ck}$ y $\frac{\partial a_h^{t+1}}{\partial b_c^t} = w_{ch}$.

Finalmente, se debe analizar qué sucede con el error si se generan cambios en los estados de la celda. Si el estado de la celda es c y el tiempo es t , s_c^t indica si se modificó o no la información almacenada en ese momento; por lo tanto, s_c^t es un valor que afecta la entrada de todas las *gates*, el próximo estado de la celda y, claramente, la salida de la propia celda; matemáticamente, esto es —ecuación (51)—:

$$\epsilon_s^t = \frac{\partial E}{\partial s_c^t} = \frac{\partial E}{\partial b_c^t} \frac{\partial b_c^t}{\partial s_c^t} + \frac{\partial E}{\partial s_c^{t+1}} \frac{\partial s_c^{t+1}}{\partial s_c^t} + \frac{\partial E}{\partial a_l^{t+1}} \frac{\partial a_l^{t+1}}{\partial s_c^t} + \frac{\partial E}{\partial a_\delta^{t+1}} \frac{\partial a_\delta^{t+1}}{\partial s_c^t} + \frac{\partial E}{\partial a_w^t} \frac{\partial a_w^t}{\partial s_c^t} \quad (51),$$

donde el estado de la celda queda como se muestra en la ecuación (52) —valores concordantes con lo mostrado por Graves (2012)—:

$$\epsilon_s^t = \epsilon_c^t \frac{\partial b_c^t}{\partial s_c^t} + \epsilon_s^{t+1} \frac{\partial s_c^{t+1}}{\partial s_c^t} + \delta_l^{t+1} \frac{\partial a_c^{t+1}}{\partial s_c^t} + \delta_\emptyset^{t+1} \frac{\partial a_\delta^{t+1}}{\partial s_c^t} + \delta_w^{t+1} \frac{\partial a_w^{t+1}}{\partial s_c^t} \quad (52).$$

Caracterización del usuario primario con un modelo neurodifuso: Anfis-*grid*-FCM

Modelo de funcionamiento del sistema Anfis

Una de las arquitecturas Anfis (*adaptive neuro fuzzy inference system*) probadas está formada por las funciones de pertenencia descritas e interconectadas como lo muestra la figura 15, dando lugar a reglas con producto T-norma (π_n) e inferencia tipo Takagi-Sugeno aplicadas a un comportamiento continuo de la señal que identifica el PU. Esta arquitectura se compone de tres entradas (no se muestran las señales de retroalimentación), una salida y cinco capas, y su modelado se basa en la propuesta de Jang —ecuaciones (35) y (44)— (Siddique y Adeli, 2013).

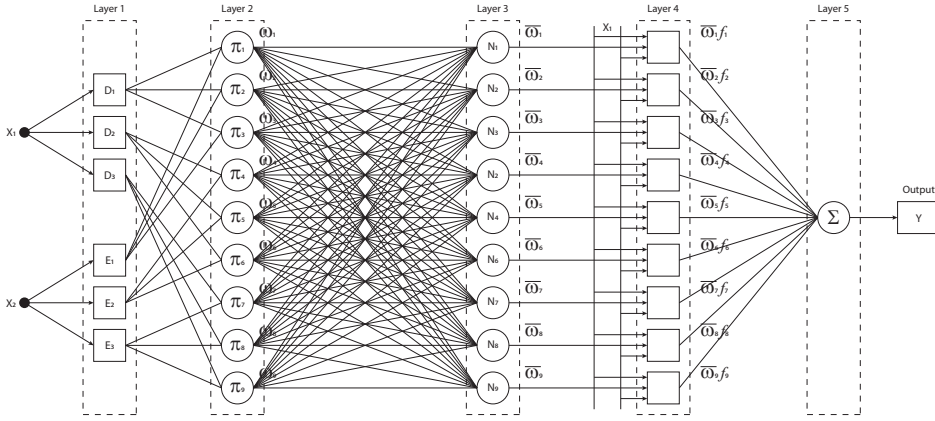
Capa 1. Cada nodo es adaptativo y representado matemáticamente por las funciones de las ecuaciones (53) y (54):

$$O_{1,i} = \mathcal{G}D_i(X_1); \forall i = 1, 2, 3 \quad (53);$$

$$O_{1,i} = \mathcal{G}E_i(X_2); \forall i = 1, 2, 3 \quad (54),$$

donde $O_{1,i}$ es la salida del nodo i (que especifica el grado al que el X_i dado satisface el cuantificador D_i y E_i), X_i corresponde a la entrada del sistema, y D_i y E_i son las etiquetas lingüísticas asociadas a la función de membresía \mathcal{G} dada por la ecuación (55).

Figura 15. Estructura Anfis para la caracterización de PU



Fuente: Siddique y Adeli (2013).

$$\mathcal{G}(X; a, b) = e^{\frac{-(X-a)^2}{2*(b)^2}} \quad (55),$$

donde a representa el centro de la función gaussiana y b determina su ancho.

Capa 2. En este nivel, la fuerza de disparo de cada regla es calculada. La fuerza de disparo se refiere a la aplicación de la T-norma: operación computacional cuyo objetivo es calcular la afirmación lingüística y en reglas del tipo “si X_1 es D_1 y X_2 es $D_2 \Rightarrow Y$ es C_1 ”, donde X y Y hacen referencia a las variables del antecedente, y F , a las del consecuente (Zapata Muñoz y Anzola Rojas, 2016). Matemáticamente, la salida está dada por la ecuación (56):

$$O_{2,i} = W_i = \mathcal{G}D_i(X_1) * \mathcal{G}E_i(X_2); \forall i = 1, 2, 3 \quad (56),$$

donde $O_{2,i}$ representa el valor de salida de la capa 2 y w_i hace referencia al grado en que se satisface la parte antecedente de una regla difusa.

Capa 3. En esta capa se obtiene el promedio de las salidas del nivel anterior y se generan los pesos normalizados (N en la figura 15), con el fin de establecer la relación entre la fuerza de una regla en particular y la suma de las fuerzas de todas las demás reglas, para así conocer “qué tanto se cumple” una regla respecto a las demás —ecuación (57)—:

$$O_{3,i} = \bar{W}_2 = \frac{W_i}{\sum_1^9 W_i} = \frac{W_i}{W_1 + W_2 + W_3 + W_4 + W_5 + W_6 + W_7 + W_8 + W_9} \quad (57),$$

donde \bar{W}_i representa las fuerzas de disparo normalizadas de las reglas y W_i es la salida de la capa anterior.

Capa 4. Aquí se determinan los parámetros del consecuente, donde la función de cada nodo pertenece a una combinación de la salida de la capa 3 y a una ecuación lineal simple tipo Takagi-Sugeno —ecuación (58)—:

$$O_{4,i} = \bar{W}_i * f_i = O_{3,i} = \bar{W}_i (S_i X_1 + T_i X_2 + Z_i) \quad (58),$$

donde el factor f_i se relaciona con las reglas difusas; S_i , T_i y Z_i son el conjunto de parámetros del consecuente de las reglas “if... then”, y donde estas reglas son del tipo ecuación (59):

$$\text{If } X_1 = D_i \text{ and } X_2 = E_i \text{ Then } f_i = S_i X_1 + T_i X_2 + Z_i \quad (59).$$

Capa 5. Corresponde a la salida o respuesta y está dada como la sumatoria de todas las señales entrantes (salida de la capa 4). Matemáticamente, puede ser representada como la ecuación (60):

$$O_{5,i} = Y = \sum_i \bar{W}_i * f_i = \frac{\sum_1^9 W_i f_i}{\sum_1^9 \bar{W}_i} \quad (60),$$

donde $O_{5,i}$ corresponde a la salida o respuesta del sistema.

Si se establece que los valores de los parámetros de la premisa son fijos (Keller et al., 2016; Samui, 2015), el Anfis puede ser escrito como una combinación lineal de los parámetros del consecuente —ecuaciones (61) y (62)—:

$$O_{5,i} = \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 + \frac{w_3}{w_1 + w_2} f_3 + \frac{W_4}{W_1 + W_2} f_4 + \frac{w_5}{W_1 + W_2} f_5 + \frac{w_6}{W_1 + w_2} f_6 + \frac{w_7}{w_1 + w_2} f_7 + \frac{w_8}{w_1 + w_2} f_8 + \frac{w_9}{w_1 + w_2} f_9 \quad (61);$$

$$\begin{aligned} O_{5,i} = & \bar{W}_1 (S_1 D_1 + T_1 E_2 + Z_1) + \bar{W}_2 (S_2 D_1 + T_2 E_2 + Z_2) + \bar{W}_3 (S_3 D_1 + T_3 E_2 + Z_3) + \dots \\ & \bar{W}_4 (S_4 D_1 + T_4 E_2 + Z_4) + \bar{W}_5 (S_5 D_1 + T_5 E_2 + Z_5) + \bar{W}_6 (S_6 D_1 + T_6 E_2 + Z_6) + \dots \\ & \bar{W}_7 (S_7 D_1 + T_7 E_2 + Z_7) + \bar{W}_8 (S_8 D_1 + T_8 E_2 + Z_8) + \bar{W}_9 (S_9 D_1 + T_9 E_2 + Z_9) \end{aligned} \quad (62).$$

Modelo Anfis-grid-FCM

El Anfis fue introducido por Jang en 1993 (Jang, 1993) y se puede afirmar que es un tipo de red neuronal que es funcionalmente igual a un modelo de inferencia Takagi-Sugeno. Anfis es un modelo híbrido inteligente que combina las ventajas de la lógica difusa con las de las redes neuronales artificiales. Específicamente, utiliza la técnica de las redes neuronales para actualizar los parámetros del modelo de inferencia Takagi-Sugeno y tiene la capacidad de aprender de la etapa de entrenamiento; por tal razón, las soluciones encontradas en un sistema de inferencia difusa (FIS) pueden describirse en términos lingüísticos (Abdulshahed et al., 2015).

Anfis-grid es un paradigma que combina Anfis con el método de particiones *grid* para generar el conjunto de reglas del sistema neurodifuso. Dicho particionamiento consiste en dividir el subespacio de datos en subespacios rectangulares utilizando particiones paralelas al eje; estos subespacios están basados en un número predefinido de funciones de membresía, lo que indica que Anfis-grid divide las variables de entrada en varios conjuntos difusos. Cuando se emplea esta técnica de partición de cuadrícula, el conjunto de reglas cubre todo el espacio de entrada mediante el uso de todas las combinaciones posibles de los conjuntos difusos de entrada. La principal limitación de este método es que el número de reglas puede aumentar dependiendo de la cantidad de datos de entrada, por lo que Anfis-grid es adecuada solo para casos con un pequeño número de variables de entrada. En esta técnica, los parámetros difusos se calculan utilizando el concepto de *mínimos cuadrados* en concordancia con el tipo de partición y las funciones de membresía (Mingzhen et al., 2007).

El Anfis basado en *fuzzy c-means* (FCM) es un tipo o método de aprendizaje no supervisado de agrupación que permite que una pieza de datos pertenezca a dos o más agrupaciones y es ampliamente utilizado para el reconocimiento de patrones y para predicción. Específicamente, este modelo genera un FIS usando FCM mediante la extracción de un conjunto de reglas que modela el comportamiento de los datos. La función requiere conjuntos separados de datos de entrada y salida como argumentos que alimentan el algoritmo. FCM divide una colección de n vectores x_i (donde $i = 1, 2, \dots, n$) en grupos difusos y determina un centro de clúster para cada grupo, de modo que la función objetivo de la medida de disimilitud se reduce [3] y hace que la predicción sea más confiable.

Red neuronal artificial de perceptrón multicapa

La MLP es un tipo de red neuronal conformada por una o más capas de neuronas en la que los datos que alimentan el sistema se envían a la capa de entrada; pueden existir una o más capas ocultas que proporcionan niveles de abstracción y una capa visible o de salida. La capacidad predictiva de este tipo de redes neuronales artificiales

(ANN) proviene de su estructura jerárquica o de varias capas. Las MLP son adecuadas para resolver problemas de predicción, de clasificación y de regresión en los que las entradas tienen asignada una entrada o etiqueta. Para el caso de un perceptrón simple, este genera una región de decisión que clasifica un conjunto de puntos mediante la separación de estos. La región de decisión divide el espacio en dos mitades determinadas por un hiperplano definido por los pesos sinápticos obtenidos durante el proceso de entrenamiento. Los pesos sinápticos son calculados por el algoritmo de corrección del error, que calcula la diferencia entre el valor obtenido después del entrenamiento y el valor esperado, y la multiplica por la pendiente del hiperplano actualizando la región de decisión en cada ejemplo de entrenamiento. Un conjunto de perceptrones simples genera un perceptrón multicapa que permite dividir la región en más de dos mitades, lo que genera un hiperplano a trozos capaz de clasificar varios puntos linealmente independientes (Flórez-López y Fernández Fernández, 2008).

Caracterización del arribo de los usuarios secundarios


La generación de esquemas óptimos de procesamiento de solicitudes hechas por SU en la etapa de selección de bandas espectrales es uno de los desafíos de la CR, ya que ello incide directamente en el tiempo que le lleva a la BS seleccionar y asignar un canal para que, de manera oportunista, los SU realicen el envío de sus datos a través de la red inalámbrica. Por ello es importante generar estrategias que permitan reducir la variable *tiempo de procesamiento* y, de esta manera, mejorar el rendimiento del sistema. Este apartado del libro plantea la generación de un modelo para predecir el arribo de SU a una BS, teniendo en cuenta los criterios y el tipo de calidad de servicio (RT o BE), con el fin de que el canal se pueda reservar de manera anticipada para la transmisión de los datos. El modelo desarrollado, llamado *estrategia proactiva de arribo de usuarios secundarios*, demuestra que es posible optimizar el rendimiento de la CR, ya que el tiempo que tardaría la estación central en asignar un canal sería menor que si se utilizara una estrategia de asignación de bandas espectrales convencional (llamada *estrategia reactiva*).

Además, se presenta el desarrollo de un algoritmo que predice la llegada de un SU —con requerimientos de tipo de servicio (BE o RT) y de BW determinados— a una BS en una red cognitiva basada en infraestructura por medio de redes neuronales. El algoritmo utiliza una técnica de construcción de forma dinámica, aprovechando la topología piramidal geométrica, y entrena una MLPNN basada en el histórico de llegada de SU para estimar las solicitudes futuras; esto permite gestionar más rápidamente la información en la BS para la selección del mejor o los mejores canales en CRN, ya que anticipa la llegada de los SU.

En el contexto de la selección de espectro en redes inalámbricas de CR centralizadas, como la que se muestra en la figura 16, la gran mayoría de autores (Do et al.,

2013; Kasbekar y Sarkar, 2010; Wang, Wang et al., 2011) han inclinado sus modelos a la utilización de estrategias reactivas, pero con un gran inconveniente, debido al tiempo que se consume en la búsqueda y selección de la frecuencia libre más óptima para la transmisión de los datos de los SU (variable crítica dentro de los sistemas de telecomunicaciones). La implementación de un modelo en el que la identificación del canal se hace milisegundos antes de la llegada del usuario cognitivo, a partir de la predicción del arribo del SU, permite disminuir los tiempos de asignación, lo que mejora la etapa de decisión de espectro (Sarmiento et al., 2016). En este sentido, para la descripción y evaluación del modelo, primero se elabora una estrategia de arribo reactivo de los SU; luego, se hace la presentación del modelo (estrategia proactiva), y finalmente se valida mostrando que su desempeño, desde el punto de vista del tiempo de procesamiento en la BS, es más óptimo debido a que se estima el arribo futuro de los SU.

Figura 16. Red de radio cognitiva basada en infraestructura



Fuente: elaboración propia.

Estimación del arribo del usuario secundario: modelo reactivo y modelo proactivo

Modelo del sistema para el caso reactivo


El diagrama de bloques del modelado de la estrategia reactiva de SU incluyó lo mostrado en la figura 17.

Tomando como referencia a Akter et al. (2008), se parte de la consideración de un sistema de Markov de dos estados (*on-off*), con el fin de determinar el número de SU que arriban a la CRN, y, con base en la teoría de colas, se genera un sistema de ecuaciones para establecer la probabilidad de los estados definidos, como se muestra en la ecuación (63).

$$P_{s,n}(t) = P(Z_s(t)) = n \quad (63),$$

donde P es la función de probabilidad, $Z_s(t)$ es el estado del s -ésimo SU en el tiempo t y el sistema de ecuaciones diferenciales está dado por las ecuaciones (64)-(66) (Akter et al., 2008), las cuales representan de forma general las probabilidades de estado que se pueden encontrar en relación con la cantidad de SU en el sistema: ausencia de SU: $\left(\frac{dP_{s,0}(t)}{dt}\right)$; existencia de n SU: $\left(\frac{dP_{s,n}(t)}{dt}\right)$, y número máximo de SU: $\left(\frac{dP_{s,N_s}(t)}{dt}\right)$ en la red cognitiva.

Figura 17. Sistema de arribo reactivo de usuarios secundarios a la estación base



Fuente: elaboración propia.

$$\frac{dP_{s,0}(t)}{dt} = \mu_s P_{s,1}(t) - N_s \lambda_s P_{s,0}(t) \quad (64);$$

$$\frac{dP_{s,n}(t)}{dt} = (N_s - n + 1) \lambda_s P_{s,n-1}(t) + (n + 1) \mu_s P_{s,n+1}(t) - (n \mu_s + (N_s - n) \lambda_s) P_{s,n}(t) \quad (65);$$

$$\frac{dP_{s,N_s}(t)}{dt} = \lambda_s P_{s,N_s-1}(t) - N_s \mu_s P_{s,N_s}(t) \quad (66),$$

donde μ_s es la tasa de distribución del tiempo de servicio del SU, λ_s define el proceso de llegada de los SU, n es la cantidad de SU en el tiempo t y N_s es el número máximo de nodos en el intervalo $T = \Delta t$.

Tomando como referencia y adaptando la idea de Akter (2008) al modelo reactivo, primero se determinará el número esperado de nodos cognitivos en un Δt , para luego obtener el número de SU RT y BE que llegarán o arribarán a la BS en dicho instante. Para ello, tomaremos $E[Z_s(t)]$ como el número de SU en un tiempo t —ecuación (67)— (Akter et al., 2008):

$$E[Z_s(t)] = \sum_{n=0}^{N_s} n P_{s,n}(t) \quad (67).$$

Al calcular la derivada, y por la linealidad de este operador, se obtiene la ecuación (68) (Akter et al., 2008):

$$\frac{dE[Z_s(t)]}{dt} = \sum_{n=0}^{N_s} n \frac{dP_{s,n}(t)}{dt} = NM_s P_s = N_s \lambda_s - (\lambda_s + \mu_s) \sum_{n=0}^{N_s} n P_{s,n}(t) = N_s \lambda_s - (\lambda_s + \mu_s) E[Z_s(t)] \quad (68),$$

donde M_s es la matriz de estados de los SU y $N = (0, 1, 2, \dots, N_s)$ corresponde a la matriz transpuesta.

Asumiendo que las mediciones se hacen cada instante de tiempo T , $t = mt$ —ecuación (69)— se considera como condición inicial para la m -ésima predicción (Akter et al., 2008):

$$E[Z_s((m-1)T)] = Z_s(m-1) \quad (69),$$

donde se asume que las mediciones se realizan en un instante de tiempo discreto mT en el que $m = 1, 2, 3, \dots$ para un valor dado de T .

Al resolver la ecuación anterior, se obtiene la ecuación (70) (Akter et al., 2008):

$$Z_s(m) = Z_s(m-1)e^{-T(\lambda_s + \mu_s)} + \frac{N_s \lambda_s}{\lambda_s + \mu_s} \left[1 - e^{-T(\lambda_s + \mu_s)} \right] \quad (70).$$

Determinado el número de SU que arribarán a la BS ($Z_s(m)$), a las $L + 1$ agrupaciones de solicitudes RT y BE se les puede asignar la distribución de probabilidad dada por la ecuación (71):

$$P\{R(t) = m \mid R(t) = n\} \quad (71),$$

donde $P(R(t) = n)$ es la probabilidad general de que en el tiempo t lleguen m solicitudes $R(t)$; particularizando lo anterior para el caso reactivo, se tendría lo mostrado en la ecuación (72) (Akter et al., 2008):

$$P(R(t) = n) = \frac{1}{2^{Z_s(t)}} \left\langle \frac{Z_s(t)}{n} \right\rangle \quad (72).$$


Ya que $Z_s(t)$ es el número de usuarios cognitivos que llegarán a la BS, y debido a que, de estos, n son solicitudes con criterios RT, los demás serían solicitudes con criterios BE.

Modelo del sistema para el caso proactivo

La metodología seguida para calcular la probabilidad de arribo de SU con criterios de QoS se observa en la figura 18. Partiendo de la existencia de una base de datos, considérese (como en el caso reactivo) que L es el número de nodos que arribarán a la BS en un intervalo de tiempo Δt ; en tal sentido, para predecir o estimar el tipo

de servicio que solicitará el siguiente SU, primero se determinará cuántas combinaciones son posibles con L usuarios, donde R de ellos solicitan QoS para RT y los B restantes ($B = L - R$) requieren criterios de servicio para BE. Nótese que $L = B + R$, y que se cumple una y solo una de las relaciones $B > R$, $B = R$ o $B < R$. Cualquiera que sea la secuencia de L solicitudes, siempre puede asociarse con un elemento del grupo de permutaciones SL . Obsérvese que R puede tomar cualquier valor entre 0 y L ($0 \leq R \leq L$); así se obtendrán $L + 1$ agrupaciones posibles, donde el proceso de alternar los dos tipos de solicitudes se puede asociar con la imbricación. Por ello, fijado un número de solicitudes RT, ¿cuántas posibles combinaciones de RT y BE hay? Para dar respuesta a esta pregunta, es necesario fijarse en que, al realizar la imbricación, se mantiene el orden relativo de los grupos, por lo que basta simplemente con calcular de cuántas maneras se pueden elegir R posiciones entre las L posibles.

Figura 18. Sistema de arribo proactivo de usuarios secundarios a la estación base



Fuente: elaboración propia

Así, para un R preestablecido, es posible encontrar $\binom{L}{R}$ organizaciones posibles, y entonces, la probable llegada de un requerimiento (cálculo de la probabilidad) puede presentarse con un elemento $\{0, 1\}^L = \{0, 1\} * \{0, 1\} * \dots * \{0, 1\}$; de esta manera, se restringe el sistema a 2^L combinaciones posibles de dos grupos de solicitudes de QoS en lugar de $L!$ (número de elementos del conjunto S_L). Es de resaltar que para $L > 3$ es válida la desigualdad $2^L < L!$, por lo que esta restricción implica una reducción considerable de cálculos. Asociando probabilidades, las agrupaciones hechas hacia la mitad tienen más probabilidad de ocurrir, razón por la cual se asigna a la división hecha (posición R) la probabilidad representada en la ecuación (73):

$$\frac{1}{2^L} \binom{L}{R} \quad (73).$$

Si se trata de asignar probabilidades a la combinación $R=0$ y $R=L$, la respuesta es obvia —véase la ecuación (11)—, pero si se considera que $2 \leq R \leq L-1$, una posible opción es asignar una distribución uniforme con el fin de que cada combinación de solicitudes tenga una probabilidad de $\frac{1}{\binom{L}{R}}$, y así todas las posibles reordenaciones (salvo

la identidad) tienen probabilidad $1/2^L$. Además, es claro que, por imbricación, se obtiene una permutación $P(\pi)$ y que la probabilidad asociada a la permutación $\pi \in S_L$ está dada por la ecuación (74):

$$P(\pi) = \pi P(x_i); P(x_i) \in (0,1]; \quad i = 1, 2, \dots, L \quad (74).$$

Si se compara $P(\pi)$ con el de la probabilidad uniforme $u(\pi) = 1/L!$, entonces para cada $\pi \in S_L$ se puede determinar qué tan predecible será la llegada de los SU con sus solicitudes de RT o BE —ecuación (75)—.

$$\delta = \frac{1}{2} \sum_{\pi \in S_L} |P(\pi) - u(\pi)| \quad (75).$$

El factor $1/2$ de la ecuación (75) permite normalizar el valor de δ ($0 \leq \delta \leq 1$). Se tiene $\delta = 0$ si y solo si $P(\pi) = u(\pi)$ para todo $\pi \in S_L$. Si δ es muy cercano a 1, la solicitud del próximo SU es predecible en un alto porcentaje, y si δ es un valor muy pequeño, la predicción puede ser errónea.

Para el caso en el que R sea fijo, se tendrá $\binom{L}{R}$ combinaciones posibles, lo que indica que el orden de llegada de los SU y, por ende, de las solicitudes de QoS es independiente entre sí.

Modelo MLPNN para la estimación del arribo del usuario secundario

Representación del histórico de un usuario secundario

Se define $\{x(i), y(i)\}$ como una pareja de coordenadas en R^{n*3} , siendo $x(i)$ la representación en sistema binario de una unidad de tiempo en un espacio R^n ; n es el número de dígitos en la representación binaria, y $y(i)$ en un espacio R^3 , donde el primer componente corresponde a la solicitud o no de un servicio tipo BE; el segundo, a la solicitud de un servicio tipo RT, y el tercero, al BW requerido en KHz. Un ejemplo de esta representación se da en la ecuación (76):

$$\{x(1), y(1)\} = \{[000], [000]\} \quad (76).$$

$$\left(\begin{array}{c} [0 \ 0 \ 0] \\ [0 \ 0 \ 1] \\ [0 \ 1 \ 0] \\ [0 \ 1 \ 1] \\ [1 \ 0 \ 0] \\ [1 \ 0 \ 1] \\ [1 \ 1 \ 0] \\ [1 \ 1 \ 1] \\ \hline \text{Inputs } x(i) \end{array} \right) \left| \begin{array}{c} [0 \ 0 \ 0] \\ [0 \ 1 \ 20] \\ [0 \ 1 \ 20] \\ [1 \ 0 \ 43] \\ [1 \ 0 \ 44] \\ [1 \ 0 \ 45] \\ [0 \ 1 \ 48] \\ [0 \ 1 \ 45] \\ \hline \text{Outputs } y(i) \end{array} \right.$$

Esta primera aproximación de representación de SU con sus respectivas características considera la topología de red neuronal sin tomar en consideración la naturaleza de los datos que se pretende caracterizar. Debido a que las funciones de transferencia entre cada capa de la red neuronal están dadas por una función tipo sigmoide, el rango de los datos oscilará entre 0 y 1. Esto no se considera un problema para el dominio de los datos que se pretende caracterizar excepto para el caso de R^3 , cuyo tercer componente tiene dominio en los números naturales (y que corresponde al BW). De esta forma, se plantea separar el conjunto de datos (mostrado anteriormente) en dos grupos y utilizar dos redes neuronales. La primera red se especializa en la caracterización del conjunto de datos $y(i)^1$, representados como se describe en la ecuación (76), y que sigue los siguientes criterios de diseño:

- El número de neuronas en la capa de entrada corresponde a la dimensión R^n de $x(i)$.
- El número de neuronas en la capa de salida corresponde a la dimensión R^2 de $y(i)$, y cada una de las neuronas estará especializada en modelar una característica del SU.
- El número de neuronas en las capas ocultas se obtiene siguiendo la topología piramidal geométrica.

La segunda red neuronal se especializa en la caracterización del conjunto de datos $y(i)^2$, representados en la ecuación (77), con los siguientes criterios:

- El número de neuronas en la capa de entrada corresponde a la dimensión R^n de $x(i)$.
- El número de neuronas en la capa de salida corresponde a la dimensión R^1 de $y(i)^2$, y cada una de las neuronas estará especializada en modelar una característica del SU.
- El número de neuronas en las capas ocultas se obtiene siguiendo la topología piramidal geométrica.

$$\left\{ \begin{array}{c|c} \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & 1 & 0 \\ 0 & 1 & 1 \\ 1 & 0 & 0 \\ 1 & 0 & 1 \\ 1 & 1 & 0 \\ 1 & 1 & 1 \end{bmatrix} & \begin{bmatrix} 0 & 0 \\ 0 & 1 \\ 0 & 1 \\ 1 & 0 \\ 1 & 0 \\ 1 & 0 \\ 0 & 1 \\ 0 & 1 \end{bmatrix} \end{array} \right\} \quad (77);$$

$\underbrace{\hspace{10em}}_{\text{Inputs } x(i)} \quad \underbrace{\hspace{10em}}_{\text{Outputs } y(i)^1}$


$$\left\{ \begin{array}{c|c} \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & 1 & 0 \\ 0 & 1 & 1 \\ 1 & 0 & 0 \\ 1 & 0 & 1 \\ 1 & 1 & 0 \\ 1 & 1 & 1 \end{bmatrix} & \begin{bmatrix} 0 \\ 20 \\ 20 \\ 43 \\ 44 \\ 45 \\ 48 \\ 45 \end{bmatrix} \end{array} \right\} \quad (78).$$

$\underbrace{\hspace{10em}}_{\text{Inputs } x(i)} \quad \underbrace{\hspace{10em}}_{\text{Outputs } y(i)^2}$

Modelo matemático del sistema neuronal

Para el desarrollo del funcionamiento de la red neuronal se considera el conjunto de ejemplos mostrado en la ecuación (77). Siguiendo los lineamientos planteados para la construcción de la red neuronal propuesta, se obtiene un sistema de 3 capas con 3 neuronas en la capa de entrada, 2 en la capa oculta y 2 en la capa de salida (figura 19).

Figura 19. Representación de la MLPNN para el conjunto de datos de la ecuación (77)



Fuente: elaboración propia.

Además, se definen las siguientes variables: m : número de capas de la red neuronal; θ : matriz de pesos de control, que mapea (genera una asociación) desde una capa i hasta una capa $i+1$, y A : unidad de activación en la capa i .

El procedimiento para el cálculo de la salida de la red neuronal se define como se muestra en la ecuación (79); este es llamado *algoritmo de propagación hacia adelante* y fue elaborado a partir de Du y Swamy (2013):

$$A^{(i)} = g\left(\theta^{(i-1)T} A^{(i-1)}\right) \quad (79),$$

donde T es la operación transpuesta, $A^{(i)}$ es la salida de la capa que se desea calcular, $A^{(i-1)}$ corresponde a la salida de la capa anterior, $i = 1, 2, 3, \dots, m$, $A^{(i)} = X$ y g es la función sigmoide.

Considerando de forma general la matriz de pesos de control $\theta^{(d)} = \theta_{ij}^d$, donde θ_{ij}^d identifica el peso para la conexión existente entre la neurona i (de la capa d) y la neurona j (de la capa $d + 1$), se procede a calcular la transición desde la capa de entrada hasta la capa oculta —ecuaciones (80) y (81)—:

$$\theta^{(1)} = \begin{bmatrix} \theta_{11}^{(1)} & \theta_{12}^{(1)} \\ \theta_{21}^{(1)} & \theta_{22}^{(1)} \\ \theta_{31}^{(1)} & \theta_{32}^{(1)} \end{bmatrix} \quad (80),$$

donde $\theta^{(1)}$ es la matriz de pesos de control de la capa 1.

$$A^{(1)} = X = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} \quad (81),$$

donde $A^{(i)}$ corresponde a la salida de la capa 1 del sistema.

Así, la transición ocurrida desde la capa de entrada hasta la capa de salida estaría dada por lo descrito en la ecuación (82):

$$A^{(2)} = \begin{bmatrix} g\left(x_1\theta_{11}^{(1)} + x_2\theta_{21}^{(1)} + x_3\theta_{31}^{(1)}\right) \\ g\left(x_1\theta_{12}^{(1)} + x_2\theta_{22}^{(1)} + x_3\theta_{32}^{(1)}\right) \end{bmatrix} \quad (82),$$

donde $A^{(2)}$ corresponde a la salida o respuesta de la capa oculta, g es la función sigmoide y $x(i)$ es la representación de una unidad de tiempo en R^n .

Por simplicidad, se definen las siguientes variables para la matriz $A^{(2)}$ —ecuación (83)—:

$$A^{(2)} = \begin{bmatrix} a_1^{(2)} \\ a_2^{(2)} \end{bmatrix} \quad (83).$$

Al calcular la transición desde la capa oculta hasta la capa de salida ($A^{(3)}$), tomando como referencia la matriz de pesos de control $\theta^{(2)}$ —ecuación (84)—, se obtiene la ecuación (85):

$$\theta^{(2)} = \begin{bmatrix} \theta_{11}^{(2)} & \theta_{12}^{(2)} \\ \theta_{21}^{(2)} & \theta_{22}^{(2)} \end{bmatrix} \quad (84),$$

donde $\theta^{(2)}$ es la matriz de pesos de control de la capa oculta.

$$A^{(3)} = \begin{bmatrix} g(a\theta_{11}^{(2)} + a_2\theta_{21}^{(2)}) \\ g(a_1\theta_{12}^{(2)} + a_2\theta_{22}^{(2)}) \end{bmatrix} \quad (85),$$

donde la variable a_n cumple con la condición de la ecuación (83). Asíumase que en este caso $a\theta_{11}^{(2)}$ es equivalente a $a_1\theta_{11}^{(2)}$.

Trabajos relacionados

En esta sección se presenta un estado del arte de trabajos recientes acerca de algoritmos para la toma de decisiones de SH en CRN. Al respecto, no se identificaron trabajos que relacionen todos los enfoques descritos en la presente propuesta, como la toma de decisiones, los modelos colaborativos y las arquitecturas descentralizadas; sin embargo, se encuentran investigaciones relevantes con enfoques independientes o con combinaciones de dos de ellos.

A continuación se describen las tres publicaciones en el área de redes de radio cognitiva descentralizadas (DCRN) que tienen mayor relación con la presente investigación. Estas publicaciones están enfocadas en el análisis de la calidad de servicio, el esquema de aprendizaje y el acceso al espectro dinámico, y utilizan estrategias como la teoría de colas, las cadenas de Markov y los filtros digitales, entre otras:

Xenakis et al. (2014), en su artículo “Multi-parameter performance analysis for decentralized cognitive radio networks”, realizan un análisis del impacto de la actividad del PU y el SU, del desvanecimiento de canales y de las colas de longitud finita en el rendimiento de las DCRN. Realizan, además, un análisis de teoría de colas y derivan varias medidas de rendimiento en relación con la pérdida de paquetes, así como el rendimiento, la eficiencia espectral y la distribución de retardo de paquetes. Los resultados cuantifican el impacto de los parámetros y las variables en el rendimiento del sistema y ponen de relieve las principales ventajas y desventajas del rendimiento en las DCRN.

Darak et al. (2015), en su artículo “Low complexity and efficient dynamic spectrum learning and tunable bandwidth access for heterogeneous decentralized cognitive radio networks”, proponen un esquema de aprendizaje y acceso al espectro dinámico de baja complejidad y eficiencia para DCRN y para redes heterogéneas de

próxima generación; este esquema consiste en una transformación de frecuencia de segundo orden, una técnica de interpolación basada en un filtro digital variable y una política de toma de decisiones sintonizable. Los resultados de la simulación verifican la superioridad del esquema propuesto sobre los esquemas existentes.

Amjad et al. (2016), en su artículo “Coexistence in heterogeneous spectrum through distributed correlated equilibrium in cognitive radio networks”, analizan múltiples técnicas de cadenas de Markov para estudiar fenómenos de desigualdad en escenarios heterogéneos de CRN coexistentes; además, proponen una solución descentralizada que no limita la capacidad de *hardware* de un dispositivo de CR e introducen una capa MAC (control de acceso al medio) para la coexistencia (CCR-MAC). Los resultados obtenidos muestran que el CCR-MAC propuesto mejora la ventaja competitiva y la equidad sin limitaciones de *hardware*.

Por otra parte, se describen a continuación las dos publicaciones que trabajan en conjunto los enfoques de toma de decisiones y arquitecturas descentralizadas y que, a su vez, tienen una fuerte similitud con la presente investigación:

Darak et al. (2017), en su artículo “Decision making policy for RF energy harvesting enabled cognitive radios in decentralized wireless networks”, proponen una nueva política de toma de decisiones (DMP) para DCRN basada en el acceso oportunista al espectro con capacidad de recolección de energía por radiofrecuencia (RFEH). La DMP propuesta consta de tres subunidades: un algoritmo de muestreo basado en un enfoque bayesiano, un esquema de acceso basado en el algoritmo de muestreo de Thompson y un esquema de selección de modo. Los resultados de la simulación muestran que la política propuesta ofrece una mejora del 10-35% en el rendimiento de la DCRN y una reducción del 40-90% en el número de conmutaciones de subbandas en comparación con las DMP existentes.

Hasegawa et al. (2014), en su artículo “Optimization for centralized and decentralized cognitive radio networks”, analizan y proponen algoritmos de optimización para la toma de decisiones en redes inalámbricas cognitivas heterogéneas. Para las DCRN, proponen como estrategia una red neuronal Hopfield-Tank, y la validan mediante un conjunto de simulaciones para, finalmente, implementarla en un sistema cognitivo experimental.

A continuación, asimismo, se describen las cinco publicaciones que trabajan en conjunto los enfoques de toma de decisiones y las CRN y que, a su vez, tienen una fuerte similitud con la presente investigación:

Tripathi et al. (2019), en su artículo “Analysis and comparison of different fuzzy inference systems used in decision making for secondary users in cognitive radio network”, implementan un sistema basado en lógica difusa con un conjunto de parámetros de entrada y salida para la toma de decisiones de los SU, a través de un análisis comparativo entre el *Sugeno fuzzy inference system* y el *Mamdani fuzzy inference system*. El trabajo concluye con una lista de ventajas y desventajas para cada una de las técnicas, y se obtiene una correlación mayor de 0,95 entre Sugeno y Mamdani; por lo tanto, la selección entre las estrategias depende de los requisitos de aplicación, pero, desde una perspectiva computacional, Sugeno presenta una mayor eficiencia que Mamdani para más de 100 reglas.

Kaur et al. (2018), en su artículo “PSO based multiobjective optimization for parameter adaptation in CR based IoTs”, estudian las características de adaptación de las CRN al internet de las cosas. Para cumplir con los objetivos de potencia mínima de transmisión, tasa mínima de error y el máximo *throughput*, los autores proponen un módulo de toma de decisiones basado en optimización multiobjetivo a partir de enjambres de partículas (PSO). Los resultados son comparados con un algoritmo genético con codificación real (RCGA). Para servicios de *e-mail*, voz y video, el promedio de *fitness* en PSO es de 0,8614, 0,7327 y 0,8597, respectivamente, en comparación con los 0,8121, 0,5975 y 0,7183 obtenidos para RCGA. Así, se demuestra que el módulo de decisión cognitiva basado en PSO supera la implementación basada en RCGA en todos los escenarios en términos de valor de la función de *fitness* y de los valores óptimos de las métricas de decisión.

Li et al. (2016), en su artículo “Optimization spectrum decision parameters in CR using autonomously search algorithm”, introducen el concepto de *bioinspiración* y su aplicación en la toma de decisiones. Se propone un algoritmo de búsqueda autónomo (ASA) basado en la evolución de la población, la reproducción, la selección y la mutación. El modelo propuesto es comparado con un algoritmo de optimización por PSO y con un algoritmo genérico (AG). Los resultados experimentales muestran que ASA satisface la demanda de comunicación y tiene un buen rendimiento, además de que puede optimizar adaptablemente los parámetros de transmisión de acuerdo con las condiciones del canal y el tipo de cambio en el servicio al cliente, lo que le permite obtener un mejor esquema de decisión de parámetros.

Pinto y Correia (2018), en su artículo “Analysis of machine learning algorithms for spectrum decision in cognitive radios”, presentan un análisis de los algoritmos de *machine learning* para el desarrollo de CRN en *hardware* real. Para esto, implementaron, en dos escenarios distintos, tres métodos para la decisión del espectro: ANN, bosques aleatorios (RnF) y HMM. Los resultados muestran que HMM obtuvo la mejor tasa

media de entrega en los dos escenarios evaluados. En el patrón de tráfico alto, HMM fue un 4% mejor que ANN y un 16% mejor que RnF; en el patrón medio, fue un 5,9% mejor que ANN y un 9,7% mejor que RnF, y en el patrón bajo, fue un 5,7% mejor que ANN y un 3% mejor que RnF.

Joda y Zorzi (2015), en su artículo “Decentralized heuristic access policy design for two cognitive secondary users under a primary Type-I HARQ process”, proponen políticas de acceso heurístico descentralizadas para dos SU cognitivos. Debido a la falta de una unidad central, el problema se modela como un proceso de decisión descentralizado parcialmente observable de Markov (DEC-POMDP), pero, por la complejidad del modelo, se diseñaron las políticas de acceso, que aprovechan la redundancia introducida por el protocolo Híbrido-ARQ tipo I. Los resultados muestran que las políticas heurísticas diseñadas aumentan el rendimiento, la flexibilidad y la robustez frente a los cambios de canal. Como trabajo futuro, los autores resaltan la importancia de implementar escenarios multiusuario.

Finalmente, se describen las dos publicaciones que trabajan en conjunto los enfoques de toma de decisiones y colaboración entre SU y que, a su vez, tienen una fuerte similitud con la presente investigación. En estas investigaciones se utilizan técnicas heurísticas y metaheurísticas y estrategias probabilísticas basadas en cadenas de Markov:

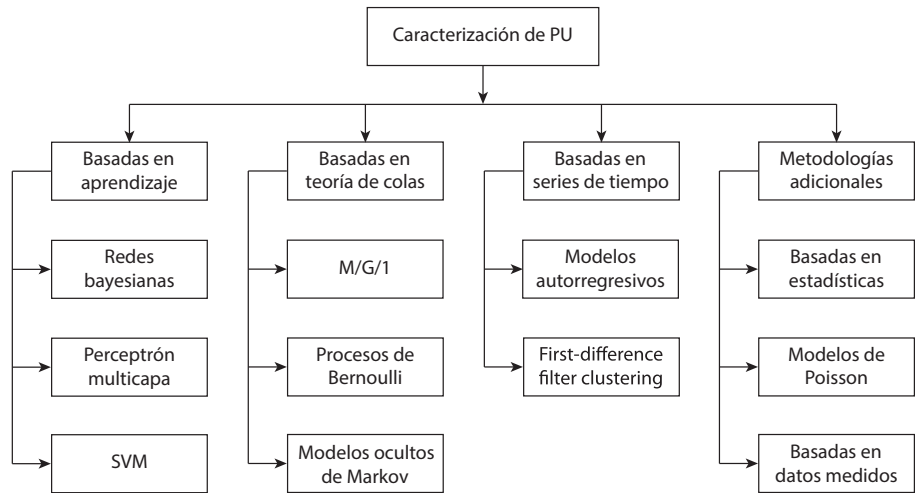
Rizk et al. (2018), en su artículo “Decision making in multiagent systems: A survey”, realizan una revisión de los modelos cooperativos más relevantes para la toma de decisiones en MAS. Así, presentan modelos basados en procesos de decisión de Markov, teoría de juegos, teoría de grafos e inteligencia de enjambres, y las diferentes técnicas son analizadas según su criterio de optimalidad y su aplicación. Entre las aplicaciones más destacadas, se incluyen diferentes sistemas cognitivos, como redes de telecomunicaciones, sistemas eléctricos, sistemas de transporte, equipos de búsqueda y rescate, transporte de objetos, exploración y mapeo. Finalmente, el documento resalta los avances y los retos para los próximos años, la necesidad de incluir en el proceso de toma de decisiones los avances en *big data* e internet de las cosas y la necesidad de desarrollar normas de evaluación que permitan la comparación y faciliten su validación.

Roy et al. (2017), en su artículo “Optimized secondary user selection for quality of service enhancement of two-tier multi-user cognitive radio network: A game theoretic approach”, utilizan la teoría de juegos para estudiar el conflicto y la cooperación entre dos niveles de SU. El análisis comparativo muestra que con esta teoría la probabilidad de bloqueo, caída y saturación de canales se reduce en un 81%, un 79% y un 84%, respectivamente, y la probabilidad de aceptación aumenta un 91%.

A partir de las anteriores investigaciones, se evidencia que aún no hay estudios que relacionen en conjunto los tres enfoques principales del presente libro —la decisión de espectro, el ambiente colaborativo y la arquitectura descentralizada— y, además, que los orienten hacia las redes de radio cognitiva, lo cual representa el principal aporte de este trabajo. Adicionalmente, el hecho de trabajar con datos de ocupación espectral reales, obtenidos a partir de una campaña de medición, le da a esta investigación un mayor valor agregado y diferenciador con respecto a las publicaciones descritas anteriormente, dado que en estas se trabaja con datos espectrales aleatorios.

Algunas de las propuestas de investigación en el modelaje o estimación de la actividad de PU se encuentran descritas o desarrolladas en Bkassiny et al. (2013); Bütün et al. (2010); López Sarmiento et al. (2015); Melián-Gutiérrez et al. (2013); Mishra et al. (2012); Pattanayak et al. (2013); Tumuluru et al. (2010); Uyanik et al. (2012); Wang, Ghosh et al. (2011); Xing, Jing, Cheng et al. (2013), y Yarkan y Arslan (2007). Un resumen de las técnicas aplicadas se muestra en la figura 20.

Figura 20. Resumen de algunas de las metodologías utilizadas en la caracterización del PU




Fuente: elaboración propia.

Tomando como referencia los resultados encontrados en los trabajos referenciados, se encuentra que los algoritmos basados en teoría de colas y las metodologías adicionales no logran, en la mayoría de los casos, encontrar variaciones temporales de corto plazo en la señal que representa el PU, lo que genera colisiones o interferencias entre los nodos cognitivos y licenciados, y los basados en series temporales, por su parte, requieren de un *hardware* robusto para ser implementados (ya que su comple-

tividad computacional es alta), y esto dificulta su utilización en áreas geográficas de difícil acceso, debido al importante consumo de energía de la red cognitiva. Si bien es cierto que se han desarrollado algunas propuestas basadas en aprendizaje autónomo, es importante considerar el desarrollo o aplicación de metodologías similares, como la basada en Anfis o LSTM (Graves et al., 2013), con el objetivo de determinar si es posible disminuir el porcentaje de error en la generación de predicciones para el comportamiento caótico de los PU, con lo que se lograría que los modelos fueran más confiables.

Un criterio importante que influye en la selección de las bandas tiene que ver con la manera como la BS procesa las solicitudes de los SU (figura 21). En la estrategia reactiva —método convencional utilizado en el estado del arte (López Sarmiento et al., 2015)—, la negociación de las características que rige el envío de datos se procesa después del arribo de la solicitud. En contraste, en la estrategia proactiva —metodología propuesta—, la selección y asignación del canal se decide con anterioridad a la llegada del SU, mediante una reserva del recurso; la desventaja de esta estrategia es que depende del nivel de acierto del modelo que se use para la estimación de la llegada del SU para una aplicación específica (BE o RT): si el cálculo de la probabilidad de arribo o predicción no es bueno, la cantidad de aciertos será muy baja y la eficiencia será insuficiente.

Figura 21. Estrategias de ejecución de las solicitudes de SU



Fuente: elaboración propia a partir de López Sarmiento et al. (2015).

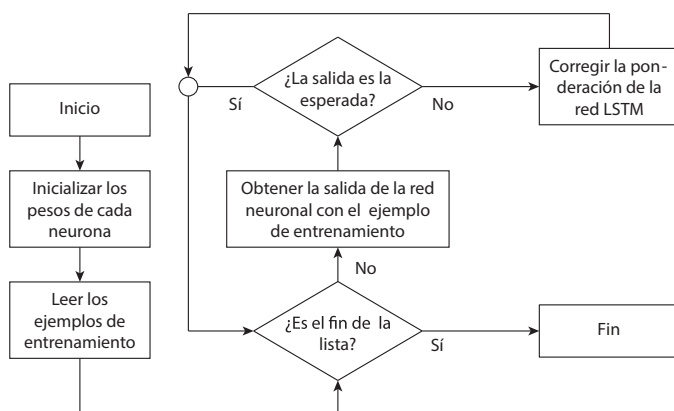
Caracterización de los usuarios primarios

En este capítulo se presentan el desarrollo y los resultados de los modelos de caracterización de usuarios primarios (PU) utilizados en la investigación: LSTM (*long short-term memory*), SVM (máquinas de soporte vectorial), Anfis-grid-FCM y MLPNN, los cuales se introdujeron en el capítulo anterior.

Caracterización del usuario primario con *long short-term memory*

El diagrama de flujo para el entrenamiento del modelo LSTM (figura 22) comienza su proceso inicializando de forma aleatoria cada neurona con valores que oscilan entre -1 y 1 ; seguidamente, se toma cada ejemplo de entrenamiento y se compara la salida con la salida esperada: si la respuesta entregada no corresponde a la deseada, el algoritmo calcula el error entre las dos salidas y corrige los pesos tanto de las compuertas (*input*, *output* y *forget*) como de la celda, a través de la aplicación de ponderaciones y haciendo uso de funciones tangenciales y sigmoideas, hasta culminar con todos los ejemplos de entrenamiento, y de esta forma aproxima la salida del modelo a la esperada (mediante la disminución del error).

Figura 22. Diagrama de flujo para el entrenamiento de LSTM



Fuente: elaboración propia.

Parte del pseudocódigo del algoritmo LSTM implementado es el siguiente:

Data: la existencia de un arreglo W_o , W_f , W_i y W_c que representa la red neuronal.

Result: red neuronal entrenada con los datos de los ejemplos de entrenamiento.

forgetLayer = Wf.size() //Se obtiene el tamaño del arreglo que representa la red neuronal;

for i = 0; i < neurons; i++ **do**

Wf[i] = random(-1,1); //Se inicializa cada capa de la red neuronal.

Wi[i] = random(-1,1);

Wc[i] = random(-1,1);

Wo[i] = random(-1,1);

end

bf = 0.5 //Aproximación de la salida obtenida para cada capa;

bc = 0.5;

bi = 0.5;

bo = 0.5;

inputs = readInputs() //Se leen los ejemplos de entrada;

outputs = readOutputs() //Se leen los ejemplos de salida;

size = inputs.size() //Se obtiene el tamaño de los ejemplos;

for i = 0; i < size; i++ **do**

sumf = 0;

sumi = 0;

sumc = 0;

sumo = 0;

for j = 0; j < neurons; j++ **do**

sumf = sumf + Wf[j]*inputs[i][j] //Se calcula la salida para cada ejemplo en cada capa;

sumi = sumi + Wi[j]*inputs[i][j];

sumc = sumc + Wc[j]*inputs[i][j];

sumo = sumo + Wo[j]*inputs[i][j];

end

ft = sigmoide(sumf + bf) //Se realizan las aproximaciones para cada salida de la red;

it = sigmoide(sumi + bi);

dct = tanh(sumc + bc);

ct = ft + it*dct;

ot = sigmoide(sumo + bo);

output = ot*tanh(ct) //Se calcula la salida de la red neuronal;

if output != outputs[i] **then**

```

    error = outputs[i] - output;
    for j = 0; j < neurons; j++ do
        Wo[j] = Wo[j] + inputs[i][j]*e //Se recorre cada neurona y se corrige su ponderación respecto al error calculado;
    end
    bo = 0.5 + error //Se corrige el desplazamiento;
end

```

Evaluación y análisis de resultados

Para evaluar el desempeño del algoritmo, la red LSTM fue sometida a dos casos de prueba: en el primero de ellos, se analizó el desempeño del sistema de modelamiento y predicción cuando la señal de entrada al sistema LSTM se genera computacionalmente para diferentes patrones de comportamiento difíciles de encontrar en las redes inalámbricas convencionales; en el segundo caso, se estudió el pronóstico entregado por el algoritmo para secuencias de datos reales capturadas en las bandas GSM-850 y Wi-Fi, partiendo de la premisa de que el 70% de los datos utilizados se usa en la etapa de entrenamiento de la red LSTM, y el 30% restante, para validación (estimación de la predicción).

Captura y procesamiento de la información espectral

En primera instancia, se procedió a determinar la aplicación de red inalámbrica sobre la que se quería evaluar la técnica basada en *deep learning* (Hochreiter y Schmidhuber, 1997): se seleccionaron, como objetivo principal, las comunicaciones celulares (GSM) y de acceso a internet (Wi-Fi), y en segunda instancia, se escogió la técnica de detección de espectro: se seleccionó la detección de energía por su fácil implementación y sus bajos requerimientos (Hernández, Salgado et al., 2015).

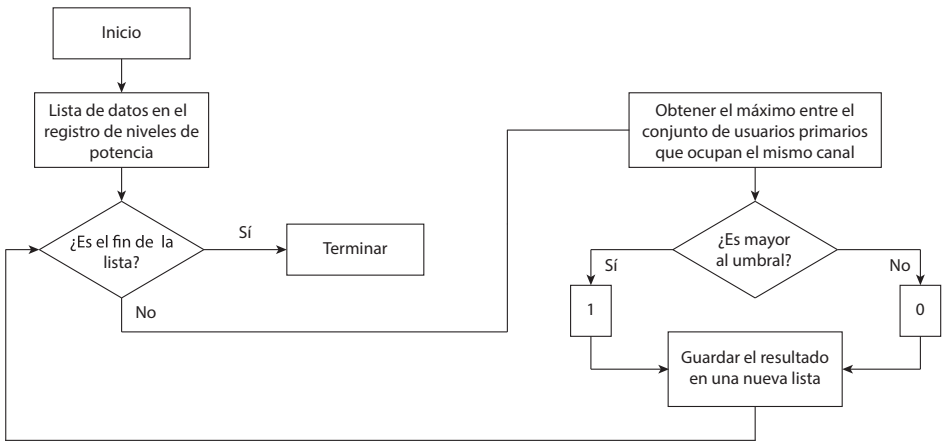
Para el procesamiento de la información espectral, se parte del hecho de que las medidas fueron tomadas cada 290 milisegundos en las bandas Wi-Fi (2,4-2,48 GHz) y GSM (*uplink* 824-849 MHz) en términos de potencia de transmisión (dBm); con el fin de facilitar el reconocimiento de patrones, se representaron los niveles de potencia en sistema binario a partir de la definición establecida en la ecuación (86):

$$f(x) = \begin{cases} 0, & \text{si } x \leq a \\ 1, & \text{si } x > a \end{cases} \quad (86),$$

donde a toma los valores de -89 dBm para el caso GSM, y -88 dBm para Wi-Fi.

En la figura 23 se aprecia el procedimiento para convertir las trazas de datos espectrales en señales discretas; cabe destacar que para el desarrollo de las pruebas se contó con una base de datos de 6,79 GB de información sobre trazas de tráfico GSM, y de 9,63 GB para trazas Wi-Fi.

Figura 23. Diagrama de flujo para discretización de datos espectrales



Fuente: elaboración propia.

Evaluación y validación del algoritmo LSTM

El rendimiento del algoritmo propuesto es puesto a prueba para un comportamiento del PU con secuencias de datos simulados y reales (trazas GSM y Wi-Fi):

Primer grupo de casos de prueba. Se crearon, de manera simulada, patrones de comportamiento (de múltiples tamaños) a partir de lo sugerido en Saleem y Rehmani (2014) y de acuerdo con la tabla 3.

Tabla 3. Casos de prueba para trazas de tráfico del usuario primario generadas mediante simulación

Identificador	Caso de prueba	Descripción
CP1	$i \% 2 == 0$	Corresponde a un histórico cuyas unidades de tiempo pares presentan una ocupación del canal.
CP2	$i \% 5 != 0$	Corresponde a un histórico cuyas unidades de tiempo que no sean múltiplos de 5 presentan una ocupación del canal.
CP3	$i \% 3 == 0$	Corresponde a un histórico cuyas unidades de tiempo que sean múltiplos de 3 presentan una ocupación del canal.


Identificador	Caso de prueba	Descripción
CP4	$i \% 3 == 0$ and $i \% 2 == 0$	Corresponde a un histórico cuyas unidades de tiempo que sean múltiplos de 3 y 2 presentan una ocupación del canal.
CP5	Aleatorio	Corresponde a un histórico en el que aleatoriamente se genera la ocupación del canal.

Fuente: elaboración propia.

A manera de descripción cualitativa, se presentan los resultados arrojados por el algoritmo LSTM al modelar y estimar el comportamiento futuro del usuario licenciado (para el caso CP1) cuando se presenta una fluctuación alta de presencia y ausencia en el canal licenciado (Saleem y Rehmani, 2014). La secuencia binaria que simula el uso del canal está formada por 77 datos; la figura 24 muestra la secuencia para los primeros 17 valores, distribuidos como 101010101010101, donde la presencia del PU se representa con 1, y la ausencia, con 0. La aplicación genera de manera adaptativa la estructura de red LSTM más adecuada para la secuencia de entrada (figura 25).


La etapa de aprendizaje (entrenamiento-modelamiento) se muestra en la figura 26, y se concluye que la red LSTM fue capaz de determinar en un 100% el patrón que sigue la secuencia de uso del canal.

Figura 24. Representación del comportamiento histórico para 77 muestras



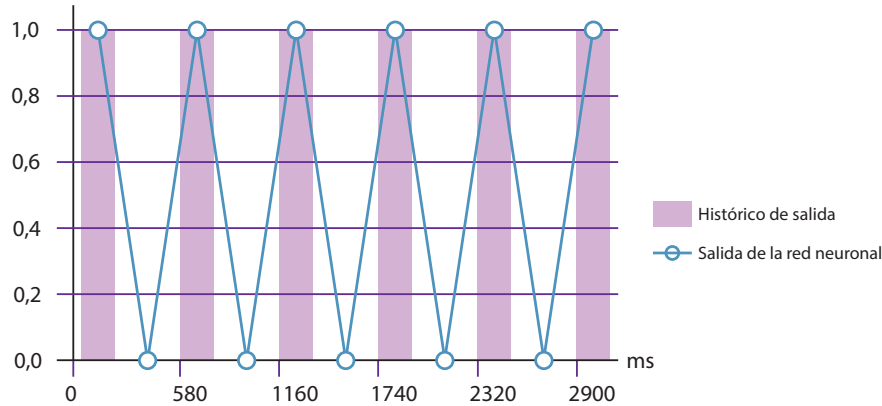
Fuente: elaboración propia.

Figura 25. Topología de la red neuronal



Fuente: elaboración propia.

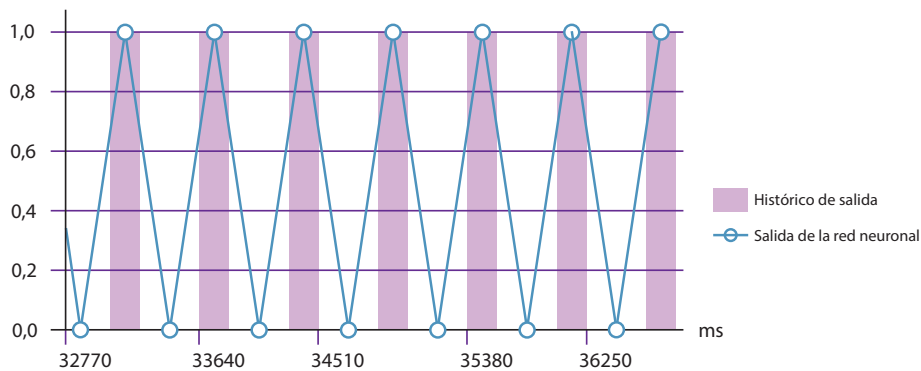
Figura 26. Resultados de la etapa de entrenamiento (fase de aprendizaje de la red)



Fuente: elaboración propia.

De la estimación futura (proyección de la predicción) entregada por la red neuronal se puede destacar que el nivel de acierto entre la señal original (secuencia morada) y la proyectada por el sistema (líneas azules) es del 100 %, lo que indica que el error de predicción es del 0 %, es decir, que el sistema neuronal es muy eficiente para el caso evaluado (figura 27).

Figura 27. Resultados de la predicción



Fuente: elaboración propia.

Los resultados cuantitativos para los diferentes casos planteados en la tabla 3 se presentan en la tabla 4.

Las métricas de evaluación de desempeño se refieren a valores promedio, pues se crearon históricos de múltiples tamaños (17, 35, 77, 157 y 200 datos binarios) aplicando diez pruebas para cada caso, debido a que se pueden obtener diferentes soluciones por cada ejecución del algoritmo.

Tabla 4. Desempeño de la red LSTM en la caracterización de usuarios primarios

LSTM				
Caso de prueba	Porcentaje de error de validación promedio	Porcentaje de error de predicción promedio	Número de iteraciones	Tiempo de procesamiento (ms)
CP1	0,0875830	0	1352	54,8
CP2	0,0936039	20,0465950	1422	75,6
CP3	0,8194522	28,9938556	5030	549,1
CP4	0,7566375	15,8806964	3757	820,4
CP5	0,7981350	37,4858167	17.402	6758,6

Fuente: elaboración propia.

Tabla 5. Desempeño de la red MLPNN en la caracterización de usuarios primarios

MLPNN				
Caso de prueba	Porcentaje de error de validación promedio	Porcentaje de error de predicción promedio	Número de iteraciones	Tiempo de procesamiento (ms)
CP1	0,049945930	0	1594	78,9
CP2	0,068684850	24,9820789	4314	244,1
CP3	0,105482774	37,6014337	5491	517,2
CP4	0,882621500	20,8151562	4702	943,1
CP5	0,504369700	52,6732207	5139	2263,5

Fuente: elaboración propia.

La validación del algoritmo LSTM se hizo evaluando las mismas métricas bajo idénticas consideraciones, pero haciendo uso de una red neuronal tipo perceptrón multicapa piramidal (tabla 5), y posteriormente se comparó con Anfis (tablas 6 y 7).

Del análisis de las tablas 4 y 5 se observa que el error de predicción promedio en LSTM varía entre el 0 y el 37,48%, lo que ubica el nivel de pronóstico por encima del 62,50% en el peor de los casos (CP5), porcentaje que además es superior al encontrado con MLPNN (47,33%). Esto indica que LSTM logró generalizar el comportamiento de los diferentes patrones presentados y logró predecir adecuadamente el comportamiento del PU en cualquier instante de tiempo t mientras el PU siga teniendo el mismo comportamiento. Otra característica importante es que, a pesar de que LSTM posee en su estructura más neuronas que MLPNN, en los casos CP1-CP4 requirió de menos iteraciones, lo que demuestra que la complejidad en la estructura LSTM permite abstraer el patrón de comportamiento de la señal PU a un menor costo computacional cuando la matriz usada como histórico es de longitud pequeña. Finalmente, el error de validación promedio corresponde a un valor muy pequeño para ambos tipos de red neuronal, condición que garantiza poder llegar a modelar la red de manera óptima.

Segundo grupo de casos de prueba. Para demostrar la viabilidad del algoritmo propuesto con trazas de tráfico reales tipo GSM y Wi-Fi, se definió la métrica llamada *índice de ocupación* (Io) —ecuación (87)— para dividir el nivel de uso de las bandas espectrales en índice de ocupación alto, índice de ocupación medio e índice de ocupación bajo, con lo que se logró una apreciación más objetiva y detallada.

$$Io = \frac{\sum_{x=0}^n t(x)}{n} 100\% \quad (87),$$

Tabla 6. Rendimiento del algoritmo para flujos GSM

Métrica	LSTM			MLPNN			Anfis		
	Ocupación alta	Ocupación media	Ocupación baja	Ocupación alta	Ocupación media	Ocupación baja	Ocupación alta	Ocupación media	Ocupación baja
Número de iteraciones	5000	5000	5000	5000	5000	5000	5000	5000	5000
Error de entrenamiento	0,4969	0,3711	0,1091	0,5163	0,3866	0,1485	0,507	0,37710	0,1295
Tiempo de procesamiento (ms)	7.527.099	7.395.395	7.472.671	1.735.304	1.665.314	1.630.825	4.279.211	4.011.087	3.997.590
Coefficiente de correlación	0,77	0,85	0,94	0,62	0,70	0,78	0,65	0,74	0,82
Porcentaje de error de validación	20,21	12,52	3,35	21,71	14,02	4,85	20,68	13,54	3,99
Porcentaje de error de predicción	22,86	12,20	2,91	24,36	13,70	4,41	23,44	12,82	3,70

Fuente: elaboración propia.

Tabla 7. Rendimiento del algoritmo para flujos Wi-Fi

Métrica	LSTM			MLPNN			Anfis		
	Ocupación alta	Ocupación media	Ocupación baja	Ocupación alta	Ocupación media	Ocupación baja	Ocupación alta	Ocupación media	Ocupación baja
Número de iteraciones	5000	5000	5000	5000	5000	5000	5000	5000	5000
Error de entrenamiento	0,7017	0,5520	0,3091	0,7970	0,5602	0,3588	0,7411	0,5587	0,3274
Tiempo de procesamiento (ms)	6.777.423	6.830.459	6.700.412	1.454.489	1.493.626	1.400.650	4.092.147	3.896.192	3.701.767
Coefficiente de correlación	0,62	0,75	0,85	0,43	0,65	0,73	0,51	0,67	0,78
Porcentaje de error de validación	38,35	21,49	10,23	41,51	23,02	11,28	39,27	22,06	10,74
Porcentaje de error de predicción	36,18	22,16	12,75	48,14	24,59	16,88	44,14	23,12	14,88

Fuente: elaboración propia.

donde $t(x)$ corresponde a los flujos de datos discretizados y n es el número de elementos en $t(x)$. Las salidas obtenidas se resumen en las tablas 6 y 7, teniendo en cuenta, primero, que para alimentar el sistema se usó un tamaño de traza de 20.00 datos para cada una de las tres bandas de frecuencia seleccionadas (de acuerdo con su índice de ocupación), y segundo, que se aplicaron diez pruebas para cada caso.


La evaluación de las métricas en cada caso sugiere que el tiempo de procesamiento es superior en LSTM, debido al mayor tamaño de las trazas y a que este tipo de red recurrente utiliza celdas de memoria para almacenar información de patrones encontrados que podrían ser reutilizados más adelante. Esta capacidad de almacenamiento y olvido de patrones afecta directamente la variable “error de validación”, que es mucho mejor en LSTM que en MLPNN.

Se puede observar que el “error de entrenamiento” es menor en LSTM, lo que se sustenta en su mayor capacidad para el reconocimiento de patrones gracias a la utilización de las compuertas de olvido, entrada y salida y a la celda de memoria.

Desde el punto de vista del porcentaje de acierto, con LSTM los valores oscilan entre el 97,09% (para un I_o bajo) y el 77,14% (para un I_o alto) en sistemas GSM, y entre el 87,25% (para un I_o bajo) y el 63,82% (para un I_o alto) en Wi-Fi, por lo que LSTM es más eficiente que MLPNN; no obstante, es importante destacar que esta mayor eficiencia lleva consigo una mayor necesidad de requerimientos en el *hardware*, factor que no es relevante si el sistema de predicción se implementa en CRN con topología centralizada.

Al examinar los porcentajes de acierto en las predicciones de aparición/no aparición de PU en las bandas espectrales (figura 28), para los índices de ocupación definidos en las tablas 6 y 7, y tomando como referencia los algoritmos que mejor rendimiento presentaron, se deduce que con LSTM se obtiene un promedio de éxito en la predicción del 87,34% en GSM y del 76,30% en Wi-Fi, en tanto que con Anfis se logró una eficiencia del 86,68% en GSM y del 72,62% en Wi-Fi.

También se puede observar una tendencia lineal decreciente y con mayor pendiente en los pronósticos a medida que la ocupación espectral aumenta, debido a una mayor intermitencia aleatoria en el uso del espectro, así como un mejor desempeño en la caracterización de PU (para las tres metodologías: LSTM, MLPNN y Anfis) en la banda espectral GSM, debido probablemente a la naturaleza más caótica presentada en los flujos Wi-Fi.

Figura 28. Porcentaje de acierto en la predicción para LSTM y Anfis

Fuente: elaboración propia.

Discusión

Dentro del área de la inteligencia artificial, las redes neuronales han tenido una amplia aplicación en series temporales dada su capacidad de predicción sobre unidades de tiempo desconocidas y debido a su capacidad de ser entrenadas por medio de ejemplos para abstraer un comportamiento, a diferencia de otras técnicas de inteligencia artificial que lo obtienen de un experto mediante la representación de variables relevantes para la solución del problema.

Una de las metodologías de aprendizaje supervisado más usadas en la caracterización de PU son las redes neuronales multicapa, pues con estas se puede llegar a obtener una mejora en la eficiencia de hasta el 60% en la predicción, según concluyen Adeel et al. (2014) (aunque en las pruebas realizadas por ellos se alcanzaron porcentajes más altos); sin embargo, recientemente se ha venido proponiendo la utilización de técnicas basadas en *deep learning* por su alto nivel de abstracción (Kalkan, 2018) para la solución de múltiples problemas, lo que representa una razón de peso para proponer su utilización en radio cognitiva (CR) (Gers y Schmidhuber, 2001; Palangi et al., 2016; Sun et al., 2016; Sundermeyer et al., 2015).

Del análisis realizado se evidencia que, si bien LSTM presenta mayor capacidad de predicción, aún posee un error importante en la estimación para aquellos casos en los que el comportamiento de los PU es caótico; sin embargo, obtener un error cercano a cero es una tarea difícil debido a la naturaleza de las señales, condición que puede sustentarse desde el punto de vista de la entropía. En la ecuación (88) (Abramson, 1981), cuando la entropía es 1, existe una probabilidad de ocupación de la banda

espectral del 50 % en cualquier instante de tiempo, lo que genera un nivel de incertidumbre alto en el momento de realizar estimaciones de ocupación del canal; situación contraria se presenta cuando su valor tiende a cero (condición más favorable).

$$E_s = \sum_{i=0}^n p(x_i) * \log_2 \left(\frac{1}{p_{x_i}} \right) \quad (88),$$

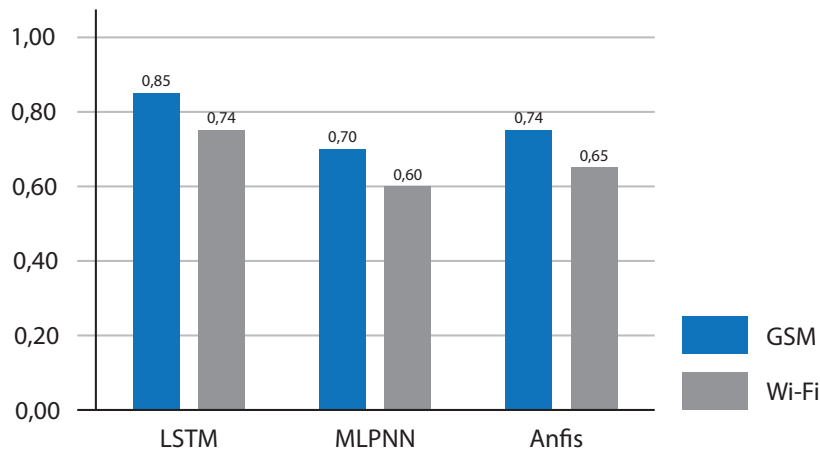
donde $p(x_i)$ corresponde a la probabilidad de aparición del carácter x_i y n es el número de caracteres.

Al calcular, por ejemplo, el valor de la entropía en GSM con LSTM, se encuentra que, para los índices de ocupación alto, medio y bajo, se obtienen valores de 0,7317737, 0,5529701 y 0,1979427, respectivamente, en coherencia con los errores de predicción de la tabla 3. Por otra parte, los históricos de datos arrojan indicios de cómo será el comportamiento de los PU, mas no garantizan que realmente se repita; sin embargo, el hecho de tener un indicio del posible comportamiento del PU le permite a la BS de una red cognitiva estar preparada para tomar acciones sobre la posible asignación de una banda frecuencial a un SU.

Un indicador adicional que permite verificar cuál es el mejor modelo entre los algoritmos LSTM, MLPNN y Anfis es el coeficiente de correlación (obtenido del promedio de los valores de la variable I_o) de las tablas 6 y 7 y la figura 29: su valor cercano a 1, en el caso de LSTM, permite concluir que ese es el mejor modelo de los tres evaluados.

Un aporte final de la aplicación desarrollada (para el algoritmo LSTM) es su capacidad de crear automáticamente la estructura neuronal según el tamaño de la traza que se pretenda caracterizar; esto representa un acierto ya que no se requieren esfuerzos adicionales en la construcción de la topología al modificar el comportamiento de los datos de entrada, como sí sucede, por ejemplo, en Adeel et al. (2014) y en Winston et al. (2013).

Figura 29. Coeficiente de correlación en la etapa de entrenamiento (modelamiento)



Fuente: elaboración propia.

Caracterización del usuario primario con un modelo neurodifuso: Anfis-grid-FCM

Procesamiento de la información espectral

Para la captura de los datos se seleccionaron, como objetivo principal, las comunicaciones celulares (GSM), y con el fin de realizar un mejor aprovechamiento de la información, se procedió a obtener el promedio de los niveles de potencia que existían en cada banda (tabla 8) para construir o generar la señal analógica final, que representaría el comportamiento del PU en cada espectro.


Tabla 8. Nivel de potencia final, que representa la presencia o ausencia de un usuario primario

Medición	Banda 1	Banda 2	Banda 3	Promedio
1	-95,5933	-96,7638	-104,8880	-99,0817
2	-88,8808	-93,1084	-93,4447	-91,8113
3	-93,3937	-94,1699	-105,4508	-97,6715
4	-105,4927	-104,0746	-93,5037	-101,0237
5	-90,3791	-95,7670	-97,9036	-94,6832
6	-109,0864	-94,5978	-106,2340	-103,3061
7	-89,1763	-95,6988	-90,5302	-91,8017

Fuente: elaboración propia.

Una vez obtenida la muestra o señal para caracterizar, el algoritmo normaliza los datos para minimizar su variación ubicándolos en el intervalo de a 1 (figura 30).


Figura 30. Muestra de niveles de potencia del usuario primario normalizados



Fuente: elaboración propia.

Antes de realizar el entrenamiento de la red Anfis, se implementa un filtro de media móvil para suavizar las fluctuaciones de alta frecuencia o eliminar tendencias que se puedan considerar como ruido (figura 31).

Figura 31. Comparación entre la señal normalizada (superior) y la filtrada (inferior)



Fuente: elaboración propia.

Dicho filtro (y_T), representado en la ecuación (89), procesa el dato actual a partir de la consideración de las cuatro muestras anteriores .


$$y_T = \frac{1}{4}y_t + \frac{1}{4}y_{t-1} + \frac{1}{4}y_{t-2} + \frac{1}{4}y_{t-3} + \frac{1}{4}y_{t-4} \quad (89),$$

donde las constantes $a_n = \frac{1}{4}$ son los coeficientes del filtro de realimentación.

Funcionamiento del algoritmo

Las funciones de pertenencia de la capa 1, para el entrenamiento del modelo Anfis en el *software* Matlab, son como las mostradas en la figura 32, donde se tienen como entradas los universos $y(k-1)$, $y(k-2)$ y $y(k-3)$, cada uno de ellos con dos conjuntos sigmoidales (mf1, mf2), además de un universo de salida ($U(k)$), con los conjuntos lineales mf1, mf2, mf3, mf4, mf5 y mf6.

Figura 32. Sistema Anfis basado en el modelo Sugeno



Fuente: elaboración propia.

La estructura FIS (*fuzzy inference system*), encargada de especificar los parámetros del sistema para el aprendizaje del Anfis dentro de las simulaciones realizadas, surgió de la integración de los métodos Anfis-grid y Anfis-FCM, como se muestra en el diagrama de bloques del algoritmo de predicción de la figura 33.

El sistema propuesto inicia con la obtención de los datos de los canales; luego, genera una sola columna de datos que representa el promedio de los niveles de

potencia para cada banda espectral; seguidamente, halla el máximo y el mínimo de los valores de dicha columna y procede a realizar el normalizado de la señal y a aplicar el filtrado descrito en la ecuación (89), y por último, une los datos de entrada y salida (figura 33) en un arreglo de dos columnas en el que las entradas (Y) son divididas en 6 subgrupos, y las salidas (U), en 4 subgrupos, de acuerdo con las ecuaciones (90) y (91).

$$Y = \{y(k-1), y(k-2), y(k-3)\} \quad (90),$$

donde Y representa las muestras anteriores ($y(k-n)$) de la señal a estimar.

$$U = \{u(k-1), u(k-2), u(k-3), \dots, u(k-6)\} \quad (91),$$

donde U representa el universo de salida para los conjuntos lineales.

Luego, se genera una búsqueda secuencial a fin de crear tres grupos de datos (para no saturar con demasiada información el Anfis) de acuerdo con la forma dada en las ecuaciones (92)-(94):

$$\text{Grupo 1} = y(k-1), y(k-2), y(k-3) \quad (92);$$

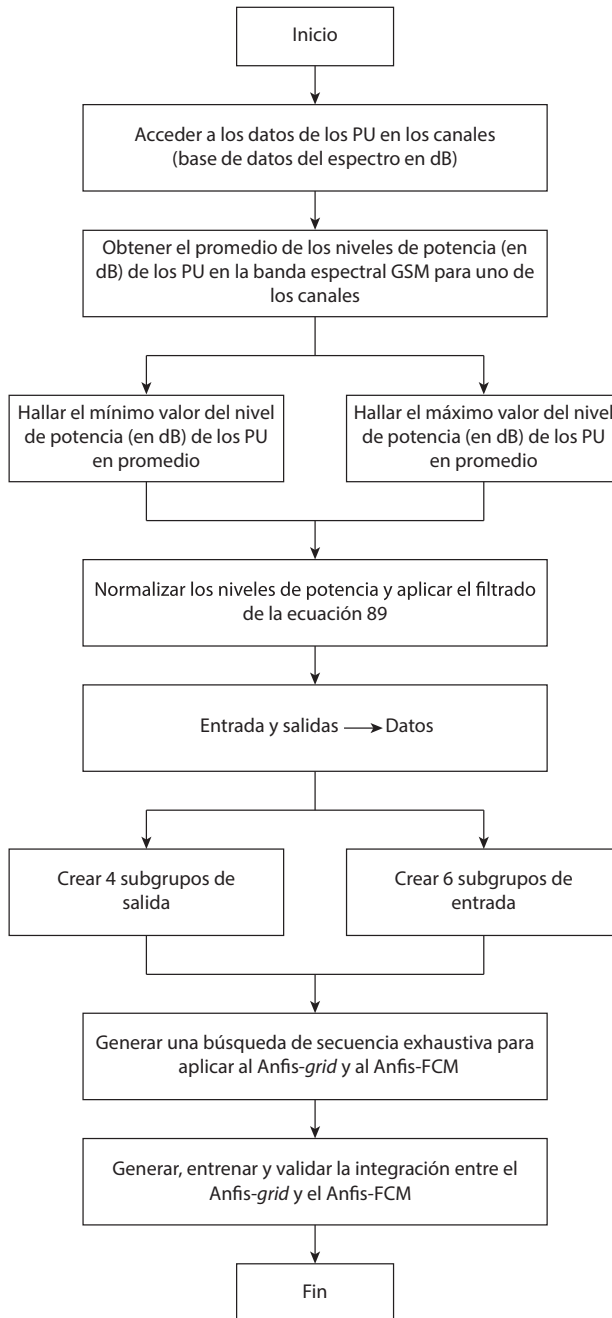
$$\text{Grupo 2} = y(k-1), y(k-2), y(k-3) \quad (93);$$

$$\text{Grupo 3} = u(k-2), \dots, u(k-6) \quad (94).$$

Adicionalmente, el algoritmo genera una búsqueda exhaustiva con el fin de determinar posibles patrones de aprendizaje que pudieran servir en la etapa de entrenamiento y aprendizaje del modelo. A partir de los datos recibidos en el paso anterior, se entrena y prueba el modelo, ajustando el número de funciones de pertenencia en Anfis-*grid* y la cantidad de clústeres en Anfis-FCM, hasta encontrar el menor error posible entre la salida deseada y la entregada por el algoritmo. La partición *grid* divide el espacio de datos en subespacios rectangulares con particiones paralelas basadas en el número y tipo predefinido de funciones de membresía (MF) (Abdulshahed et al., 2015), que son obtenidas con el método de estimación de mínimos cuadrados.

Cuando se diseñan o construyen las reglas difusas o *fuzzy*, los parámetros del consecuente en la MF (que son de salida lineal) se establecen como ceros; por lo tanto, es necesario identificar y perfeccionar estas variables utilizando Anfis (Abdulshahed et al., 2015), lo que genera el concepto Anfis-*grid* (Abonyi et al., 1999; Kennedy et al., 2003). La aplicación más amplia para las *grid partition* en los FIS tiene el inconveniente de que el número de reglas difusas aumenta exponencialmente cuando el número de variables de entrada aumenta (Neshat et al., 2011).

Figura 33. Diagrama de bloques del algoritmo de predicción de usuarios primarios con *Anfis-grid* y *Anfis-FCM*



Fuente: elaboración propia.

Anfis-FCM basa su funcionamiento en *fuzzy c-means* (FCM), que es una técnica de *clusterización* de información en la que cada uno de los datos pertenece a un clúster que es especificado mediante un grado de pertenencia (Valero Verdú y Senabre Blanes, 2013); este algoritmo fue planteado por Dunn en 1973 (Dunn, 1973). FCM es el modo difuso del algoritmo *K-means* y no considera límites definidos entre los clústeres (Jain, 2010; Velmurugan, 2014), lo que supone una ventaja, ya que puede asignar MF parciales a diferentes grupos del conjunto universal de clústeres en lugar de a un solo grupo (Abdulshahed et al., 2015). FCM está basado en la minimización de la función objetivo de la ecuación (95) (Fauzi bin Othman y Yau, 2007):

$$J_m = \sum_{i=1}^N \sum_{j=1}^c \mu_{ij}^m \|x_i - C_j\|^2; \quad 1 \leq m \leq \infty \quad (95),$$

donde m es cualquier número real mayor a 1, μ_{ij} es el grado de membresía de x_i en el clúster j , x_i es el i -ésimo término de los datos medidos, C_j es el j -ésimo término del clúster y $\|x_i - C_j\|$ es cualquier norma que exprese la similitud entre los datos medidos y el centro.

La división difusa se realiza a través de una optimización iterativa de la función objetivo mostrada en la ecuación (95), tomando como referencia la función de membresía μ_{ij} y los centros del clúster C_j en cada dimensión —ecuaciones (96) y (97)—. Cabe destacar que esta iteración en el algoritmo converge cuando el valor de J_m (que es la función objetivo) corresponde con lo establecido en la ecuación (95) (Fauzi bin Othman y Yau, 2007):

$$\mu_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{\|x_i - C_j\|}{\|x_i - C_k\|} \right)^{\frac{2}{m-1}}} \quad (96),$$

donde μ_{ij} representa la función de membresía, C_k es el i -ésimo término del clúster y $1 \leq m \leq \infty$.

$$C_j = \frac{\sum_{i=1}^N \mu_{ij}^m * x_j}{\sum_{i=1}^N \mu_{ij}^m} \quad (97),$$

donde C_j es el valor del j -ésimo clúster y x_j es el valor del j -ésimo dato medido.


Evaluación y análisis de resultados

Validación del modelo Anfis

La validación del sistema Anfis propuesto se realizó haciendo uso del *software* Matlab con un patrón de datos de 1000 muestras, de las cuales el 50% se usó en la etapa de entrenamiento, y el otro 50%, en la fase de validación (estimación de la predicción) para un canal espectral en la banda *uplink* GSM. En la fase de aprendizaje Anfis, los parámetros del antecedente y los del consecuente son entrenados con el algoritmo *backpropagation*, obteniendo la diferencia entre la sumatoria de los puntos a partir de los datos de entrada y la sumatoria de los puntos a partir de los datos entregados por el Anfis, y propagando el error desde las salidas hacia las entradas para ajustar las variables y disminuir el valor del error. La figura 34 muestra la comparación entre la secuencia usada para el entrenamiento y la calculada por el modelo; se observa que la etapa de entrenamiento es bastante acertada ya que es capaz de seguir el comportamiento caótico del PU en el canal, incluso para variaciones pequeñas de la señal.

Para determinar qué tan adecuado es el proceso de acierto en el entrenamiento, se utiliza la raíz del error cuadrático medio (RMSE) de la ecuación (98); esta métrica determina el desajuste entre el modelo y el comportamiento real de la señal (Salcedo, 2006; Soto et al., 2010), y representará un mejor comportamiento cuando su valor sea más cercano a cero.

Figura 34. Entrenamiento del usuario primario en un canal GSM (modelado) con Anfis-grid-FCM



Fuente: elaboración propia.

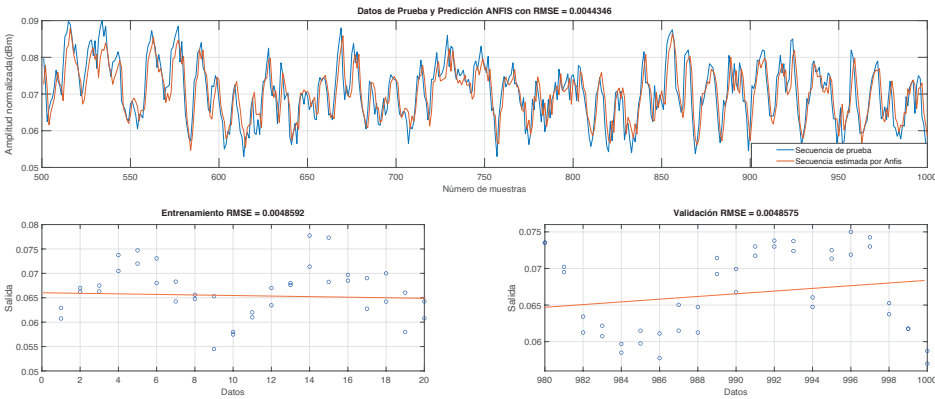
$$RMSE = \sqrt{\frac{\sum_{i=1}^n (d_i - O_i)^2}{n}} \quad (98),$$

donde d_i hace referencia al patrón de entrenamiento real dado, O_i corresponde a la respuesta entregada por el modelo Anfis y n es la cantidad de datos.

El valor óptimo encontrado para la variable RMSE (que corresponde al de la figura 34) fue de 0,0042639, utilizando una función de activación tipo “gbellmf”, con un error que varía entre $-0,01$ y $+0,15$, parámetro que indica una diferencia y variación mínima entre los datos de entrenamiento deseados y los obtenidos por el algoritmo, lo que permite inferir que el sistema es un buen estimador para describir y pronosticar señales de PU continuas en bandas GSM.

La etapa de validación se aprecia en la parte superior de figura 35, donde se compara la secuencia de verificación que se desea alcanzar para 500 muestras con la calculada por Anfis-grid-FCM: se obtuvo un valor RMSE de 0,004451.

Figura 35. Validación del modelo Anfis-grid-FCM estimando una predicción futura de comportamiento del usuario primario para 500 datos




Fuente: elaboración propia.

Al analizar la dispersión para los primeros 20 datos de entrenamiento, se encuentra que es de aproximadamente 0,001, y para los últimos 20 datos de validación es de 0,0033, valor que, aunque un poco más elevado, permite concluir que la predicción estimada es muy cercana a los datos de prueba; esta condición puede ser corroborada por la cercanía mostrada entre los puntos de las gráficas de dispersión ubicadas en la parte inferior de la figura 35.

Evaluación de desempeño del algoritmo Anfis-grid-FCM

Se valida el sistema propuesto al compararlo con la técnica LSTM para las métricas de juicio RMSE, precisión en la predicción, coeficiente de correlación y tiempo de cómputo. La respuesta del algoritmo LSTM para el mismo comportamiento de entrada del PU durante el entrenamiento y la validación es la obtenida en las figuras 36 y 37 y en la tabla 9.

Figura 36. Entrenamiento del comportamiento del usuario primario en un canal GSM (modelado) con LSTM



Fuente: elaboración propia.

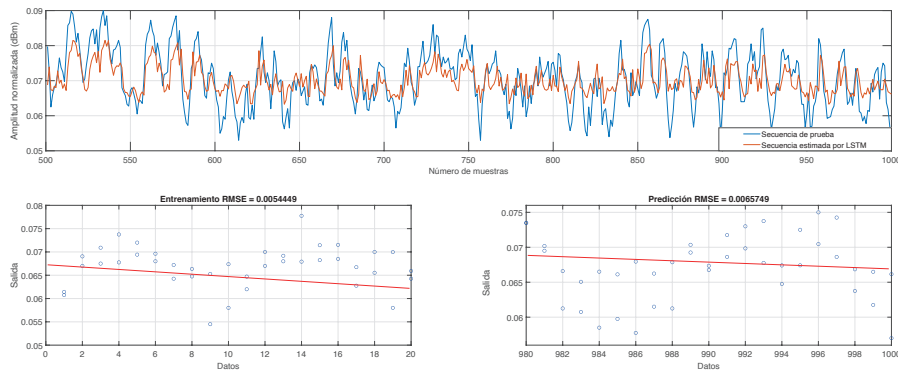
Tabla 9. Resultados encontrados con LSTM

Métrica	Etapas de entrenamiento (modelamiento)	Etapas de validación (predicción)
RMSE	0,0058962	0,0056982
Variación del error	-0,019 y +0,018	-0,0185 y +0,015
Dispersión de los datos	0,010	0,018

Fuente: elaboración propia.

El análisis de las salidas entregadas por Anfis y LSTM parte de los resultados almacenados en las bases de datos de entrenamiento y prueba que están resumidos en la tabla 10. Puede observarse que los valores de entrenamiento son mejores que los de prueba, a excepción de la métrica que identifica el tiempo necesario para la ejecución de los modelos, que es menor en la etapa de prueba, debido a que el grado de ajuste de parámetros para disminuir el error entre la salida deseada y la entregada por los algoritmos es aplicado en la fase de aprendizaje.

Figura 37. Validación del sistema LSTM estimando una predicción futura de comportamiento del usuario primario para 50 datos



Fuente: elaboración propia.

Tabla 10. Resultados estadísticos de los sistemas Anfis y LSTM

Métrica de evaluación	Datos de entrenamiento		Datos de validación	
	Anfis	LSTM	Anfis	LSTM
RMSE	0,0042639	0,0044510	0,0058962	0,0056982
Porcentaje de precisión en la predicción	93,67	72,88	93,94	72,17
Coefficiente de correlación	0,94	0,71	0,91	0,68
Costo computacional (s)	32,97	17,54	3,22	1,31

Fuente: elaboración propia.

Si bien es cierto que el tiempo necesario para el entrenamiento y prueba en Anfis representa un 52,086 % más que en LSTM, la exactitud en la predicción del estado de ocupación del canal es mucho más acertada en Anfis-grid-FCM, con un valor del 93,94 %, lo que implica una menor probabilidad de colisiones entre el PU y el posible nodo cognitivo candidato a utilizar el espectro licenciado disponible. También se debe notar que el comportamiento de la variable *precisión en la predicción* presenta un desempeño ligeramente mejor en el entrenamiento al compararse con los valores encontrados en la fase de prueba, pero se destaca, igualmente que ni Anfis-grid-FCM ni LSTM son capaces de reducir a cero el error en el aprendizaje.

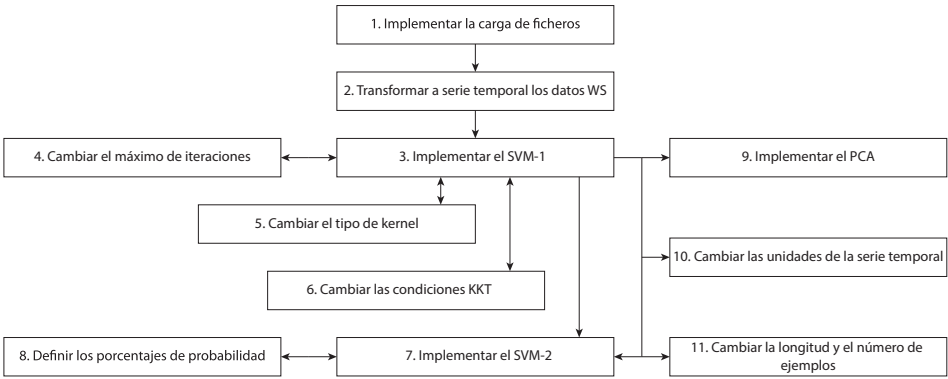
Tomando como referencia las métricas RMSE y el coeficiente de correlación, se concluye que tienen una tendencia similar, pero ligeramente mejor en Anfis, lo que indica que, desde el punto de vista de la obtención de mejores pronósticos, es la opción más adecuada.

En síntesis, al comparar los resultados de forma global, se llega a la conclusión de que el método *Anfis-grid*-FCM es más adecuado que LSTM (para este caso particular) si dentro del sistema de radio cognitiva no es tolerable la existencia de posibles colisiones entre los PU y los SU cuando coexistan simultáneamente dentro de la red inalámbrica; no obstante, la gran ventaja de LSTM es que la robustez del *hardware* necesaria para la implementación sería mucho menor que la requerida por *Anfis*.

Caracterización del usuario primario con SVM

En este apartado se exponen los resultados obtenidos al usar dos clasificadores basados en SVM para realizar la caracterización en redes Wi-Fi a partir de la emisión/no emisión de datos en el canal 6 (banda de 2,437 GHz). La figura 38 muestra las actividades de aplicación realizadas para caracterizar el uso o no del espectro. Inicialmente, se genera una serie temporal a partir de los datos de emisión de una red Wi-Fi, para lo cual se usa el programa *Acrylic*, que devuelve una lista de datos con la fecha, la hora, el minuto y el segundo de emisión o uso del canal por parte del PU (información conocida a partir de ahora como *timestamp*) y su longitud; con estos datos, se implementa un módulo para cargar el fichero generado con *Acrylic* (punto 1). Seguidamente, se crea otro módulo para convertir la información en una serie temporal que representa la emisión/no emisión para cada *slot* de tiempo (punto 2). Esta serie temporal se asume como el resultado en un entorno real de una radio cognitiva monitorizada, y sobre ella, que representa los valores de emisión (presencia/ausencia) del PU, se integran dos SVM: uno, generado con la *toolbox* de Matlab (SVM Matlab, desde ahora llamado *SVM-1*) (punto 3), y otro, de código libre (LibSVM, desde ahora llamado *SVM-2*) (punto 7) (Chang y Lin, 2013).

Figura 38. Diagrama de bloques del sistema de caracterización con SVM



Fuente: elaboración propia.

Primero, se integra el SVM-1 (punto 3) y se evalúa el comportamiento para estimar el uso del canal variando múltiples características del sistema: el número de iteraciones (punto 4), el tipo de kernel (punto 5), las condiciones KKT (Karush-Kuhn-Tucker) (punto 6) (Krogstad, 2012), las características de los datos capturados a través del uso del PCA (*principal component analysis*) (punto 9), las unidades de medida de la serie temporal (punto 10) y la longitud y el número de ejemplos (punto 11).

Posteriormente, se utiliza el SVM-2 (punto 7) evaluando su nivel de predicción a través del uso de PCA (punto 9) y variando las unidades de medida de la serie temporal (punto 10) y la longitud y el número de ejemplos (punto 11); también se ha implementado la posibilidad de variar los porcentajes de probabilidad (punto 8), parámetro con el cual se pretende que el predictor devuelva valores cercanos a 1 cuando el último instante de tiempo monitorizado es de emisión, y cercanos a 0 cuando es de no emisión, independientemente de la lejanía del instante en que se prediga la señal real.

Consideraciones previas de los SVM como clasificadores en radio cognitiva

Los SVM son algoritmos de aprendizaje supervisado que requieren un entrenamiento (fase de modelamiento de los PU) con un conjunto de ejemplos antes de que se puedan aplicar para clasificar muestras (predicción de PU). Cada ejemplo tiene unas características muy bien definidas (en el caso de los PU, corresponden a los valores de emisión en los tiempos anteriores a la predicción) y un valor que define la clase, en este caso binario (1, si hay presencia del PU, y 0, si no la hay). La clase es la que se predice a partir de las características. Las características suelen ser distintas mediciones o valores que definen el ejemplo. En la fase de aprendizaje (modelamiento) se introducen las características (valores anteriores de presencia o ausencia de los PU) y

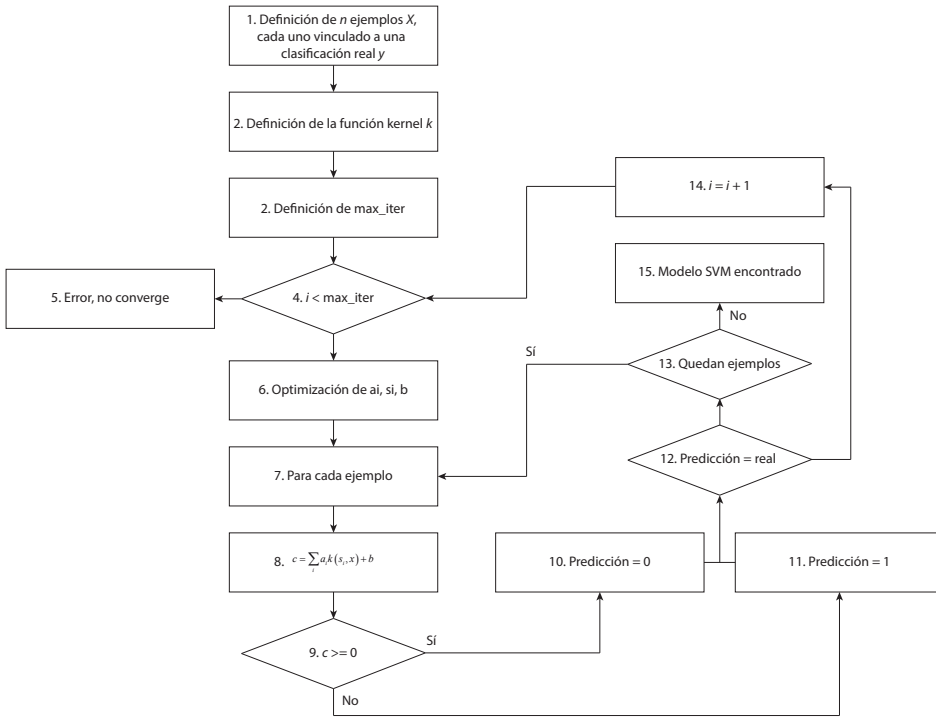
la clase (el estado actual de emisión o no emisión), y el SVM busca una solución para diferenciar los ejemplos según su clase. En la fase de test (comprobación del índice de acierto de la predicción) se introducen las características de distintos ejemplos en el SVM ya entrenado, y el clasificador devuelve una clase (1 o 0). Para cada ejemplo, esta clase que devuelve el clasificador se compara con el dato real para comprobar el índice de acierto. Una vez se consiguen resultados de test satisfactorios, se puede utilizar el SVM para clasificar ejemplos (predecir los PU).

Los SVM tienen como principal propiedad la creación de un hiperplano o conjunto de hiperplanos de dimensionalidad mayor a la que ofrecen los ejemplos de entrada, y de este modo la posibilidad de separación de clases aumenta radicalmente. Los SVM se encargan de buscar el hiperplano con mayor distancia entre los ejemplos de una clase y otra. La manera más adecuada de realizar la separación es mediante una línea recta, un plano recto o un hiperplano N-dimensional. A veces, un algoritmo SVM debe tratar con más de dos variables —curvas no lineales de separación—, casos en los que los conjuntos de datos no pueden ser completamente separados en más de dos categorías. Las funciones kernel ofrecen una solución a este problema, proyectando la información a un espacio de características de mayor dimensión, y especifican cómo se crean estos espacios de dimensionalidad mayor a partir de las dimensiones originales. Normalmente, los SVM se utilizan para problemas de regresión y de clasificación, pero rara vez para predicción de series temporales. Para aplicar SVM a la caracterización de radios cognitivas, que se muestran como una serie discreta, se extrae una serie temporal de n *timestamps*, cada uno de los cuales representa emisión (1) o no emisión (0). Los primeros $n-1$ *timestamps* se utilizan como características del ejemplo, y el *timestamp* n (que es la clase), como el valor que se predice.

Diagrama secuencial del SVM-1

El primer algoritmo utilizado se soporta en el existente en las librerías propias de Matlab. La figura 39 presenta el diagrama de flujo resumido de cómo implementarlo y aplicarlo para la predicción de futuros patrones de comportamiento. Primero, se define un conjunto de ejemplos (punto 1) para representar las series temporales que definen los valores de emisión y no emisión de un PU para un intervalo de tiempo determinado y pasado. El conjunto de estos ejemplos caracteriza al PU usando el formato que requiere SVM.

Figura 39. Diagrama de flujo del primer algoritmo SVM-1



Fuente: elaboración propia a partir de Matlab.

Seguidamente, se define la función kernel (punto 2); en caso de un kernel lineal, k es el producto escalar. El módulo SVM usa un método de optimización para identificar los vectores de soporte s_i , los pesos a_i y el bias b . Estos valores no representan nada propio en CR, sino que son propios del clasificador SVM y ayudan a generar dos conjuntos diferenciables de datos: uno para emisión y otro para no emisión. Esta optimización se repite si no se hallan valores válidos hasta un máximo de iteraciones (max_iter) definido externamente a la aplicación del *software* desarrollado (punto 3). Por cada iteración, se debe hacer lo siguiente (punto 4):

- Calcular los vectores de soporte s_i , los pesos a_i y el bias b .
- Para cada ejemplo x de los creados en el punto 1 (punto 7):
 - Se calcula la predicción con la ecuación (99) (punto 8):

$$c = \sum_i a_i k(s_i, x) + b \quad (99).^1$$

1 Cabe destacar que cada una de las variables de la ecuación fue previamente definida en este mismo capítulo.

- Se obtiene la clase de la predicción analizando el valor c (punto 9): si c es positivo o cero, la clase es 0 (punto 10), y si c es negativo, la predicción es 1 (punto 11).
- El algoritmo comprueba la predicción con la clasificación real del ejemplo (punto 12): si coinciden, se pasa al siguiente ejemplo (punto 13), y si no, se suma 1 al número de iteraciones (punto 14) y se vuelve al punto 4.

En caso de no quedar ejemplos o de haberlos clasificado todos correctamente (lo que es lo mismo), el módulo devuelve un modelo SVM (punto 15). Si se supera el máximo de iteraciones internas del módulo SVM, este devuelve un error indicando que no ha convergido el algoritmo, es decir, que no se ha encontrado un clasificador apto para este problema (punto 5). Para caracterizar CR, se define x como la característica de cada ejemplo. Se buscan los valores s , a_i y b de forma que se consiga un valor c negativo para todos los ejemplos de clase 1 y un valor c positivo para todos los ejemplos de clase 0. Posteriormente, con s , a_i y b definidos, al aplicar la función anterior a un ejemplo, el valor c define si el PU se encuentra o no en el canal. Si c es positivo o cero, la predicción es “no emisión”, y si c es negativo, la predicción es “emisión”.

Diagrama secuencial del SVM-2

El segundo algoritmo, modificado para modelar y predecir el uso del canal, está basado en Chang y Lin (2013). En la figura 40 se muestra el diagrama de flujo del algoritmo usado, donde se observa que primero se define un conjunto de n ejemplos que representan series temporales que definen los valores de emisión y no emisión para un intervalo de tiempo determinado. De este modo, cada una de las muestras se interpreta como ausencia/no ausencia del PU en un intervalo de tiempo pasado en la banda de frecuencia. Cada serie temporal consta de l valores de emisión (1 si hay emisión y -1 si no la hay), los cuales deben corresponder con cada x_i . La clase de dicho ejemplo es representado por y , que es el valor de presencia o ausencia en el instante de tiempo $l+1$ (punto 1). Es importante aclarar que $x_i \in R^n, i=1, \dots, l$; es decir, para el caso del PU, $x_i \in \{1, -1\}$ (punto 2) y $y_i \in \{1, -1\}, i=1, \dots, l$ (punto 3). En el punto 4 se declara el tipo de kernel que utilizará el algoritmo LibSVM; cada kernel establece el modo como se van a separar los conjuntos según su clase y . Las opciones son lineal, polinómico, sigmoidal y función de base radial. En este caso, se eligió un kernel lineal, que está dado por el producto escalar, ya que se concluyó (a partir de pruebas) que era el que mejor respuesta entregaba en el modelamiento de PU y el que menor costo computacional tenía. Matemáticamente —ecuación (100)—, el SVM-2 intenta resolver el problema de optimización relacionado por medio de la construcción de un hiperplano de separación en la SVM que minimice el valor de las sumas

de las desviaciones (ε_i) en los errores de entrenamiento y maximice el margen para los vectores correctamente clasificados en la caracterización de los PU (punto 5).

$$\min_{w,b,s} \quad \frac{1}{2} w^T w + c \sum_{i=1}^l \varepsilon_i \quad (100),$$

donde

$$\varepsilon_i \geq 0; i = 1, \dots, l, c > 0,$$

sujeto a:

$$y_i (w^T k(x_i) + b) \geq 1 - \varepsilon_i,$$

dónde w^T es una matriz que define los vectores de soporte, c es el parámetro de regularización, $k(x_i)$ es la función kernel y b es el bias. Estas variables generan dos conjuntos diferenciables de datos: uno para emisión y otro para no emisión. Como la matriz w puede tener una alta dimensionalidad, antes de resolver la ecuación, esta debe ser simplificada mediante una transformación matemática (Meerschaert, 2013) que se aplica para estos casos, es decir, para simplificar problemas de optimización de alta dimensionalidad. La simplificación se da en la ecuación (101) (punto 6 de la figura 40):

$$\min_{\alpha} \frac{1}{2} \alpha^T Q \alpha - e^T \alpha \quad (101),$$

sujeto a:

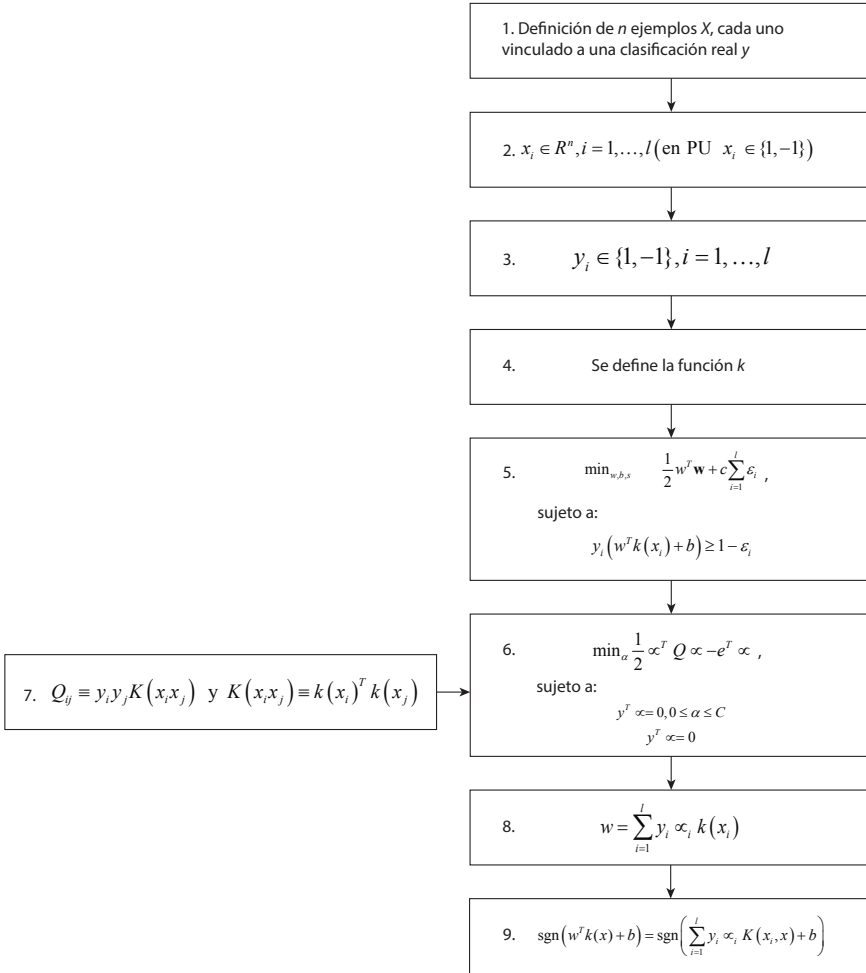
$$y^T \alpha = 0, 0 \leq \alpha \leq C$$

$$y^T \alpha = 0$$

$$0 \leq \alpha \leq C,$$

donde e es un vector de longitud n de ‘unos’; Q es una matriz $l \times l$ tal que $Q_{ij} = y_i y_j K(x_i, x_j)$ y $K(x_i, x_j) = k(x_i)^T k(x_j)$ (punto 7); Q_{ij} representa la relación de similitud entre dos ejemplos, teniendo en cuenta su clase o valor de predicción, y $K(x_i, x_j)$ representa la relación de similitud entre dos ejemplos. Se resuelven las condiciones para calcular α , la matriz de pesos, que define la importancia de cada una de las características.

Figura 40. Diagrama secuencial del segundo SVM propuesto para usuarios primarios



Fuente: elaboración propia a partir de Chang y Lin (2013).

La ecuación (102) calcula los vectores soporte para obtener el valor óptimo de w :

$$w = \sum_{i=1}^l y_i \alpha_i k(x_i) \quad (102),$$

donde $k(x_i)$ es el kernel aplicado sobre las características x_i de los ejemplos, y_i es la clase real del ejemplo (1 o -1) y α_i es el vector de pesos calculado en el punto 6.

Por último, la función de decisión para saber si un ejemplo tendrá emisión en el futuro es la mostrada en la ecuación (103):

$$\text{sgn}\left(w^T k(x) + b\right) = \text{sgn}\left(\sum_{i=1}^l y_i \varphi_i K(x_i, x) + b\right) \quad (103),$$

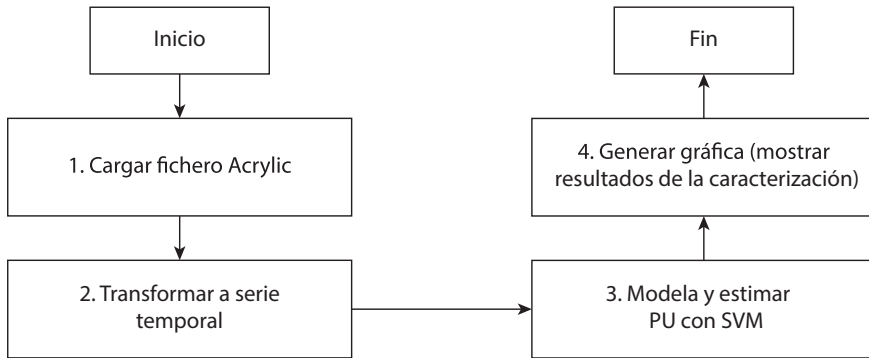
donde *sgn* hace referencia a la función signo.

Cabe destacar nuevamente que en la caracterización de PU se define x_i como las características de cada ejemplo (permitiendo solo los valores 1 o -1), e y_i , como la clase, siendo 1 para emisión y -1 para no emisión. La ecuación (103) calcula, en función de los datos introducidos, si el PU guarda más similitudes con los ejemplos que emiten en el futuro o con los que no emiten, y de este modo predice si hay o no presencia del PU. En síntesis, para caracterizar PU, se utilizan los valores w (vectores de soporte), φ_i (vector de pesos) y b (bias), calculados en el proceso descrito, para posteriormente usar la función de decisión con el fin de predecir el uso o no del canal.

Metodología de prueba de las SVM y procesamiento de los datos de entrada a los algoritmos

La metodología utilizada para evaluar y analizar el nivel de caracterización de cada SVM se basó en el desarrollo de una aplicación de *software* sobre Matlab que incluyó los cuatro principales módulos mostrados en la figura 41.

- Cargar fichero Acrylic: este módulo carga un fichero Acrylic en formato CSV y extrae para cada paquete su tiempo de inicio y su duración.
- Transformar la serie temporal.
- Modelar y estimar los PU con SVM: incluye generar los casos de entrenamiento, entrenar la SVM y crear los casos de test, predecir la serie temporal y devolver los casos de test reales, la predicción y el porcentaje de acierto.
- Generar la gráfica: en esta, el espacio bidimensional representa, en el eje de la variable independiente, el tiempo de predicción en milisegundos, siendo el 0 el primer instante estimado. Cuanto más aumenta el valor x , más lejana es la predicción.

Figura 41. Metodología seguida para estimar la ausencia o presencia de usuarios primarios

Fuente: elaboración propia.

Una vez capturados los datos de ocupación espectral, se procedió a realizar un pre-procesamiento de estos, con el objetivo de que fueran interpretados de manera correcta por las SVM. Esta etapa incluyó los puntos 1 y 2 de la figura 41. En la figura 42 se representa el diagrama de flujo del módulo encargado de extraer los datos del fichero generado por Acrylic y de convertirlos a milisegundos (punto 1).

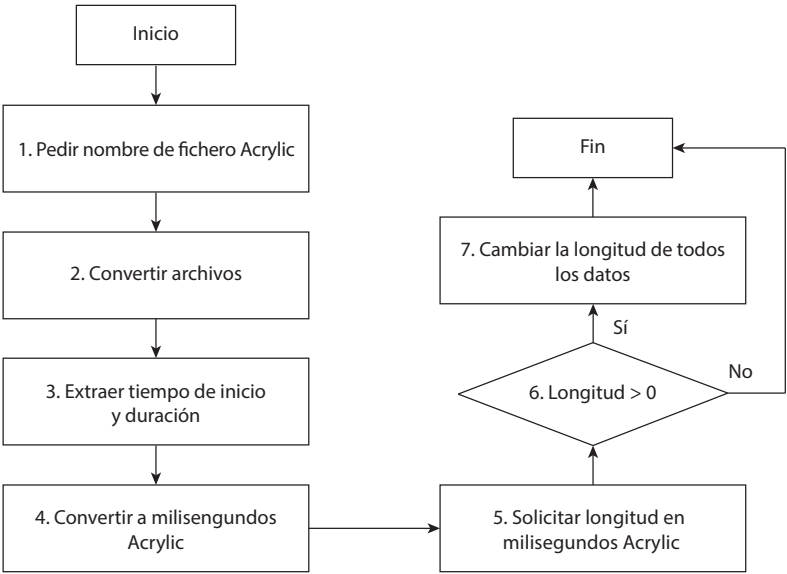
El punto 2 de la figura 42 es una acción que llama a la biblioteca externa, *csvimport* (Sadanandan, 2011). Esta librería lee archivos CSV y permite convertirlos en formato Matlab; no obstante, para que se amolde a la funcionalidad esperada, se le ha realizado una modificación que permite eliminar todas las comillas extraídas del CSV para permitir compatibilidad con los ficheros de salida del analizador de protocolos para distintas versiones del Acrylic.

Las fases 5-7 dan la posibilidad de elegir una duración fija en milisegundos (cualquier valor entre 0 y 500) de todos los estados del PU extraídos. Si el valor es 0, no se modifican las duraciones de las capturas, y su valor queda como aparece en el fichero original; si se elige un valor entre 1 y 500, la duración de todos los paquetes se cambiará al valor definido.

Para valores erróneos se volverá a solicitar un valor entre 0 y 500 ms. Se ha definido 1 ms como valor mínimo debido a que es el valor más bajo que permite el sistema de datos usado, y 500 ms como valor máximo con el fin de limitar el tiempo de procesamiento exigido al realizar el entrenamiento de la SVM.

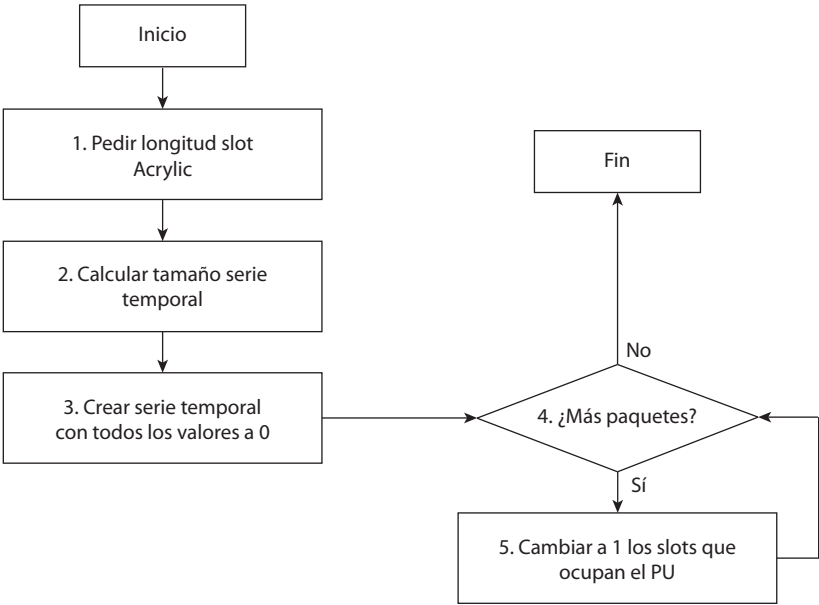
Obtenidos los datos, se transforman las capturas (figura 43) obtenidas mediante Acrylic a un formato válido que permita modelar y predecir, mediante SVM, una serie temporal de presencia/ausencia de PU en la banda de frecuencia seleccionada.

Figura 42. Diagrama de flujo del módulo encargado de extraer los datos del archivo capturado en Acrylic



Fuente: elaboración propia.

Figura 43. Procesamiento de las secuencias a series temporales



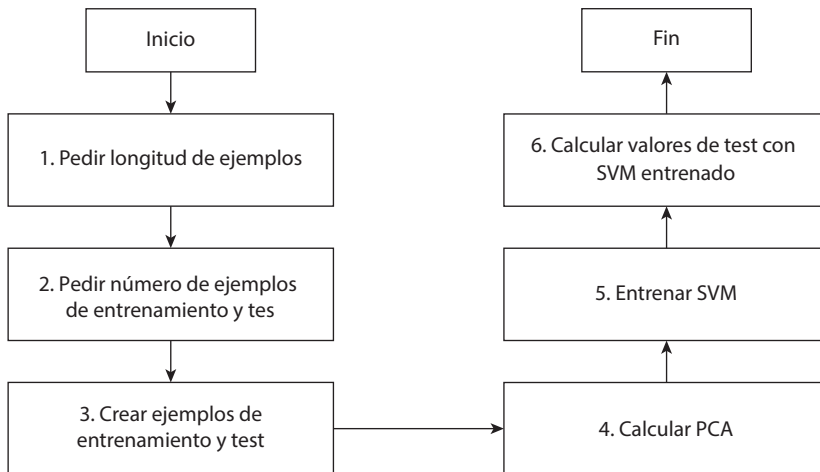
Fuente: elaboración propia.

Estimación de usuarios primarios con SVM

El modelamiento y predicción de PU en la red Wi-Fi incluyó la secuencia de pasos del diagrama de bloques de la figura 44.

Inicialmente, es necesario definir la longitud de los *slots* de ejemplos para el entrenamiento y test de las SVM (punto 1). Se decidió que este valor fuera un número entre 10 y 2000, en razón de que el tiempo ideal en el que hay cambios entre emisión y no emisión es de 1 s. Independientemente del segundo que se escoja en una serie temporal extraída con el analizador, suele haber un alto porcentaje de tiempos de emisión y no emisión; sin embargo, si se toman tiempos más pequeños, como 100 ms, por ejemplo, existe un muy alto porcentaje de probabilidad de que el fragmento escogido sea solo emisión o solo no emisión, lo cual no aporta información relevante.

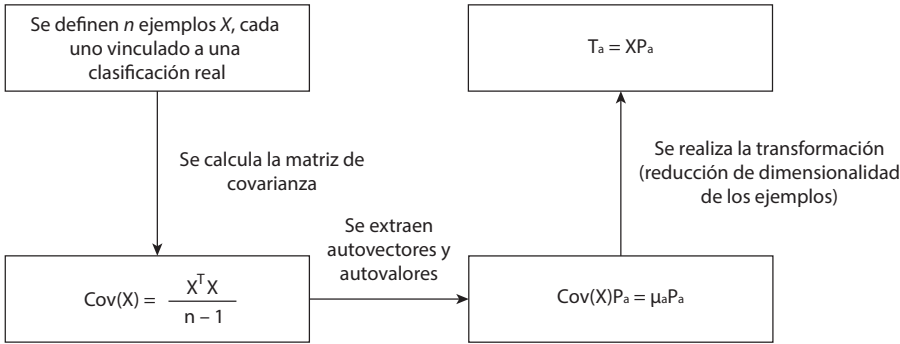
Figura 44. Secuencia de pasos para modelar y predecir usuarios primarios con SVM



Fuente: elaboración propia.

Seguidamente, se debió escoger el número de ejemplos de entrenamiento (muestras para modelar el PU) y test (número de predicciones que se realizarán), cuyo valor máximo fue de 1000, ya que elevar dicho valor implicaría tiempos de ejecución extremadamente altos (punto 2). Del punto 3 se extraen tantos ejemplos como se desee de una longitud definida sobre la serie temporal capturada de Acrylic. En el punto 4, el cálculo del PCA permite reducir la dimensionalidad de un conjunto de datos, mediante el hallazgo de las características que afectan su variabilidad, a través de una transformación lineal que incluye tanto la construcción de una matriz de covarianzas ($Cov(X)$) como la extracción de autovectores y autovalores, como se detalla en la figura 45 (Powell y Lehe, s.f.).

Figura 45. Compresión del volumen de datos para procesar en la etapa de entrenamiento y estimación del canal



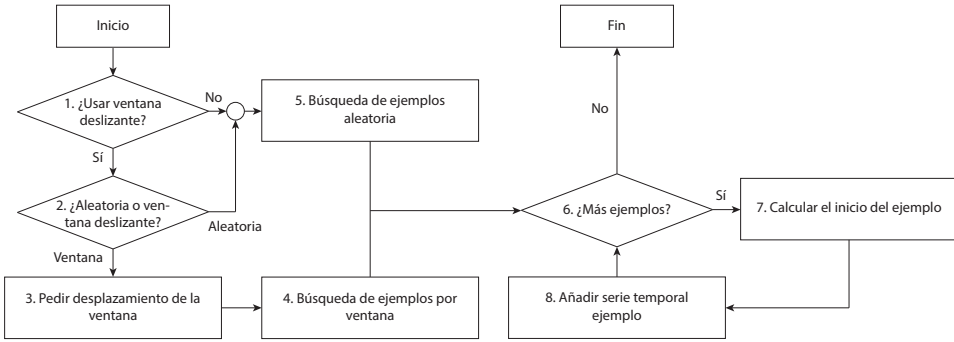
Fuente: elaboración propia.

La reducción de dimensionalidad aplicada sobre los ejemplos de series temporales de los PU hace que se tenga la misma información en menos volumen de datos, lo cual podría acelerar el proceso de caracterización y predicción de PU con SVM. Las etapas 5 y 6 de la figura 44 corresponden al modelamiento del uso histórico del canal (entrenamiento de la SVM) y al cálculo de la predicción o estimación futura de uso de la banda espectral por parte del usuario licenciado.

Las variables que definen los bloques de la figura 45 son: X : una matriz $(n * m)$; $X_{i,j}$: la característica j del ejemplo i ; n : el número de ejemplos; T_a : la matriz $n * l$, que representa las proyecciones de X en μ_a , y la cantidad de varianza capturada (μ_a) es el valor propio asociado a P_a (que determina la relación existente entre las variables).

La figura 46 expone de forma general el diagrama de flujo para crear los ejemplos que se modelan y predicen. Se puede sintetizar que, en función del número y la longitud de los ejemplos, se comprueba si se puede usar el concepto de *ventana deslizante* para la selección de la subserie temporal. Si $l + (l * (n - 1)) > L$, se puede usar la ventana deslizante, donde l es la longitud de los ejemplos, n es el número de ejemplos y L es la longitud de la serie temporal. En caso de que no se pueda utilizar, se usará el método aleatorio automáticamente para generar los ejemplos. Si se puede usar la ventana deslizante, se debe determinar qué método de selección de inicio de la subserie temporal para cada ejemplo se quiere usar. En caso de seleccionar la ventana deslizante, se calculan los posibles *offsets* que se pueden utilizar en función de la longitud de los ejemplos, el número de ejemplos y la longitud de la serie temporal, especificando un *offset* entre 1 y el máximo calculado por la aplicación.


Figura 46. Diagrama de flujo de creación de los ejemplos para modelar y estimar el uso del canal de un usuario primario



Fuente: elaboración propia.

Análisis de resultados del nivel de predicción con los algoritmos SVM-1 y SVM-2
 Como se mencionó anteriormente, los datos de Acrylic se transforman, en principio, a una serie temporal a partir de la aplicación desarrollada en Matlab (Petter, 2013), usando como unidad de tiempo los milisegundos. Cada paquete dura en transmitirse tantos milisegundos como su longitud en bytes o un número fijo de milisegundos. Como ejemplo de visualización, en la figura 47 se ve una serie temporal extraída del fichero usando como tiempo de emisión de paquetes su longitud. En azul se observan los momentos en los que el PU hace presencia en el canal, mientras que las zonas en blanco muestran los tiempos de no emisión o de desperdicio del BW disponible en el canal. La longitud total de la serie temporal es de 600.296 unidades de tiempo.

Figura 47. Comportamiento de un usuario primario en términos de emisión/no emisión para una canal en la banda Wi-Fi entregada por Acrylic



Fuente: elaboración propia.

SVM-1

Una vez entrenada la SVM, se llegó a la conclusión de que no convergía. Que no converja la SVM quiere decir que no llega a encontrar ninguna combinación de vectores de soporte s_i , pesos a_i y bias b que cumpla con el costo especificado y que, por tanto, encuentre un patrón que represente acertadamente el PU. Con el fin de mejorar el nivel de modelamiento de los PU, se probaron varias soluciones:

- Modificar la longitud de los ejemplos (de 10 a 2000) y el número de ejemplos (de 1000 a 100.000) para obtener más información de la forma de actuar del PU.
- Incrementar el número máximo de iteraciones de entrenamiento (de 15.000 a más de 2.000.000), lo que dispara el tiempo de ejecución del algoritmo.
- Cambiar el kernel del algoritmo de lineal (que busca un hiperplano lineal para separar los dos conjuntos de ejemplos) a polinómico de grado tres como hiperplano.
- Transformar las condiciones de KKT (Krogstad, 2012), que son necesarias y suficientes para que la solución de un problema de programación matemática (caracterización de PU) sea óptima. En el caso de la SVM implementada en Matlab, estas condiciones se aplicaron sobre el lagrangiano —ecuación (104)— para calcular el hiperplano de máxima separación.

$$L(x, \lambda) = f(x) + \sum \lambda_{g,i} g_i(x) + \sum \lambda_{h,i} h_i(x) \quad (104),$$

donde $f(x)$ es el kernel para optimizar, $g_i(x)$ es un vector de restricciones del tipo $g(x) \leq 0$, $h_i(x)$ es un vector de restricciones del tipo $h(x) = 0$, la primera sumatoria varía de acuerdo con $i=1, \dots, k$, y la segunda, para los valores de $j=1, \dots, m$. Los vectores $\lambda_{g,i}$ y $\lambda_{h,j}$ corresponden a los multiplicadores de Lagrange. Las condiciones KKT utilizadas por la SVM son las que se muestran en la ecuación (105):

$$\begin{aligned} \nabla_x L(x, \lambda) &= 0 \\ \lambda_{g,i} g_i(x) &= 0 \forall i \\ g(x) &\leq 0 \\ h(x) &= 0 \\ \lambda_{g,i} &\geq 0 \end{aligned} \quad (105).$$

Al modificar el margen de error de las condiciones KKT, se está permitiendo un margen de error en la ubicación del posible patrón de comportamiento del PU, lo que implica que el modelamiento se amolde menos a los datos reales:

- Se modificó el índice de violación de las condiciones KKT, que especifica la fracción del número de variables que se permite no cumplir: 0 implica que se han de cumplir todas las condiciones, y 1, que se puede no cumplir ninguna.
- Para encontrar el hiperplano, la SVM permite dos metodologías: la primera es la *sequential minimal optimization* (SMO), que basa su funcionamiento en los multiplicadores de Lagrange, y la segunda es el *quadratic programming* (QP), que es un sistema de optimización incluido en la licencia Optimization Toolbox™.

SVM-2

Se probó la realización del modelamiento del PU, para después realizar una predicción con el máximo número de ejemplos (100.000) y su máxima longitud (2000), de acuerdo con la aplicación desarrollada. La duración del entrenamiento fue de 2956 segundos y se obtuvo un resultado satisfactorio. Posteriormente, se experimentó calcular, para 1000 ejemplos, la predicción en el instante $l + 1$ (lo que corresponde a una estimación de rango corto), y el resultado de acierto fue del 100%:


Predicción SVM 1 de 1

Accuracy = 100 % (1000/1000) (classification)

Elapsed time is 12,3648261 seconds

En la figura 48 se encuentra gráficamente el ejemplo de predicción anterior (partiendo del hecho de que el modelamiento tuvo un 100% de acierto). Se debe mencionar también que, como la serie temporal predicha consta de un único valor, en vez de aparecer una línea, aparece un único punto. Además, la serie temporal real de envío de datos, que normalmente se muestra con una señal azul, al tratarse del mismo valor que la predicción, no aparece en este caso, pues la predicción en rojo se encuentra exactamente sobre el valor real. El eje de la variable independiente representa el tiempo de predicción en milisegundos, siendo el 1 el primer y único tiempo de predicción (el instante $l + 1$), y el eje de la variable dependiente, por su parte, identifica los valores de envío y no envío del PU.

Figura 48. Comparación entre el comportamiento real y la predicción para el usuario primario en el canal evaluado sin la utilización de PCA



Fuente: elaboración propia.

En la matriz de clasificación (tabla 11) se compilan los resultados para 1000 ejemplos de predicción ($I + 1$); las filas de la matriz representan los valores de estimación del modelo, mientras que las columnas indican los valores reales. La matriz de clasificación se creó ordenando todos los casos en categorías: si el valor de predicción coincide con el valor real y si el valor de predicción es correcto o incorrecto. Para este caso, en 487 ejemplos hubo emisión real, y todos ellos fueron predichos como emisión, mientras que en 513 ejemplos hubo no emisión real, y el clasificador los estimó como no emisión. Al no haber clasificado erróneamente ninguno de los casos, la predicción tuvo un acierto del 100 %.

Tabla 11. Matriz de clasificación para 1000 ejemplos

Predicción\Emisión real	1 (emisión real)	0 (no emisión real)
1 (emisión predicha)	487	0
0 (no emisión predicha)	0	513

Fuente: elaboración propia.

Al anterior proceso se le incluyó PCA buscando reducir el tiempo de entrenamiento del sistema SVM. Calcular los componentes PCA con el máximo número de ejemplos (100.000) y su máxima longitud (2000) tardó 211 segundos. Hay que tener en cuenta que, antes de generar el modelamiento, se eliminó la media de los valores y se calcularon sus respectivos componentes PCA. La duración del entrenamiento fue de

3958 segundos o de 66 segundos. Posteriormente se calculó, para 1000 ejemplos, la predicción en el instante $l+1$, y el resultado de acierto fue del 100%:

Predicción SVM 1 de 1

Accuracy = 100 % (1000/1000) (classification)

Elapsed time is 11,493758 seconds

La matriz de clasificación (tabla 12) indica que en 356 ejemplos hubo emisión real, y todos fueron predichos como existencia del PU en el canal, mientras que en 644 ejemplos hubo no emisión real, y el clasificador los catalogó como no emisión. Al no haber clasificado erróneamente ninguno de los casos, la predicción tuvo un acierto del 100%.

Tabla 12. Matriz de clasificación para 1000 ejemplos usando PCA

Predicción\Emisión real	1 (emisión real)	0 (no emisión real)
1 (emisión predicha)	356	0
0 (no emisión predicha)	0	644

Fuente: elaboración propia.

Al concluir que el porcentaje de acierto era del 100%, se intentó detectar los instantes temporales $l+1000$, para lo cual se calculó el instante $l+1$; después, se usó esta predicción para calcular el instante $l+2$, y así, sucesivamente, hasta $l+x$. El proceso de entrenamiento o caracterización para este caso fue exactamente igual que para las pruebas realizadas antes. Para una $x=1000$, el resultado de la predicción tuvo un éxito de cerca del 50% tanto sin PCA como con PCA (tablas 13 y 14).

Para la predicción sin PCA, en 518 ejemplos hubo presencia real del PU: 289 de ellos fueron predichos correctamente, como emisión, y 229 fueron clasificados incorrectamente, como no emisión. Asimismo, en 482 ejemplos hubo no emisión real: el clasificador clasificó 263 equivocadamente, como emisión, y 219 correctamente, como no emisión. En resumen, 492 casos fueron clasificados incorrectamente y 508 correctamente, por lo que se obtuvo un acierto del 50,8%:

Predicción SVM 1000 de 1000

Accuracy = 50,8 % (508/1000) (classification)

Elapsed time is 15,095385 seconds

Tabla 13. Matriz de clasificación para 1000 ejemplos con estimación sin PCA

Predicción\Emisión real	1 (emisión real)	0 (no emisión real)
1 (emisión predicha)	289	263
0 (no emisión predicha)	229	219

Fuente: elaboración propia.

Por su parte, para la predicción con PCA, en 513 ejemplos hubo emisión real: 270 de ellos fueron predichos correctamente, como emisión, y 243 fueron clasificados incorrectamente, como no emisión. Asimismo, en 487 ejemplos hubo no emisión real: el clasificador clasificó 242 equivocadamente, como emisión, y 245 correctamente, como no emisión. Así, 485 casos fueron clasificados incorrectamente y 515 correctamente, lo que arroja un acierto del 51,5%:

Predicción SVM 100de 1000
Accuracy = 51,5 % (515/1000) (classification)
Elapsed time is 16,175938 seconds


Tabla 14. Matriz de clasificación para 1000 ejemplos con estimación / + 1000 con PCA

Predicción\Emisión real	1 (emisión real)	0 (no emisión real)
1 (emisión predicha)	270	242
0 (no emisión predicha)	243	245

Fuente: elaboración propia.

Para cada uno de los casos entrenados y estimados, los porcentajes se acercan siempre al 50 %, debido a que es la probabilidad de que se tenga emisión o no. Básicamente, el clasificador caracteriza la señal del PU esperando que esta se mantenga eternamente en 1, si empezó siendo 1, o en 0, si empezó siendo 0, como se evidencia en la figura 49, donde la señal predicha (color rojo) se mantiene en no emisión toda la predicción, mientras que la real (color azul) evidencia la no presencia del PU hasta pasado el milisegundo 700 y retorna al estado de no emisión a partir de los 965 ms.

Figura 49. Comparación entre la actividad real del usuario primario y la estimada por la SVM-2 con PCA




Fuente: elaboración propia.

Finalmente, se probó, en la fase de predicción, extraer en porcentajes la probabilidad de que cada ejemplo se encuentre en una clase u otra; es decir, lo que se pretendió fue obtener un porcentaje de probabilidad en la emisión, en lugar de una indicación de la presencia o ausencia; de esta forma, en vez de estimar 1 o 0, se predijo un valor x entre 0 y 1, donde x es la probabilidad de emisión en el instante a predecir y $1-x$ es la probabilidad de no emisión. Así, se entrenó el algoritmo para que devolviera porcentajes. Para una predicción de $x = 1000$ ms en el futuro, el resultado fue cercano a un 50% de éxito sin PCA y a un 50% de éxito con PCA.

Cuando se usan porcentajes, hay una probabilidad de que la señal cambie de 0 a 1 y viceversa, pero la probabilidad es aproximadamente de un 0,15%, y la posibilidad de volver al valor original en el instante siguiente es muy elevada, por lo que, en la mayoría de los casos, la señal se mantiene en su valor original; lo anterior se evidencia en la figura 50, donde se observa que en un tiempo determinado la predicción intenta cambiar a un nivel alto (sobre el *timestamp* 850), pero, debido al historial previo, se rectifica rápidamente y vuelve al nivel bajo, lo que confirma que intentar caracterizar la actividad de PU mediante SVM es ineficiente cuando se discretiza la señal.

Figura 50. Comparación entre la actividad real del usuario primario y la estimada por la SVM-2 según porcentajes de probabilidad



Fuente: elaboración propia.

Discusión

Los modelos presentados han pretendido generar una nueva propuesta para la caracterización (modelamiento + estimación) de PU, para un canal en la banda espectral Wi-Fi, con base en el uso del algoritmo de aprendizaje supervisado SVM.

Los resultados encontrados a partir del uso de la SVM-1 no han logrado representar la dinámica de comportamiento del PU, ya que el algoritmo ha sido incapaz de converger, lo que indica que no llegó a encontrar una solución al problema, y eso impidió entrar en la fase de predicción.

Por esta razón, se evaluó un segundo algoritmo, el SVM-2, que consiguió reproducir la dinámica esperada y logró entregar resultados fiables para el primer *timestamp* de estimación futura; no obstante, cuando se estimaron *timestamps* consecutivos para una misma serie temporal, el algoritmo siempre predijo en función del último instante de tiempo registrado: si había presencia del PU, siempre predecía su presencia, y si el canal estaba libre, predecía su ausencia. A partir de los planteamientos y análisis expuestos, y según la experiencia adquirida a lo largo de la investigación desarrollada, se infiere que el uso de técnicas de inteligencia artificial para el modelamiento y estimación de PU en redes cognitivas (con topologías de red centralizada) podría ser un gran acierto dada la capacidad de aprendizaje autónomo que poseen, siempre y cuando se usen metodologías como las redes bayesianas dinámicas o las redes neuronales (Xing, Jing, Huo et al., 2013); no obstante, como trabajo futuro, se plantea la posibilidad de usar SVM pero con señales continuas.

Caracterización de los usuarios secundarios

En este capítulo se presenta el diseño, desarrollo, desempeño y resultados de los modelos seleccionados para la caracterización del arribo de los usuarios secundarios.

Modelos reactivo y proactivo

A continuación, se presenta el desarrollo y los resultados alcanzados con los modelos reactivo y proactivo para la caracterización del arribo de los usuarios secundarios.

Evaluación de desempeño en el procesamiento de solicitudes de acceso a canales en la estación base

El tiempo de procesamiento de una solicitud se puede estimar a través de la ecuación (106):

$$t_m = t_a + t_c + x(m)t_d \quad (106),$$

donde t_a es el tiempo de arribo del n -ésimo usuario secundario (SU), t_d es el tiempo de procesamiento del servicio solicitado, t_c es el tiempo de asignación del canal y $x(m)$ es la función característica definida por la ecuación (107):


$$x(m) = \begin{cases} 1 & \text{para el modelo reactivo} \\ 0 & \text{para el modelo proactivo} \end{cases} \quad (107).$$

Además, se tiene la ecuación (108):

$$t_c = t_o \cdot N_c \quad \text{y} \quad t_d = t_o \cdot N_d \quad (108),$$

donde t_o es el tiempo que tarda el nodo central en hacer una operación, N_c es el número de operaciones para la asignación del canal y N_d es el número de operaciones que se requieren para procesar la solicitud.

Figura 51. Evaluación del nivel de estimación del arribo de usuarios secundarios a la estación base con el modelo proactivo



Fuente: elaboración propia.

El t_a se puede calcular a partir de la función de distribución dada por la ecuación (109):

$$t_a = \frac{1}{\lambda_{su}} \ln \left(\frac{1}{p(x=n)} \right) \quad (109),$$

donde λ_{su} es el parámetro de la distribución usada. Por lo tanto, se llega a que t_m queda determinada por la ecuación (110):

$$t_m = \frac{1}{\lambda_s} \ln \left(\frac{1}{P(x=n)} \right) + t_o (N_c + x(m)N_d) \quad (110).$$

De la anterior relación se concluye que la única diferencia entre el modelo reactivo y el proactivo es el término $t_o N_d$, el cual es un valor no negativo que permite afirmar la desigualdad mostrada en la ecuación (111):

$$t(reactive) > t(proactive) \quad (111).$$

Modelo MLPNN para la estimación del arribo del usuario secundario

En la presente sección se describe el modelo MLPNN para la estimación del arribo del SU.

Diagrama de flujo del algoritmo de aprendizaje

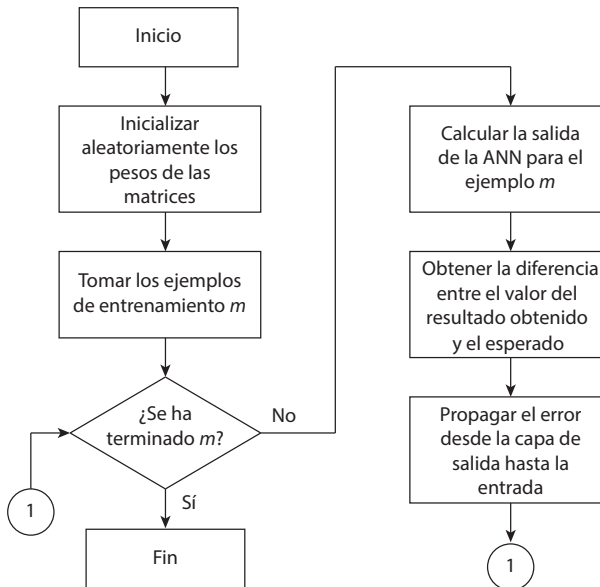
El diagrama de flujo se observa en la figura 52. Además, un fragmento del código de la MLPNN para la optimización de la red neuronal se muestra a continuación. La secuencia que se muestra supone la existencia de dos arreglos, Theta1 y Theta2, correspondientes a las matrices de pesos ponderados de la red neuronal. El algoritmo toma los ejemplos de entrenamiento hasta encontrar los valores óptimos de Theta1 y Theta2 que minimizan el error obtenido (figura 52).

Parte del código del algoritmo MLPNN es el siguiente:

```

delta_accum_1=zeros (size (Theta1));
delta_accum_2=zeros (size (Theta2));
for t=1:m do
a_1=X(t,: );
z_2=a_1 * Theta1';
a_2=[1 sigmoide (z_2)];
z_3=a_2 * Theta2';
a_3= sigmoide (z_3);
y_i=zeros (1,K);
y_i(y(t))=1;
delta_3=a_3-y_i;
delta_2=delta_3 * Theta2 .* sigmoideGradient ([1 z_2]);
delta_(accum_1)=delta_(accum_1)+delta_2 (2:end)' *a_1;
delta_accum_2=delta_accum_2+delta_3' *a_2;
end;
Theta1_grand= delta_accum_1 / m
Theta2_grand= delta_accum_2 / m
    
```

Figura 52. Diagrama de entrenamiento del sistema MLPNN



Fuente: elaboración propia.

Entrenamiento de la red neuronal

Durante este proceso se determina el valor de las matrices de pesos de control utilizando el algoritmo de propagación hacia atrás (*backpropagation*), que incluye los siguientes lineamientos dentro de su algoritmo:

- Inicializar de forma aleatoria los pesos de las matrices con números entre -1 y 1 .
- Implementar el algoritmo de propagación hacia adelante para obtener A^m para cualquier $x(i)$.
- Calcular el costo $J(\theta)$ a partir de la ecuación (112) (Hsieh, 2009), con el fin de obtener la diferencia entre los valores esperados y los obtenidos; el objetivo es hacer que su valor se aproxime lo más cerca posible a 0.

$$J(\theta) = -\frac{1}{m} * \sum_{x=0}^m \sum_{x=0}^n \left(y(x) * \log\left(\left(A^{(x)}\right)_m\right) + (1 - y(x)) * \log\left(\left(A^{(x)}\right)_n\right) \right) \quad (112),$$

donde $J(\theta)$ es la función costo para redes neuronales; m es el número de ejemplos de entrenamiento; n es el número de características; $y(x)$ es el vector objetivo; $A^{(x)} = h(\theta)x^{(i)}$; $x^{(i)}$ es el valor estimado para la entrada m y la característica n ; $h(\theta) = g(\theta_0 + \theta_1 x_1 + \theta_2 x_2)$; θ son los parámetros del vector que se aplican a la regresión lineal, y g es la función sigmoide.

- Calcular las derivadas parciales de $\frac{dJ(\theta)}{d\theta_{ij}^k}$, intentando con ello minimizar el error al máximo —ecuación (113) (Hsieh, 2009)—:

$$\theta_{ij}^k = \theta_{ij}^k - \alpha \frac{dJ(\theta)}{d\theta_{ij}^k} \quad (113),$$

donde α es la tasa de aprendizaje del gradiente descendente, θ_{ij}^k son los pesos de la hipótesis (parámetros del vector que se van ajustando para minimizar el error en la estimación) y los subíndices ij representan el número de la característica aplicado a la regresión lineal.

Software de predicción de arribo de usuarios secundarios

Para determinar la habilidad y precisión del algoritmo MLPNN para calcular la probabilidad de arribo del siguiente SU a la estación base (BS), con criterios de calidad de servicio (QoS) tipo mejor esfuerzo (BE) o tiempo real (RT) y de ancho de banda (BW), se desarrolló una aplicación *software*. En la figura 53 se muestra la fase de creación del histórico de solicitudes BE, RT y BW (en la figura se visualiza el comportamiento pasado con solicitudes BE y RT únicamente).


En la figura 54 se muestra una captura de la segunda fase del *software*, en la que se crean las dos redes neuronales MLPNN para un determinado SU: la primera de ellas

está especializada en estimar el BW que probablemente va a solicitar el SU, y la segunda está entrenada para predecir la probabilidad de que se solicite un servicio BE o RT.

La figura 55, por su parte, representa gráficamente la etapa de entrenamiento o aprendizaje de las redes neuronales. Por cuestiones de orden, en la figura solo se muestra el modelamiento para el comportamiento histórico en las solicitudes tipo BE, donde es claro que la MLPNN logra establecer el patrón (pasado) solicitado por el SU.

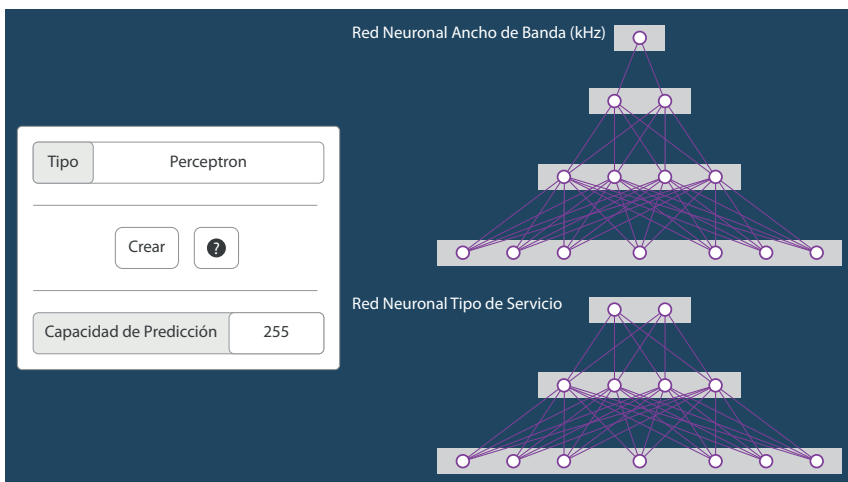
La última fase del algoritmo corresponde a la predicción, la cual estimará el 30% futuro de los datos históricos y los comparará con el comportamiento real (figura 56).

Figura 53. Software de predicción de arribo de usuarios secundarios (generación del histórico)



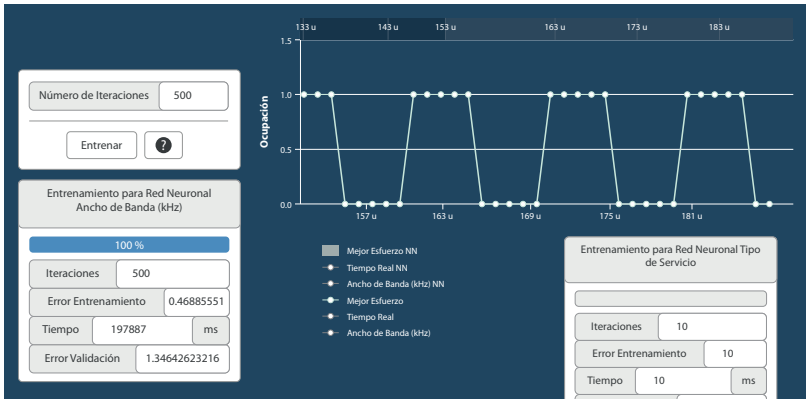
Fuente: elaboración propia.

Figura 54. Etapa de creación de las MLPNN especializadas



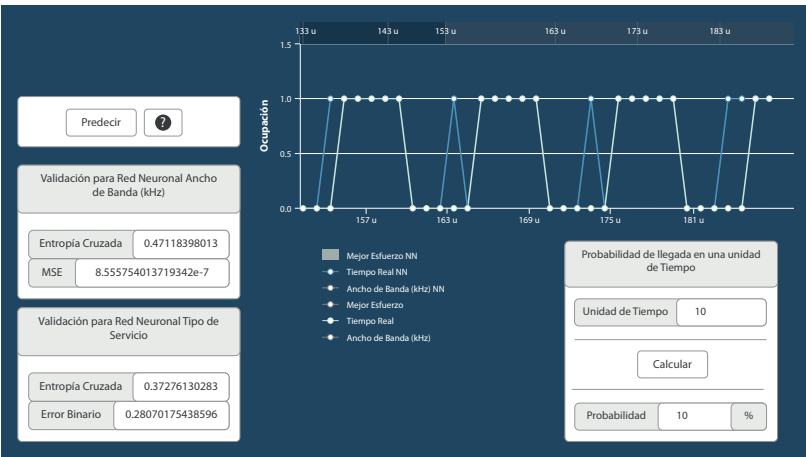
Fuente: elaboración propia.

Figura 55. Fase de entrenamiento de la red neuronal



Fuente: elaboración propia.

Figura 56. Fase de predicción de la red neuronal (con cálculo de probabilidad de una solicitud de QoS)



Fuente: elaboración propia.

Evaluación de resultados

Con el fin de verificar la propuesta desarrollada, se generaron tres casos de prueba haciendo uso de las distribuciones exponencial, *poisson* y uniforme. Los resultados cuantitativos durante la fase de entrenamiento para 200 ejemplos se muestran en las tablas 15, 17 y 19, y las respuestas en la estimación de las solicitudes de BE, RT y BW se observan en las tablas 16, 18 y 20.

Tabla 15. Resultados del entrenamiento para el caso de prueba de distribución exponencial

Métrica	1.ª MLPNN (BW)	2.ª MLPNN (BE y RT)
Iteraciones	500.000	500.000
Error de entrenamiento	0,13705	0,04018
Tiempo (ms)	350.856	261.833
Error de validación	0,00027	0,00027
Porcentaje de cantidad de aciertos	62	99

Fuente: elaboración propia.

Tabla 16. Resultados de la predicción para el caso de prueba de distribución exponencial

Métrica	1.ª MLPNN (BW)	2.ª MLPNN (BE y RT)
Entropía cruzada	0,43791	4,70093
MSE	0,05005	No aplica
Error binario	No aplica	0,47761
Porcentaje de cantidad de aciertos	48	72

Fuente: elaboración propia.

Tabla 17. Resultados del entrenamiento para el caso de prueba de distribución *poisson*

Métrica	1.ª MLPNN (BW)	2.ª MLPNN (BE y RT)
Iteraciones	500.000	500.000
Error de entrenamiento	0,37262	0,17537
Tiempo (ms)	333.243	307.682
Error de validación	0,00205	0,00205
Porcentaje de cantidad de aciertos	11	95

Fuente: elaboración propia.

Tabla 18. Resultados de la predicción para el caso de prueba de distribución *poisson*

Métrica	1.ª MLPNN (BW)	2.ª MLPNN (BE y RT)
Entropía cruzada	0,44064	0,47060
MSE	0,00767	No aplica
Error binario	No aplica	0,18750
Porcentaje de cantidad de aciertos	5	91

Fuente: elaboración propia.

Tabla 19. Resultados del entrenamiento para el caso de prueba de distribución uniforme

Métrica	1.ª MLPNN (BW)	2.ª MLPNN (BE y RT)
Iteraciones	500.000	500.000
Error de entrenamiento	0,54275	0,29872
Tiempo (ms)	354.977	357.718
Error de validación	0,00205	0,02485
Porcentaje de cantidad de aciertos	3	93

Fuente: elaboración propia.

Tabla 20. Resultados de la predicción para el caso de prueba de distribución uniforme

Métrica	1.ª MLPNN (BW)	2.ª MLPNN (BE y RT)
Entropía cruzada	0,90017	4,70093
MSE	0,10927	No aplica
Error binario	No aplica	0,89655
Porcentaje de cantidad de aciertos	2	55


Fuente: elaboración propia.

Los resultados encontrados sugieren que el porcentaje de acierto en la predicción de solicitud de BW por parte del SU es bajo.

Es importante recalcar que esta métrica evalúa que en cualquier instante de tiempo el valor esperado sea igual al valor obtenido, sin ninguna tolerancia de error. En este sentido, por ejemplo, para la distribución exponencial (figura 57) se observa que la red neuronal identificó el patrón, razón por la cual el MSE (que para este caso muestra la diferencia entre los valores esperados y mínimos) es muy pequeño, del orden de las centésimas.

Otra característica del comportamiento del sistema a partir de la respuesta entregada en los casos de prueba es que logró identificar patrones para las distribuciones exponencial y *poisson*; sin embargo, para el caso de la distribución uniforme, al no presentar un patrón en sus datos históricos, no fue posible modelar ni predecir su comportamiento.

Figura 57. Distribución exponencial predicha para la variable *ancho de banda*



Fuente: elaboración propia.

Modelo de decisión espectral colaborativo

En la introducción se realizó una primera descripción del modelo de decisión espectral colaborativo, que está conformado por cuatro módulos fundamentales: 1) módulo colaborativo (intercambio de información entre usuarios secundarios [SU]); 2) módulo de caracterización del usuario primario (PU); 3) módulo de probabilidad de arribo del SU, y 4) módulo de selección de la oportunidad espectral (SO); en el capítulo 1, a su vez, se realizó la descripción de los fundamentos teóricos relevantes para esta investigación; en el capítulo 2 se presentó el módulo de caracterización del PU, y en el capítulo 3 se describió del módulo de probabilidad de arribo del SU. De acuerdo con lo anterior, en este capítulo se presentan el módulo colaborativo (intercambio de información entre SU) y el módulo de selección de la SO.

Debido a que la información de ocupación espectral tiene un papel relevante en esta investigación, primero se describirá la metodología que se llevó a cabo para capturar, organizar y procesar los datos experimentales de ocupación espectral; luego, se presentará el módulo colaborativo; posteriormente, se describirá el módulo de selección de la SO, junto con los resultados obtenidos, y, finalmente, se presentará el modelo de decisión espectral colaborativo definitivo, a partir de los resultados alcanzados en cada uno de los cuatro módulos que lo conforman.

Con el objetivo de facilitar la comprensión y organización de este libro, la descripción del *software* desarrollado se dejó como un capítulo independiente posterior al actual.

Selección del *software* y los equipos

Para desarrollar la presente investigación se utilizaron los siguientes recursos: un sistema de monitorización del espectro (tabla 21), en este caso el analizador MS2721B de Anritsu, para realizar la captura de los datos de potencia espectral en las bandas GSM y Wi-Fi; múltiples bases de datos electrónicas para realizar la revisión literaria sobre *handoff* espectral (SH) para redes de radio cognitiva (CRN); el *software* Matlab

para desarrollar el simulador y los correspondientes algoritmos de decisión espectral; un computador de escritorio (tabla 22) para realizar el procesamiento de la información, el diseño del modelo, el desarrollo de la experimentación, el análisis de los resultados y la documentación de toda la investigación, y, finalmente, un clúster para desarrollar el algoritmo y ejecutar las pruebas de entrenamiento y predicción (tabla 23).

Tabla 21. Especificaciones de los equipos para la monitorización del espectro

Equipo	Especificaciones	
	Rango de frecuencia	Referencia
Antena tipo discono	25 MHz-6 GHz	Super-M Ultra Base
Cable de banda ancha	DC-18 GHz	CBL-6FT-SMNM+
Amplificador de bajo ruido	20 MHz-8 GHz	ZX60-8008E-S+
Analizador de espectro	9 KHz-7,1 GHz	MS2721B Anritsu

Fuente: elaboración propia.

Tabla 22. Especificaciones del equipo de cómputo

Característica	Valor de referencia
Procesador	AMD FX 9590 de 8 núcleos y 4,71 GHz
Memoria RAM	DDR3 de 16 GB
Disco de estado sólido	Kingston SV300S37A de 240 GB
Tarjeta de video	AMD Radeon R7 200
Tarjeta de red	10/100/1000 mbps
Monitor	LG IPS Full HD
Sistema operativo	Windows 7 de 64 bits

Fuente: elaboración propia.

Tabla 23. Especificaciones del clúster

Característica	Descripción
Equipo	Máquina virtual KVM-Bios Openstack Foundation, 2015.1
Marca	Servidor Dell R900
Cantidad de procesadores	Intel® Xeon® CPU E7450 (2,40 GHz, 24 cores)
Memoria RAM	DDR2 de 64 GB
Sistema de almacenamiento	1000 GB EXT4
Sistema operativo	Ubuntu Server 14.04.04 con entorno de escritorio XFCE4

Fuente: Hernández, Salgado et al. (2015).

Tipo de red

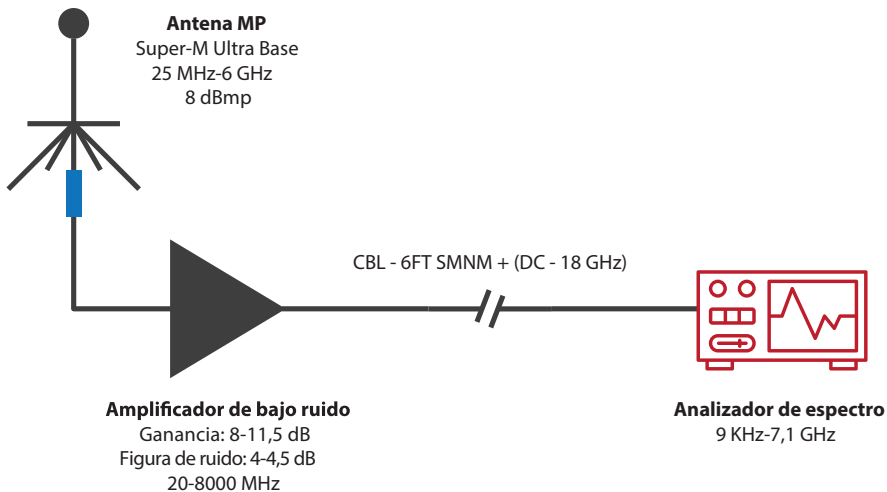
Para realizar un análisis comparativo más completo, se decidió evaluar y validar el desempeño de cada algoritmo de decisión espectral en dos redes diferentes: GSM y Wi-Fi. La razón para escoger la banda GSM fue la alta demanda de telefonía celular y la baja calidad de servicio (QoS) (Pedraza et al., 2016), y en el caso de la banda Wi-Fi, la razón de su escogencia obedeció al interés de analizar el desempeño de los algoritmos en un ambiente más estocástico y a la viabilidad de su posible utilización por parte de SU de telefonía móvil (Cardenas-Juarez et al., 2016).

Captura y procesamiento de los datos de ocupación espectral

Este apartado describe el procedimiento realizado para obtener la información de ocupación espectral, la cantidad de información almacenada y su posterior procesamiento como insumo de la herramienta de simulación. El análisis se presenta para la red GSM, pero para Wi-Fi se siguió una metodología similar.

La figura 58 describe la configuración de los equipos para realizar el proceso de medición de la ocupación espectral en las bandas GSM (824 MHz-874 MHz) y Wi-Fi (2,4 GHz-2,5 GHz); las especificaciones de los equipos utilizados se muestran en la tabla 21, y la configuración de los parámetros técnicos del analizador de espectro para la banda GSM se puede observar en la tabla 24.

Figura 58. Configuración experimental para medir la ocupación espectral



Fuente: elaboración propia.

Tabla 24. Configuración de los parámetros técnicos del analizador de espectro para GSM

Parámetro	Valor
Banda de frecuencia	824 MHz-874 MHz
Sistema de comunicación	Móvil
Tecnología de comunicación	GSM
Técnica de detección	Detección de energía
Tiempo de captura	Un mes
Tiempo de barrido	290 ms
Resolución de BW (RBW)	100 KHz
<i>Span</i>	50 MHz
Puntos por <i>span</i> (PPS)	500

Fuente: elaboración propia.

Los rangos de medición de las bandas se basaron en aspectos como el tiempo de barrido, la resolución de ancho de banda (RBW) y el *span*, con el fin de garantizar una adecuada medida en función del piso de ruido y el BW [ancho de banda] del canal de la tecnología a medir. (Pedraza et al., 2016)

La técnica de detección utilizada fue la de energía, debido a su factibilidad de implementación. Además, la campaña de medición se realizó durante un mes, desde mayo hasta junio de 2018. Una explicación más detallada de la configuración de los parámetros técnicos del analizador de espectro se puede consultar en Pedraza et al. (2016).

El valor del *span* corresponde al rango de frecuencia que está siendo analizado, en este caso, 50 MHz (824 MHz-874 MHz), y los PPS determinan el número de canales de frecuencia (división uniforme de una porción del espectro) para los cuales el analizador de espectro midió el correspondiente nivel de potencia durante cada barrido. De acuerdo con lo anterior, el analizador de espectro entregó, en cada barrido, la información del valor de potencia medido en dBm correspondiente a 500 canales de frecuencia (potenciales SO), con un BW de 100 KHz (50 MHz / 500) cada uno.

El número de barridos que realiza el analizador de espectro depende del tiempo de barrido (290 ms) y de la duración de la campaña de medición (un mes). De acuerdo con el tiempo de barrido, se tienen aproximadamente 3,448 barridos por segundo; por tanto, el número total de barridos realizados en un mes es: $8.937.216 \text{ (barridos/mes)} = 3,448 \text{ (barridos/segundo)} \times 60 \text{ (segundos/minuto)} \times 60 \text{ (minutos/hora)} \times 24 \text{ (horas/día)} \times 30 \text{ (días/mes)}$, y el número total de datos de potencia es: $4.468.608.000 \text{ (datos de potencia del canal/mes)} = 8.937.216 \text{ (barridos/mes)} \times 500 \text{ (datos de potencia del canal/barrido)}$.

A partir de la información anterior, se construyó una matriz de potencia de $8.937.216 \times 500$, que contiene el valor de potencia de cada uno de los 500 canales (comprendidos entre 824 MHz y 874 MHz) para 8.937.216 instantes de tiempo (TS) (cada TS equivale a 290 ms); sin embargo, debido a la gran cantidad de filas, dicha matriz tuvo que segmentarse en 240 matrices de 37.238×500 para poder trabajar con ella.

Nivel de tráfico

Hasta el momento, se cuenta con una matriz de valores de potencia de cada uno de los 500 canales (con BW de 100 KHz, comprendidos entre 824 MHz y 874 MHz) para cada uno de los 8.937.216 TS (correspondientes a un mes continuo de tiempo, teniendo en cuenta que cada TS es igual a 290 ms), a la cual denominaremos *matriz de potencias* (PM). Con el objetivo de analizar el desempeño de los algoritmos de decisión espectral de acuerdo con el nivel de tráfico en la red, se decidió extraer de la PM tres trazas de información (submatrices) que representaran el comportamiento del espectro cuando la red tuviera un nivel de tráfico bajo (LT), tráfico medio (MT) y tráfico alto (HT); estas nuevas matrices se denominaron PM de LT (PM-LT), PM de MT (PM-MT) y PM de HT (PM-HT), respectivamente. Cada una de estas tres matrices tiene un tamaño de 14.483×500 , donde las 500 columnas representan cada uno de los canales medidos, y las 14.483 filas representan los TS consecutivos en los cuales se realizó la medición. Los 14.483 TS de cada matriz se segmentaron en dos partes: una, con 12.414 TS, que corresponden a una subtraza de 60 minutos, denominada *entrenamiento* (TR), y otra, con 2069 TS, que corresponden a una subtraza de 10 minutos, denominada *evaluación* (EV). La matriz de TR contiene la información histórica (últimos 60 minutos) de ocupación espectral que conocen los algoritmos de SH, mientras que la matriz de EV contiene la información futura (10 minutos) de ocupación espectral que no conocen los algoritmos de SH y que solo es manipulada por la herramienta de simulación para realizar la correspondiente evaluación y validación de cada algoritmo de SH.

De acuerdo con esta explicación, se tienen finalmente seis matrices de potencias por cada tipo de red (GSM y Wi-Fi): PM-LT-TR, PM-LT-EV, PM-MT-TR, PM-MT-EV, PM-HT-TR y PM-HT-EV; sin embargo, solo es necesario encontrar las tres matrices de EV, ya que cada matriz de TR corresponde a los 60 minutos anteriores de la respectiva matriz de EV. Para encontrar las tres matrices de EV, se realizó un análisis estadístico de la ocupación espectral capturada, para lo cual fue necesario conocer la disponibilidad de cada canal en cada TS, por lo que el primer paso fue obtener la matriz de disponibilidad (AM) a partir de la PM.

Para obtener la AM a partir de la potencia de cada canal, se calculó un umbral de decisión; los canales con potencias menores al valor del umbral de decisión se

clasificaron como *disponibles*, y dicho estado se representó en la AM con un ‘1’ lógico, y en el caso contrario, los canales fueron clasificados como *ocupados*, y su estado se denotó con un ‘0’ lógico. El valor de la potencia del umbral de decisión se calculó a partir la ecuación (114) con una probabilidad de falsa alarma del 1 % (Pedraza et al., 2016). Otro método para determinar el valor del umbral de decisión es tomar un nivel de guarda de 5 dBm por encima del piso de ruido promedio del analizador de espectro, con el objetivo de minimizar posibles falsas alarmas. El piso de ruido promedio se determinó con la ubicación de una impedancia de 50 Ω a la entrada del analizador de espectro, con un nivel de atenuación de 0 dB, con detección de raíz media cuadrática (RMS) y con un largo periodo de medición (Pedraza et al., 2016). La tabla 25 muestra los valores del piso de ruido promedio y del umbral de decisión para las dos metodologías.

$$P_{fa} = \frac{\Gamma\left(m, \frac{\lambda}{2}\right)}{\Gamma(m)} \quad (114).$$

Tabla 25. Umbral de decisión para la detección de usuarios primarios

Banda de frecuencia	Piso de ruido promedio	Umbral de decisión (piso de ruido: +5 dBm)	Umbral de decisión: ecuación (114)
GSM (824 MHz-874 MHz)	-113 dBm	-108 dBm	-109 dBm
Wi-Fi (2,4 GHz-2,5 GHz)	-111 dBm	-106 dBm	-108 dBm

Fuente: elaboración propia.

Con la AM ya construida, se procedió a realizar un análisis estadístico de la ocupación espectral en el tiempo de acuerdo con el número promedio de PU activos simultáneamente; esto consistió en calcular el porcentaje de canales ocupados por cada TS. Luego, se diseñó un algoritmo que contara el número de TS con ocupación mayor al 80 % dentro de una ventana móvil de 10 minutos (2069 TS) y que promediara los porcentajes de ocupación de cada TS incluido dentro de la ventana. Dicha ventana se desplazó por el total de filas de la AM para analizar todas las combinaciones posibles. Los resultados evidenciaron que el peor caso corresponde a una ocupación promedio de la ventana del 48 %, y en el mejor caso, del 18 %, valores que corresponden a las ventanas que describen las matrices de EV para HT y LT, respectivamente. Para el caso de MT, se tomó el valor medio entre 48 y 18 y se buscó una ventana que se ajustara a este valor. Los valores de ocupación espectral promedio encontrados se explican en gran parte debido a que los primeros 25 MHz de la banda de 824 MHz a 874 MHz corresponden al enlace ascendente GSM. Estos valores también evidencian la oportunidad de hacer un uso más eficiente del espectro en dicha banda.

Con los resultados anteriores, se determinaron las matrices de potencia: PM-LT-TR, PM-LT-EV, PM-MT-TR, PM-MT-EV, PM-HT-TR y PM-HT-EV, y a partir de estas se construyeron las matrices de disponibilidad: AM-LT-TR, AM-LT-EV, AM-MT-TR, AM-MT-EV, AM-HT-TR y AM-HT-EV; sin embargo, debido a la extensión de los resultados obtenidos, se decidió excluir las matrices de potencia y disponibilidad correspondientes a MT, por lo que de aquí en adelante solo se mencionan los niveles de LT y HT, así como las matrices de potencia (PM-LT-TR, PM-LT-EV, PM-HT-TR y PM-HT-EV) y las matrices de disponibilidad (AM-LT-TR, AM-LT-EV, AM-HT-TR y AM-HT-EV), tanto para GSM como para Wi-Fi.

Módulo colaborativo: intercambio de información entre usuarios secundarios

Una de las principales novedades de esta investigación es el hecho de contemplar la característica de colaboración entre SU para determinar la mejor SO. Como se mencionó en la introducción y en el capítulo 1, la mayor parte de los trabajos de investigación en radio cognitiva (CR) se fundamentan en una red centralizada, en la que toda la información está organizada en un solo lugar y cuyo acceso resulta más fácil y beneficioso para la toma de decisiones; sin embargo, aunque su observación y conocimiento global es una ventaja, para sistemas a gran escala y aplicaciones en redes de seguridad pública no es la mejor opción, pues el aumento en los costos de medición, la complejidad del sistema, la cantidad de información que debe controlar y el desequilibrio y potencial caos si la estación base (BS) llegara a fallar (vulnerabilidad) la convierten en una arquitectura no factible para todas las estructuras de CRN (Pankratev et al., 2019). En el caso de las redes distribuidas, como las redes móviles *ad hoc*, o manet (*mobile ad-hoc network*), se caracterizan por su alta movilidad, su autonomía y su adaptación e independencia, y sus aplicaciones se encuentran en escenarios que involucran vehículos terrestres (VANET), vehículos aéreos no tripulados (Bujari et al., 2018), vigilancia urbana y misiones de búsqueda o rescate (Dhamodharavadhani, 2015). Sin embargo, la falta de infraestructura, la topología dinámica, la implementación rápida y los entornos hostiles de aplicación hacen que la manet sea vulnerable a una amplia gama de ataques de seguridad (Abass et al., 2017; Kongsiriwattana y Gardner-Stephen, 2017; Vasudeva y Sood, 2018); además, el consumo de energía y el retardo son altos (Kongsiriwattana y Gardner-Stephen, 2017), y el BW es bajo, así como su rendimiento, por las frecuentes fallas de enlace (Dhamodharavadhani, 2015; Goswami, 2017). Esta problemática puede ser solucionada si se distribuye la responsabilidad de la información en diferentes puntos de control, criterio base de las redes de radio cognitiva descentralizadas (DCRN). Ahora, debido a que en las DCRN no se centralizan la información y la gestión de la red, resulta realmente importante el concepto de *colaboración entre SU* para la toma de decisiones.

De acuerdo con lo anterior, la presente investigación implementó y adaptó la colaboración al modelo de decisión espectral propuesto, a través de un módulo de intercambio de información entre SU, que se describe a continuación.

Inicialmente, cada SU almacena información de su entorno radioeléctrico, y para hacerlo, se plantean cuatro diferentes alternativas: guardar toda la información posible, guardar solo los últimos k datos de información, guardar el promedio de toda la información posible o guardar solo el promedio de los últimos k datos de información. Con el objetivo de optimizar el uso de la batería del SU, se descartaron la primera y tercera alternativas, dejando solo las opciones de guardar los últimos k datos de información o su promedio; para tomar la decisión sobre cuál de estas estrategias seleccionar para el modelo de decisión espectral colaborativo, se implementaron las dos para saber cuál generaba menor número de *handoffs* espectrales al transmitir la misma cantidad de información durante 9 minutos y a partir del mismo algoritmo de toma de decisiones.

Los resultados mostraron que, para k mayores de 180, los últimos k datos resultan ser una mejor opción con una diferencia del 29 %, mientras que, para valores de k menores de 180, el promedio tiene mejores resultados con una diferencia del 32 %. De acuerdo con lo anterior, se decidió seleccionar la alternativa del promedio, además porque esta trae consigo información de varios periodos anteriores a k , lo que representa un valor agregado.

Módulo de selección de la oportunidad espectral

En esta sección se describe el módulo de selección de la SO. Primero, se presenta la metodología de evaluación planteada; segundo, se mencionan los algoritmos de decisión espectral seleccionados; tercero, se describen los criterios de decisión (DC) utilizados en cada uno de los algoritmos de decisión espectral seleccionados; cuarto, se describe el algoritmo *fuzzy* AHP (FAHP, algoritmo multivariable difuso), a partir del cual se determinaron los pesos de cada uno de los DC; quinto, se presenta el algoritmo FFAHP, y sexto, se describen las métricas de evaluación (EM) con las cuales se realizó la comparación entre cada algoritmo de decisión espectral seleccionado. Los resultados de la evaluación se presentan en la siguiente sección, debido a su volumen.

Metodología de evaluación

Con base en el análisis de la información obtenida a través de la revisión de la literatura sobre SH para CRN, se diseñó una metodología para la evaluación del desempeño de la movilidad en redes móviles de CR.

Esta evaluación consistió en un análisis comparativo del desempeño de los algoritmos de decisión espectral más relevantes para CRN en la literatura actual. La evaluación del desempeño se realizó para cinco EM: número de *handoffs* promedio acumulado (AAH), número de *handoffs* fallidos promedio acumulado (AAFH), BW promedio (ABW), retardo promedio acumulado (AAD) y *throughput* promedio acumulado (AAT), en ocho escenarios diferentes: GSM-RT-LT, GSM-RT-HT, GSM-BE-LT, GSM-BE-HT, Wi-Fi-RT-LT, Wi-Fi-RT-HT, Wi-Fi-BE-LT y Wi-Fi-BE-HT, producto de la combinación de tres parámetros de interés: el tipo de red (GSM y Wi-Fi), el nivel de tráfico (tráfico bajo [LT] y tráfico alto [HT]) y la clase de aplicación (tiempo real [RT] y mejor esfuerzo [BE]).

Para obtener la información de evaluación de cada algoritmo en las cinco EM, para los ocho escenarios descritos, se desarrolló una herramienta de simulación novedosa que reconstruye progresivamente el comportamiento de la ocupación del espectro a partir del uso de trazas de datos experimentales capturadas en las bandas GSM y Wi-Fi. Esto permite considerar, dentro de la simulación, una aproximación al comportamiento real del PU y, por ende, obtener una validación más exacta del desempeño real de cada algoritmo. Los datos de ocupación espectral corresponden a un mes de observación y fueron capturados en la ciudad de Bogotá, Colombia (Pedraza et al., 2016).

Si un SU desea realizar una transmisión durante φ minutos, la herramienta de simulación desarrollada realiza el siguiente procedimiento:

1. Actualiza el valor de los DC con base en la información anterior al TS actual, denominado τ_0 , en el cual el SU solicita el recurso espectral.
2. Realiza un *ranking* de clasificación de las SO con base en el puntaje obtenido por cada una, de acuerdo con la metodología del algoritmo de decisión espectral que se esté evaluando.
3. Selecciona la SO que ocupe el primer lugar en el *ranking* para asignársela al SU e iniciar su transmisión.
4. En este momento, denominado τ_1 , se verifica en la base de datos (traza de datos capturados y procesados) si la SO seleccionada se encuentra disponible: si es así, se aumenta en uno la EM AAH y se procede al quinto paso; de lo contrario, se aumenta en uno la EM AAFH, se selecciona la SO que ocupe el siguiente lugar en el *ranking* y se retorna al cuarto paso.
5. La herramienta de simulación verifica en cada TS, a través de la base de datos, si la SO que está siendo utilizada por el SU continúa disponible.

6. En el momento τ_k que la SO seleccionada sea requerida por un PU, es decir, cuando la SO ya no se encuentra disponible según la base de datos, si $\Delta\tau = \tau_k - \tau_1$ es menor de 60 segundos, entonces se selecciona la siguiente SO en el *ranking* y se retorna al cuarto paso; en caso contrario, se actualiza τ_0 con el valor de tiempo actual y se retorna al primer paso.
7. Si durante ζ segundos no se encuentra un canal disponible, la comunicación se da por perdida.

El procedimiento anterior se repite hasta que se completen los φ minutos de transmisión del SU o hasta que la comunicación se dé por perdida. En caso de que el SU complete su comunicación, la herramienta de simulación calcula el valor promedio de las cinco EM por cada minuto de los φ minutos de transmisión del SU. La base de datos suministra únicamente la información espectral correspondiente al TS que se esté ejecutando en la simulación, y para no afectar la validación, los valores de los DC se construyen progresivamente a partir de la información espectral anterior al TS actual. Esta simulación se ejecuta de forma independiente para cada algoritmo de decisión espectral y para cada uno de los ocho escenarios.

Selección de los algoritmos de *handoff* espectral

A partir de una revisión de la literatura actual sobre el tema de SH para CRN, se seleccionaron los algoritmos de decisión espectral. Para realizar esta selección, se tuvieron en cuenta no solo los resultados del algoritmo, sino también su fundamentación matemática y una metodología clara que permitiera su reproducción. Además, debido a que la selección de una SO involucra múltiples variables, los métodos MCDM son una herramienta matemática adecuada para modelar el proceso de SH y, por tanto, han sido los más ampliamente utilizados en los trabajos de investigación sobre SH (Lahby et al., 2011; Stevens-Navarro et al., 2008; Yang y Jung-ShyrWu, 2008; Yang y Tseng, 2013; Zapata et al., 2012). Los algoritmos de SH seleccionados fueron: SAW (Hernández, Giral y Santa, 2015; Zhang, 2004), TOPSIS (Vásquez et al., 2015; Zhang, 2004), VIKOR (Hernández, Páez et al., 2015; Stevens-Navarro, Gallardo-Medina et al., 2012) y FFAHP (Hernández, Pedraza y Rodríguez-Colina, 2016), que ha demostrado ser una alternativa eficaz para la evaluación y selección de SO.

Para cada uno de los algoritmos de SH seleccionados se desarrollaron dos versiones: una, con enfoque en aplicaciones RT, y otra, con enfoque en aplicaciones BE; por ejemplo, para el caso de SAW, se tiene SAW-RT y SAW-BE.

Dado que los algoritmos SAW, TOPSIS y VIKOR se explicaron en el capítulo 1, acá únicamente se describirán el algoritmo FFAHP y, adicionalmente, el FAHP, a partir del cual se calcularon los pesos de cada DC.

Criterios de decisión

Ahora, cada algoritmo de decisión espectral seleccionado (SAW, TOPSIS, VIKOR y FFAHP) depende de los DC que se seleccionen y de sus correspondientes valores. Para esta investigación, se seleccionaron cuatro DC: probabilidad de disponibilidad (AP) del canal, tiempo estimado de disponibilidad (ETA) del canal, relación de señal a interferencia más ruido (SINR) y BW, debido a que era posible determinar sus valores a partir de los datos de ocupación espectral experimentales. También se decidió que cada uno de los cuatro algoritmos de decisión espectral trabajara con los mismos cuatro DC.

La variable AP corresponde al análisis del ciclo de trabajo normalizado de cada una de las 500 potenciales SO. Por tanto, el resultado de AP es un vector de 1×500 , donde cada elemento es equivalente al promedio de la correspondiente columna de la matriz AM-LT-TR o AM-HT-TR, según el nivel de tráfico.

La variable ETA corresponde al tiempo de disponibilidad promedio de cada canal. Primero, se calculan todos los periodos de tiempo que cada canal estuvo disponible de forma continua, y luego se toma el promedio de dichos periodos para cada canal. Por tanto, el resultado del ETA también es un vector de 1×500 para la matriz AM-LT-TR o AM-HT-TR, según el nivel de tráfico.

La variable SINR corresponde al promedio de la diferencia entre la potencia de la señal y el piso de ruido promedio. Primero, para cada elemento de la matriz AM-LT-TR diferente de cero, se realiza la diferencia entre el elemento que tiene la misma posición en la matriz PM-LT-TR y el valor promedio del piso de ruido, y el resultado de la diferencia se almacena en la misma posición de una matriz temporal denominada *matriz SINR-LT-TR*. Segundo, se calcula el valor promedio de cada columna de la matriz SINR-LT-TR, por lo que el resultado de SINR también es un vector de 1×500 . Por último, se realiza el mismo procedimiento con la matriz AM-HT-TR, según el nivel de tráfico.

La variable BW, por su parte, corresponde al BW promedio de cada canal; sin embargo, debido a que son canales, todos tienen el mismo BW, equivalente a 100 KHz, por lo que el promedio será siempre el mismo, lo que le resta importancia a esta variable. No obstante, con el objetivo de que la variable BW tuviera incidencia en el *ranking* de cada SO, se decidió tomar, para cada potencial SO, el BW agregado de hasta cuatro canales adyacentes, tanto a la izquierda como a la derecha, siempre y cuando estuvieran disponibles de forma consecutiva para formar un solo canal.

En la banda GSM, todos los canales tienen un BW de 200 KHz; sin embargo, debido a los parámetros técnicos configurados en el analizador de espectro, la campaña

de medición arrojó datos de ocupación espectral para segmentos de frecuencia con un BW fijo de 100 KHz. Al respecto, a pesar de que se podría haber realizado el promedio del nivel de potencia para cada dos segmentos, a fin de obtener el valor correspondiente a cada canal GSM, se decidió trabajar con el BW de 100 KHz para realizar un uso oportunista más eficiente del espectro disponible.

Una vez calculados los valores de los DC, se procedió a realizar su normalización para que los puntajes que definían la posición de las SO en el *ranking* siempre fueran los justos, tanto en la clase de aplicación RT como en la BE. La normalización de los valores para los cuatro DC consistió en ajustar su rango de escala de 0 a 100, para lo cual se multiplicaron todos los valores de un mismo DC por un factor de escala equivalente a 100 dividido por el valor más alto del DC correspondiente.

Algoritmo multivariable difuso

El algoritmo AHP (*analytical hierarchical process*) para la toma de decisiones basada en múltiples criterios, tanto cuantitativos como cualitativos, ha demostrado ser una alternativa eficaz para la selección del canal objetivo (Kibria et al., 2005; Lahby et al., 2011; Rodríguez-Colina et al., 2011; Song y Jamalipour, 2005; Stevens-Navarro et al., 2008; Stevens-Navarro, Martínez-Morales et al., 2012). El algoritmo AHP se basa en juicios subjetivos, a través de comparaciones de la importancia entre criterios usados para la selección de una alternativa, por lo que es más una medida relativa que un valor absoluto (Saaty, 1990).

Sin embargo, el método AHP propuesto en Saaty (1990) tiene las siguientes limitaciones: 1) trabaja con una escala de juicios muy desbalanceada, 2) no maneja información con incertidumbre y ambigüedad asociada a la asignación de un número a cada evaluación, 3) su *ranking* es bastante impreciso y 4) la subjetividad del juicio, la selección y la preferencia de quienes toman las decisiones tienen gran influencia en los resultados; sin embargo, estas limitaciones se pueden corregir a través de la integración de la lógica difusa en el algoritmo AHP, lo que mejora el manejo de la subjetividad y la incertidumbre en la información y en las evaluaciones de criterios; al añadirle la lógica difusa al AHP, se obtiene el algoritmo multivariable difuso (FAHP) (Mehbodniya et al., 2012; Patil y Kant, 2014; Zapata et al., 2012).

Aunque el método FAHP tenga en esencia la misma metodología del algoritmo AHP, la lógica difusa ayuda a tratar la subjetividad y la incertidumbre en las evaluaciones de criterios, ya que, mediante un proceso matemático, permite utilizar un rango en la respuesta en lugar de un número puntual (Cortés, 2011).

El algoritmo FAHP propuesto, adaptado a la CR, se desarrolló a través de cuatro pasos: 1) definición del problema, 2) construcción de la jerarquía, 3) construcción de la matriz de juicios y 4) cálculo de los pesos normalizados.

Definición del problema

El problema puede ser dividido en cuatro niveles jerárquicos: objetivo, criterios, sub-criterios y alternativas: el objetivo es la selección de la mejor SO en una CRN; los criterios y subcriterios son los factores que afectan la preferencia de una alternativa, y las alternativas son todas las SO presentes en la banda de frecuencia seleccionada.

El procedimiento para determinar los criterios y subcriterios fue realizado a través de una modificación del método Delphi (Green et al., 2007), que es relativamente simple de implementar y que ha sido adoptado para diversas aplicaciones, como pronósticos, estimaciones y problemas de toma de decisiones (Green et al., 2007). El método consiste generalmente en un panel de expertos que responden cuestionarios en dos o más rondas. Después de cada ronda, un moderador provee un resumen anónimo de los juicios y razones de cada experto en la ronda previa. Para esta investigación, los DC para el algoritmo FAHP fueron propuestos inicialmente a partir de todos los parámetros reportados en la literatura actual sobre SH para CRN, y finalmente fueron seleccionados con una modificación del método Delphi propuesta en Hernández, Salgado et al. (2015). La contribución al método Delphi es el concepto de *experto* en sí mismo, definido como el profesional inmerso en la administración y operación de red, así como la propuesta del método Delphi modificado, la cual consiste en considerar dos entradas en lugar de una para cada ronda. Para la primera ronda y las siguientes, se consideraron dos entradas: la decisión de un Consejo de Administradores de Red (CAR), compuesto por nueve expertos seleccionados aleatoriamente, y el *ranking del impacto de las variables* (RIV) que influyen en el proceso de SH y que están reportadas en la literatura.

La segunda ronda del método Delphi implementado consideró las trece variables seleccionadas durante la primera ronda del proceso y el RIV actualizado. El CAR determinó cuáles de las trece variables eran significativas, si debían adicionarse nuevas o si se debía modificar o descartar algunas, lo cual se combinó con las estadísticas del RIV y se actualizó. En caso de presentarse desacuerdo entre miembros del CAR, se desarrolla un análisis global combinado con las estadísticas del RIV, y luego, un segundo conjunto de variables es propuesto para la tercera ronda, con el mismo procedimiento. Este proceso se repite iterativamente hasta alcanzar un consenso general por parte del CAR combinado con las estadísticas del RIV. En el método Delphi propuesto, si el consenso no se da antes de la quinta ronda, la decisión final es tomada

con base en las estadísticas finales del RIV. Para este caso, el consenso se logró en la tercera ronda, en la cual se descartaron ocho variables.

Después de tres rondas del método Delphi modificado, cinco variables fueron seleccionadas por la combinación del CAR y las estadísticas del RIV. Estas fueron: clase de servicio del SU (RT y BE), AP, ETA, SINR y BW. El siguiente paso fue organizar los DC en criterios y subcriterios para el objetivo de seleccionar la mejor SO para el SU. Se consideró que la variable *clase de servicio* es más general que las otras, por lo que se decidió seleccionarla como criterio, clasificándola como RT y BE, y se consideraron las otras cuatro variables como subcriterios de la clase de servicio. Así, en esta investigación, el criterio *clase de servicio* es determinado por la aplicación del SU, y se considera que el objetivo es el mismo para RT y BE (seleccionar la mejor SO); sin embargo, la importancia (ponderación) de cada subcriterio es diferente y corresponde al enfoque de las aplicaciones RT y BE.

Los cuatro subcriterios fueron medidos y calculados a partir de datos experimentales de ocupación espectral capturados en las bandas GSM y Wi-Fi.

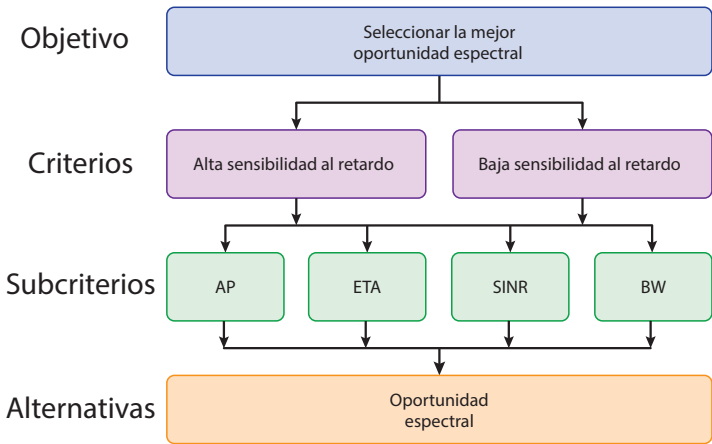
Estructura jerárquica

La estructura jerárquica del algoritmo FAHP se construyó con base en el objetivo, los criterios, los subcriterios y las alternativas seleccionadas (figura 59).

Matrices de juicio

De acuerdo con el método AHP, una vez diseñada la jerarquía, se construyen las matrices de juicios, las cuales corresponden a las evaluaciones comparativas que definen el nivel de importancia relativa entre cada combinación posible de parejas de criterios, subcriterios y alternativas, de forma independiente. Sin embargo, debido a que solo se tienen dos únicos criterios —RT y BE, los cuales son mutuamente excluyentes, cada uno con los mismos cuatro subcriterios—, no tiene sentido realizar una matriz de juicios para este nivel. En el caso de las alternativas, debido a que las SO modifican sus características (subcriterios) dinámicamente en el tiempo, tampoco tendría sentido realizar una matriz de juicios a este nivel, por lo que se decidió que el algoritmo FAHP evaluara dinámicamente el conjunto de alternativas.

Figura 59. Estructura propuesta para el algoritmo FAHP



Fuente: elaboración propia.

De acuerdo con Büyüközkan et al. (2004),

las personas encargadas de la toma de decisiones usualmente se sienten mejor presentando sus juicios como un intervalo en vez de dar un valor puntual y fijo. Esto se debe a que él, ella o ellos son incapaces de explicar sus preferencias, dada la naturaleza difusa de los procesos de comparación humana. (pp. 260-261; traducción propia)


Por ello, se decidió trabajar con una escala de TFN (números difusos triangulares), presentados en la tabla 26 y la figura 60. La escala de importancia difusa se obtuvo de la conversión de la escala de importancia fundamental de nueve niveles a números difusos presentada por Büyüközkan et al. (2004).

Tabla 26. TFN y TFN recíproco para la escala de importancia de FAHP

Nomenclatura	Escala de importancia	TFN	TFN recíproco
EI	Igualmente importante	$(1/2, 1, 3/2)$	$(2/3, 1, 2)$
MI	Moderadamente más importante	$(1, 3/2, 2)$	$(1/2, 2/3, 1)$
SI	Fuertemente más importante	$(3/2, 2, 5/2)$	$(2/5, 1/2, 2/3)$
VSI	Muy fuertemente más importante	$(2, 5/2, 3)$	$(1/3, 2/5, 1/2)$
XI	Extremadamente más importante	$(5/2, 3, 7/2)$	$(2/7, 1/3, 2/5)$

Fuente: elaboración propia a partir de Büyüközkan et al. (2004); Büyüközkan y Çifçi (2012); Choudhary y Shankar (2012); Cortés (2011); Giupponi y Pérez-Neira (2008); Kaya y Kahraman (2010); Mehbodniya et al. (2012); Patil y Kant (2014), y Zadeh (1965).

Figura 60. TFN para la escala de importancia de FAHP



Fuente: elaboración propia.

Una matriz de juicios de n criterios o subcriterios está descrita por la ecuación (115):

$$A = [a_{ij}]_{n \times n} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix} \quad (115),$$

donde $i = j = 1, 2, \dots, n$, y n es el número de criterios o subcriterios.

Para el caso del algoritmo FAHP, las matrices de juicios que contienen los TFN representan las comparaciones por parejas entre subcriterios (Mehbodniya et al., 2012), como lo describe la ecuación (116):

$$\tilde{A}(\tilde{a}_{ij})_{n \times n} = \begin{bmatrix} (0.5, 1, 1.5) & (l_{12}, m_{12}, u_{12}) & \cdots & (l_{1n}, m_{1n}, u_{1n}) \\ (l_{21}, m_{21}, u_{21}) & (0.5, 1, 1.5) & \cdots & (l_{2n}, m_{2n}, u_{2n}) \\ \vdots & \vdots & \ddots & \vdots \\ (l_{n1}, m_{n1}, u_{n1}) & (l_{n2}, m_{n2}, u_{n2}) & \cdots & (0.5, 1, 1.5) \end{bmatrix} \quad (116),$$

$$\text{donde } (\tilde{a}_{ij}) = [\tilde{a}_{ij}]^{-1} = (l_{ij}, m_{ij}, u_{ij})^{-1} = \left(\frac{1}{u_{ij}}, \frac{1}{m_{ij}}, \frac{1}{l_{ij}} \right).$$

Los elementos de la diagonal de cada matriz corresponden a la igualdad, a razón de que compara la importancia entre los mismos subcriterios. La mitad diagonal superior de cada matriz describe la importancia relativa del subcriterio de la primera columna con respecto al subcriterio de la primera fila.

Con base en la escala de importancia difusa presentada en la tabla 26 y la figura 60, y a partir el método Delphi modificado, se determinó el nivel de importancia relativa de cada par de subcriterios y se construyeron las matrices de juicios para los subcriterios. La matriz de juicios preliminar se construyó con los resultados de la primera ronda del método Delphi modificado. Además, los resultados de la primera ronda fueron usados en la segunda tanto para el enfoque RT como para el BE. El proceso de decisión se repite hasta que los resultados convergen; estos son presentados en las matrices de juicio para los subcriterios con el enfoque de RT (tabla 27) y para los subcriterios con el enfoque de BE (tabla 28).

Tabla 27. Matriz de juicios para los subcriterios de tiempo real

Subcriterio	AP	ETA	SINR	BW
AP	(1/2, 1, 3/2) EI	(1, 3/2, 2) MI	(3/2, 2, 5/2) SI	(3/2, 2, 5/2) SI
ETA	(1/2, 2/3, 1) 1/MI	(1/2, 1, 3/2) EI	(3/2, 2, 5/2) SI	(3/2, 2, 5/2) SI
SINR	(2/5, 1/2, 2/3) 1/SI	(2/5, 1/2, 2/3) 1/SI	(1/2, 1, 3/2) EI	(1, 3/2, 2) MI
BW	(2/5, 1/2, 2/3) 1/SI	(2/5, 1/2, 2/3) 1/SI	(1/2, 2/3, 1) 1/MI	(1/2, 1, 3/2) EI

Fuente: elaboración propia.

Tabla 28. Matriz de juicios para los subcriterios de mejor esfuerzo

Subcriterio	AP	ETA	SINR	BW
AP	(1/2, 1, 3/2) EI	(1, 3/2, 2) MI	(1/3, 2/5, 1/2) 1/VSI	(1/3, 2/5, 1/2) 1/VSI
ETA	(1/2, 2/3, 1) 1/MI	(1/2, 1, 3/2) EI	(2/5, 1/2, 2/3) 1/SI	(2/5, 1/2, 2/3) 1/SI
SINR	(2, 5/2, 3) VSI	(3/2, 2, 5/2) SI	(1/2, 1, 3/2) EI	(3/2, 2, 5/2) SI
BW	(2, 5/2, 3) VSI	(3/2, 2, 5/2) SI	(2/5, 1/2, 2/3) 1/SI	(1/2, 1, 3/2) EI

Fuente: elaboración propia.

Las aplicaciones RT y BE tienen diferentes enfoques: para RT, los subcriterios con más alta prioridad son los que reducen el retardo, como AP y ETA, y para BE, los subcriterios con más alta prioridad son los que incrementan la tasa de datos, como BW y SINR.

Cálculo de los pesos normalizados

Con las matrices de juicios definidas, se procedió a calcular los pesos normalizados para cada subcriterio, con base en el modelo propuesto por Mehbodniya et al. (2012). Estos resultados están basados en el análisis difuso extendido presentado en Chang (1996), como se describe a continuación.

El valor del i -ésimo objeto del análisis extendido es definido como se muestra en la ecuación (117):

$$\tilde{S}_i = \sum_{j=1}^n \tilde{a}_{ij} \left[\sum_{i=1}^n \sum_{j=1}^n \tilde{a}_{ij} \right]^{-1} \quad (117),$$

donde $\sum_{j=1}^n \tilde{a}_{ij} = \left(\sum_{j=1}^n l_{ij}, \sum_{j=1}^n m_{ij}, \sum_{j=1}^n u_{ij} \right)$.

La matriz inversa de la ecuación (117) se calcula a partir de la ecuación (118):

$$\left[\sum_{i=1}^n \sum_{j=1}^n \tilde{a}_{ij} \right]^{-1} = \left(\frac{1}{\sum_{i=1}^n \sum_{j=1}^n u_{ij}}, \frac{1}{\sum_{i=1}^n \sum_{j=1}^n m_{ij}}, \frac{1}{\sum_{i=1}^n \sum_{j=1}^n l_{ij}} \right) \quad (118).$$

El grado de posibilidad de que un número difuso convexo sea más grande que k números difusos convexos está dado por la ecuación (119):

$$V(\tilde{S} \geq \tilde{S}_i) = V[(\tilde{S} \geq \tilde{S}_1) \wedge (\tilde{S} \geq \tilde{S}_2) \dots (\tilde{S} \geq \tilde{S}_k)] = \min \{V(\tilde{S} \geq \tilde{S}_i)\} \quad (119),$$

donde el grado de posibilidad de que $\tilde{S}_1 \geq \tilde{S}_2$ y $\tilde{S}_2 \geq \tilde{S}_1$ está dado por las ecuaciones (120) y (121), respectivamente:

$$V(\tilde{S}_1 \geq \tilde{S}_2) = \begin{cases} 1 & m_1 \geq m_2 \\ 0 & l_2 \geq u_1 \\ \frac{l_2 - u_1}{(m_1 - u_1) - (m_2 - l_2)}, & otherwise \end{cases} \quad (120);$$

$$V(\tilde{S}_2 \geq \tilde{S}_1) = \begin{cases} 1 & m_2 \geq m_1 \\ 0 & l_1 \geq u_2 \\ \frac{l_2 - u_1}{(m_2 - u_2) - (m_1 - l_1)}, & otherwise \end{cases} \quad (121).$$

Ahora, asumiendo que $d'_1 = \min\{V(\tilde{S}_1 \geq \tilde{S}_2)\}$, el vector de pesos es $w' = (d'_1, d'_2, \dots, d'_n)$.

Finalmente, después de la normalización, el vector de pesos no difuso está dado por la ecuación (122):

$$W = (d_1, d_2, \dots, d_n)^T = \left(\frac{d'_1}{\sum_{i=1}^n d'_i}, \frac{d'_2}{\sum_{i=1}^n d'_i}, \dots, \frac{d'_n}{\sum_{i=1}^n d'_i} \right) \quad (122).$$

A partir del procedimiento anterior, se muestran los resultados del vector de pesos correspondiente al criterio RT (tabla 29) y del vector correspondiente al criterio BE (tabla 30).

Tabla 29. Pesos normalizados de los subcriterios de tiempo real

Subcriterio RT	AP	ETA	SINR	BW
Pesos normalizados	0,3593	0,2966	0,1970	0,1471

Fuente: elaboración propia.

Tabla 30. Pesos normalizados de los subcriterios de mejor esfuerzo

Subcriterio BE	AP	ETA	SINR	BW
Pesos normalizados	0,1607	0,1523	0,3949	0,2921

Fuente: elaboración propia.

Los pesos normalizados describen el grado de importancia relativa de cada subcriterio para la selección del canal de respaldo según el criterio de RT o BE. Por ejemplo, en el caso de que un SU requiera un canal de respaldo para una aplicación de TR, la selección de dicho canal dependerá en un 36 % de la AP del canal, en un 30% del ETA del canal, en un 20% de la SINR del canal y en un 14% del BW del canal, aproximadamente.

Los pesos descritos en las tablas 29 y 30 se utilizan para configurar cada uno de los cuatro algoritmos de decisión espectral a evaluar comparativamente.

Algoritmo multivariable difuso realimentado

En el algoritmo FFAHP, el puntaje de cada SO es calculado a partir de los pesos obtenidos con FAHP, usando la ecuación (123) para el enfoque RT y la ecuación (124) para el enfoque BE. La SO con el puntaje más alto es la SO objetivo; la SO con el segundo puntaje más alto es la SO de respaldo, y las siguientes son SO candidatas en orden de mayor a menor puntaje.

$$Score_i_{_RT} = AP \times 0,3593 + ETA \times 0,2966 + SINR \times 0,1970 + BW \times 0,1471 \tag{123};$$

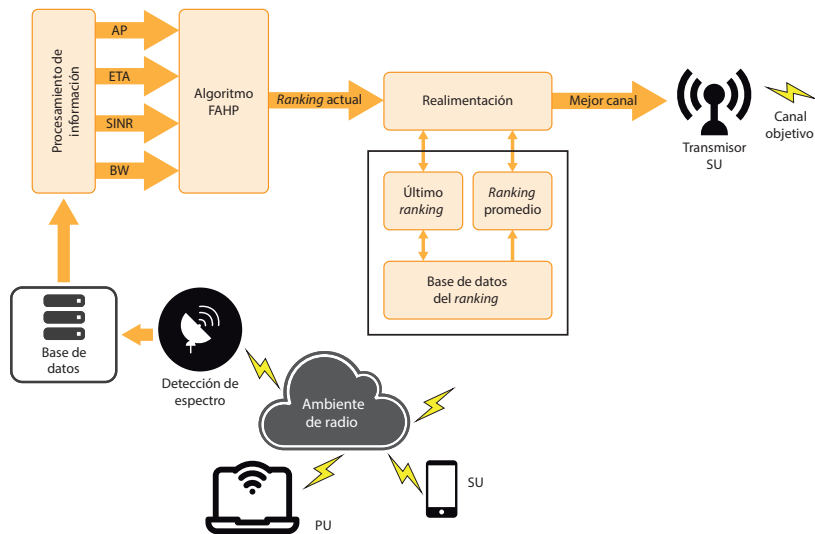
$$Score_j_{_BE} = AP \times 0,1607 + ETA \times 0,1523 + SINR \times 0,3949 + BW \times 0,2921 \tag{124},$$

donde *Score i* es el puntaje asignado a la SO *i* para la aplicación RT y *Score j* es el puntaje asignado a la SO *j* para la aplicación BE.

El algoritmo FFAHP propuesto tiene por objetivo incrementar la precisión en la selección de la SO. Para lograr esto, FFAHP realimenta la información de las evaluaciones de las SO realizadas anteriormente. Así, la selección de la SO se realiza con base en la evaluación de la información actual del espectro y en las evaluaciones pasadas.

Inicialmente, el proceso de detección de espectro captura la información de frecuencia, potencia y tiempo. La cantidad de datos capturados dependerá de los parámetros de RBW, *span* y tiempo de barrido, configurados en el analizador de espectro (Pedraza et al., 2016); los datos capturados son almacenados en una base de datos. Periódicamente, la unidad de procesamiento de información calcula el valor de los DC —AP, ETA, SINR y BW— y los normaliza sobre una base de 100. El algoritmo FAHP recibe los valores actualizados de cada DC y procede a evaluar cada SO. Si la aplicación es de RT, utiliza la ecuación (123), y si es de BE, utiliza la ecuación (124). El rango del puntaje de evaluación puede estar entre 0 y 100, siendo 100 el mejor puntaje posible. La figura 61 ilustra el diseño del algoritmo FFAHP.

Figura 61. Esquema del algoritmo FFAHP propuesto



Fuente: elaboración propia.

En esta parte del proceso se tiene un *ranking* de cada una de las SO con base únicamente en la información actual de los DC; sin embargo, la SO con la mejor evaluación hasta el momento puede no ser la seleccionada finalmente, debido a que este valor de evaluación se pondera con las evaluaciones realizadas en el pasado. El proceso de realimentación recibe las evaluaciones actuales (PS) de cada SO y las pondera con el valor de la última evaluación reciente (LS) y con el promedio de las evaluaciones (AS) realizadas en la última hora. Esta ponderación da como resultado el *ranking* definitivo de las SO. El procedimiento anterior se describe en la ecuación (125):

$$Final_Score_{ij} = \alpha \times PS + \beta \times LS + (1 - \alpha - \beta) \times AS \quad (125),$$

donde α y $\beta \in [0,1]$ y $Final_Score_{ij}$ es el valor de la evaluación final de la SO i o j .

La SO con la mejor evaluación final es la seleccionada para realizar la transmisión de los datos del SU. Posteriormente, el bloque de realimentación transfiere el valor de PS a LS y actualiza el valor de AS de acuerdo con el nuevo valor de LS. Si la SO seleccionada finalmente se encuentra ocupada, el algoritmo FFAHP sobrescribe el valor de LS en cero para la respectiva SO.

Para determinar los valores de α y β , se realizó un análisis experimental autorregresivo con diferentes combinaciones de estas variables para un conjunto de datos predeterminado. Se tomaron los valores de α y β para los cuales la precisión en la selección de la SO fue más alta. Dichos valores corresponden a $\alpha=0,60$ y $\beta=0,35$, con una precisión experimental del 87%.

Métricas de evaluación

Para evaluar el desempeño de los algoritmos de decisión espectral, se determinaron cinco EM, que se describen en la tabla 31, donde se presenta su sigla, nombre, descripción y tipo de EM; este último hace referencia a si la métrica es de beneficio (es mejor si es mayor) o costo (es mejor si es menor). La palabra *promedio* en las EM hace referencia a que los resultados de estas corresponden al promedio de los valores arrojados por varios experimentos realizados.

Tabla 31. Métricas de evaluación utilizadas para los algoritmos FAHP y FFAHP

Sigla	Nombre	Descripción	Tipo de EM
AAH	Número de <i>handoffs</i> promedio acumulado	Es el número total de <i>handoffs</i> realizados durante los 9 minutos de la transmisión del SU.	Costo
AAFH	Número de <i>handoffs</i> fallidos promedio acumulado	Es el número de <i>handoffs</i> que el SU no pudo materializar porque encontró las respectivas SO objetivo ocupadas.	Costo

Sigla	Nombre	Descripción	Tipo de EM
ABW	Ancho de banda promedio	Es el BW promedio utilizado por el SU durante los 9 minutos de la transmisión.	Beneficio
AAD	Retardo promedio acumulado	Es el tiempo promedio total experimentado por el SU durante la transmisión de una determinada cantidad de información.	Costo
AAT	<i>Throughput</i> promedio acumulado	Es la tasa de datos efectiva transmitida por el SU durante los 9 minutos de la transmisión.	Beneficio

Fuente: elaboración propia.

Con el objetivo de facilitar el análisis comparativo de cada algoritmo, se calcularon los valores relativos (en porcentaje) de cada EM. Para las métricas de tipo *beneficio*, se calculó el valor relativo (*Rel*) del algoritmo *i* a partir del valor absoluto (*Abs*) y del valor máximo (*Max*) de la EM, como se describe en la ecuación (126), y para las métricas de tipo *costo*, se calculó el valor relativo (*Rel*) del algoritmo *i* a partir del valor absoluto (*Abs*) y del valor mínimo (*Min*) de la EM, como se describe en la ecuación (127).

$$X_i^{Rel} = \frac{X_i^{Abs}}{X_{Max}^{Abs}} \times 100\% \quad (126);$$

$$X_i^{Rel} = \frac{X_i^{Min}}{X_i^{Abs}} \times 100\% \quad (127).$$

Para el cálculo de los puntajes globales, se ponderó según la ecuación (128), en el caso de los algoritmos híbridos, y como lo describe la ecuación (129), en el caso del algoritmo predictivo.

$$PG_i = 0,225 \times AAH_i + 0,025 \times AAFH_i + 0,25 \times (ABW_i + AAD_i + AAT_i) \quad (128);$$

$$PG_i = 0,02 \times AAFH_i + 0,18 \times AAPH_i + 0,2 \times (AAH_i + AAIH_i + AAEH_i + AAUH_i) \quad (129).$$

Evaluación de los algoritmos de decisión espectral

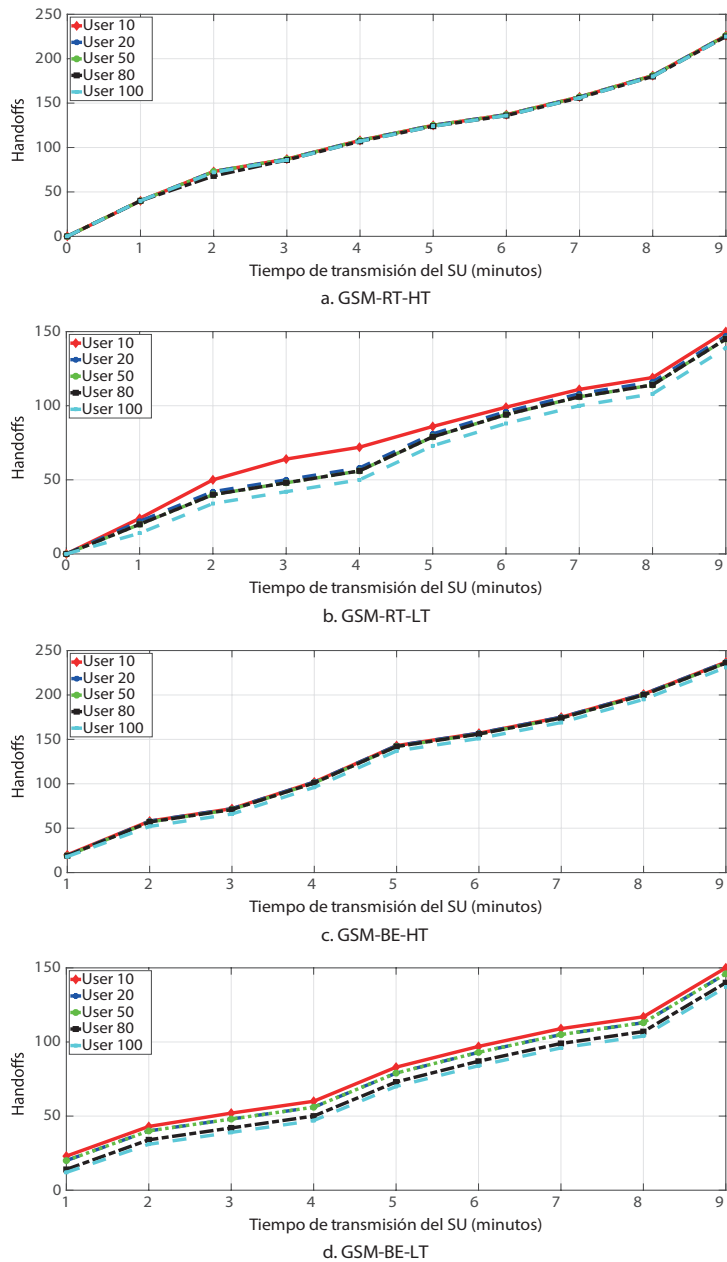
Debido a la gran cantidad de información obtenida a través de las simulaciones realizadas, y con el objetivo de no combinar demasiadas curvas que luego fueran difíciles de leer, se decidió mostrar el desempeño de cada algoritmo individualmente en todas sus situaciones posibles, es decir, para los cinco diferentes niveles de cooperación entre SU (10 %, 20 %, 50 %, 80 % y 100 %), con una traza de HT y LT, con enfoque RT y BE, en las redes GSM y Wi-Fi y para las cinco EM. Lo anterior da un total de 8 figuras por cada escenario (GSM-RT-LT, GSM-RT-HT, GSM-BE-LT, GSM-BE-HT,

Wi-Fi-RT-LT, Wi-Fi-RT-HT, Wi-Fi-BE-LT y Wi-Fi-BE-HT), producto de la combinación de los tres parámetros de interés —tipo de red (GSM y Wi-Fi), nivel de tráfico (LT y HT) y clase de aplicación (RT y BE)—, para cada algoritmo por cada EM, y en cada una de ellas, los cinco niveles de cooperación, para un gran total de 160 figuras que fueron agrupadas por algoritmo y tipo de red para sintetizarlas en 40 figuras, que se describen a continuación.

Las figuras 62-101 describen las EM AAH, AAFH, ABW, AAD y AAT que se presentan en cada algoritmo de SH durante una transmisión de 9 minutos, para 5 diferentes niveles de cooperación entre SU (10 %, 20 %, 50 %, 80 % y 100 %), con una traza de HT y LT, con enfoque RT y BE y en las redes GSM y Wi-Fi, mientras que las tablas 32-51, por su parte, muestran los correspondientes porcentajes comparativos de desempeño para cada algoritmo en las EM AAH, AAFH, ABW, AAD y AAT, para los 5 diferentes niveles de cooperación entre SU (10 %, 20 %, 50 %, 80 % y 100 %), con una traza de HT y LT, con enfoque RT y BE y en las redes GSM y Wi-Fi.

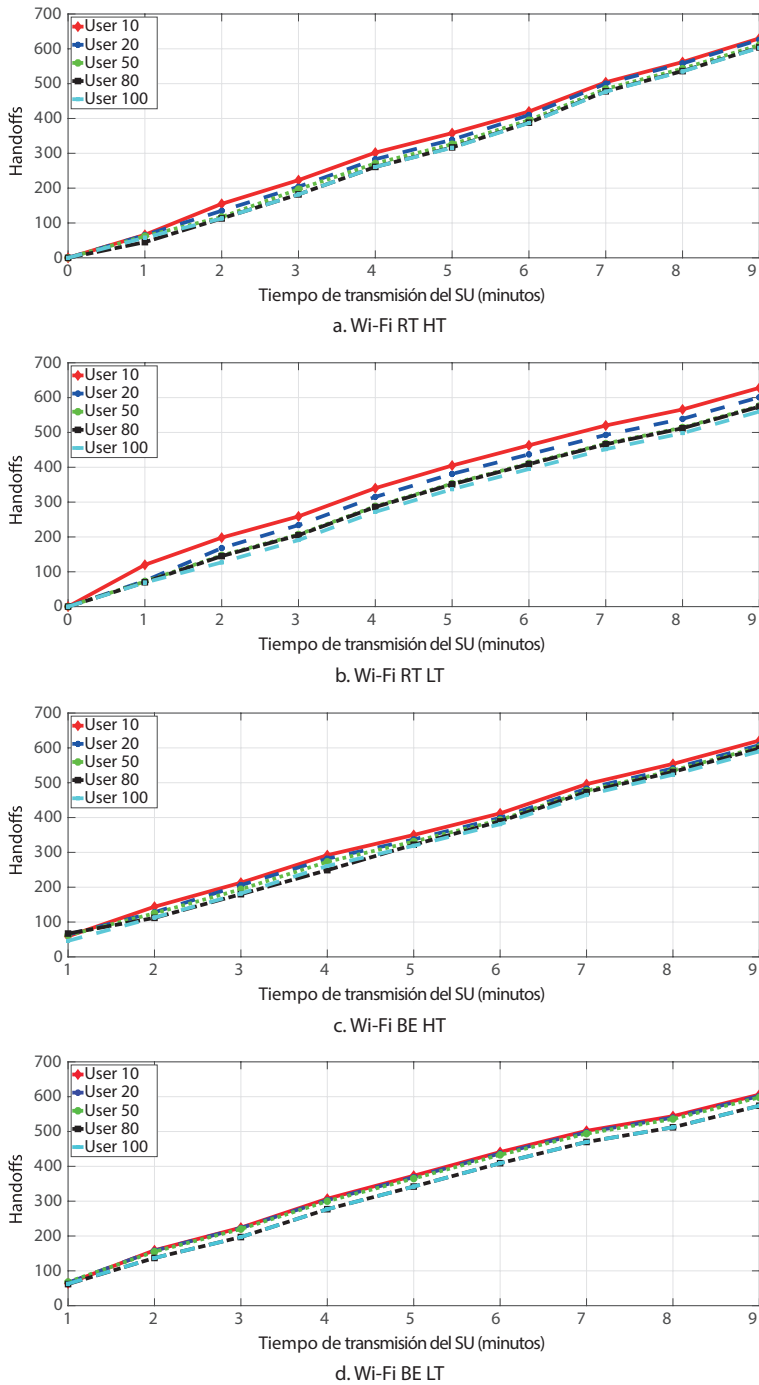
Handoffs totales promedio acumulado

Figura 62. AAH en GSM para el algoritmo FFAHP



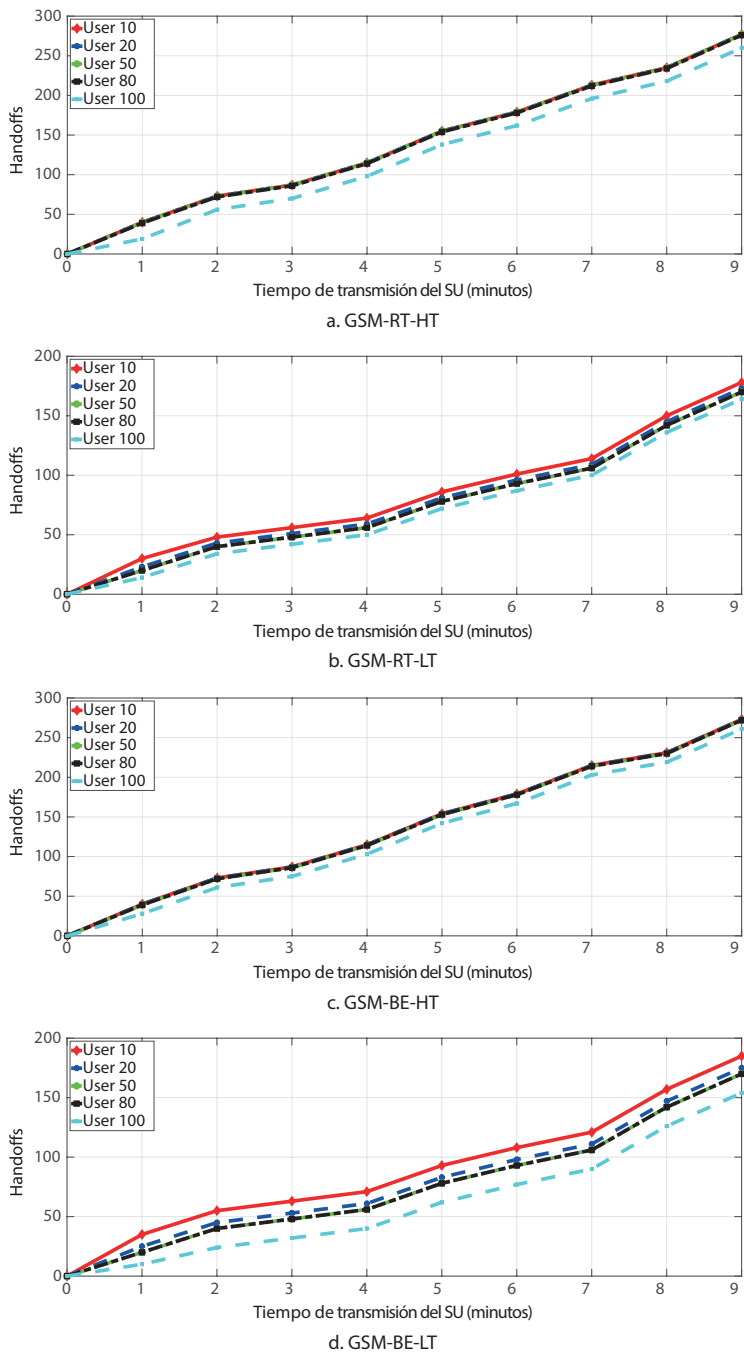
Fuente: elaboración propia.

Figura 63. AAH en Wi-Fi para el algoritmo FFAHP




Fuente: elaboración propia.

Figura 64. AAH en GSM para el algoritmo SAW



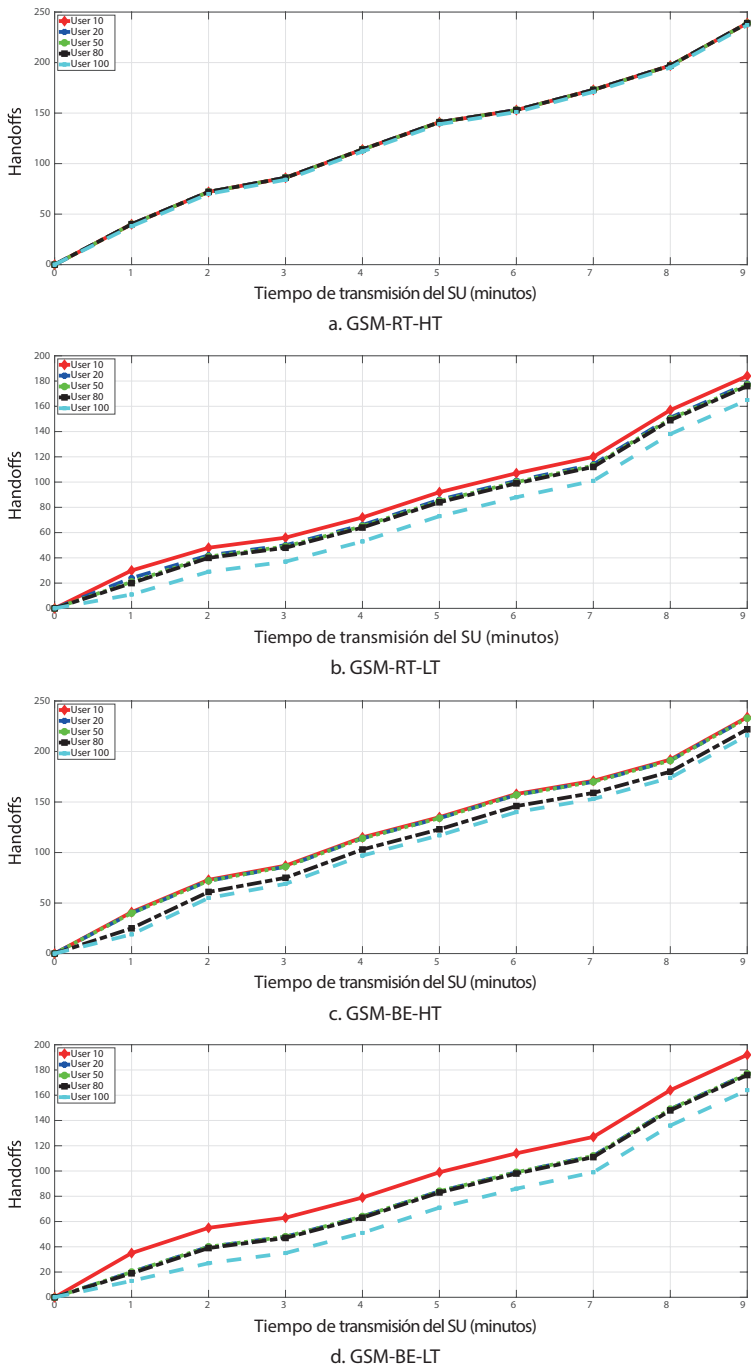
Fuente: elaboración propia.

Figura 65. AAH en Wi-Fi para el algoritmo SAW



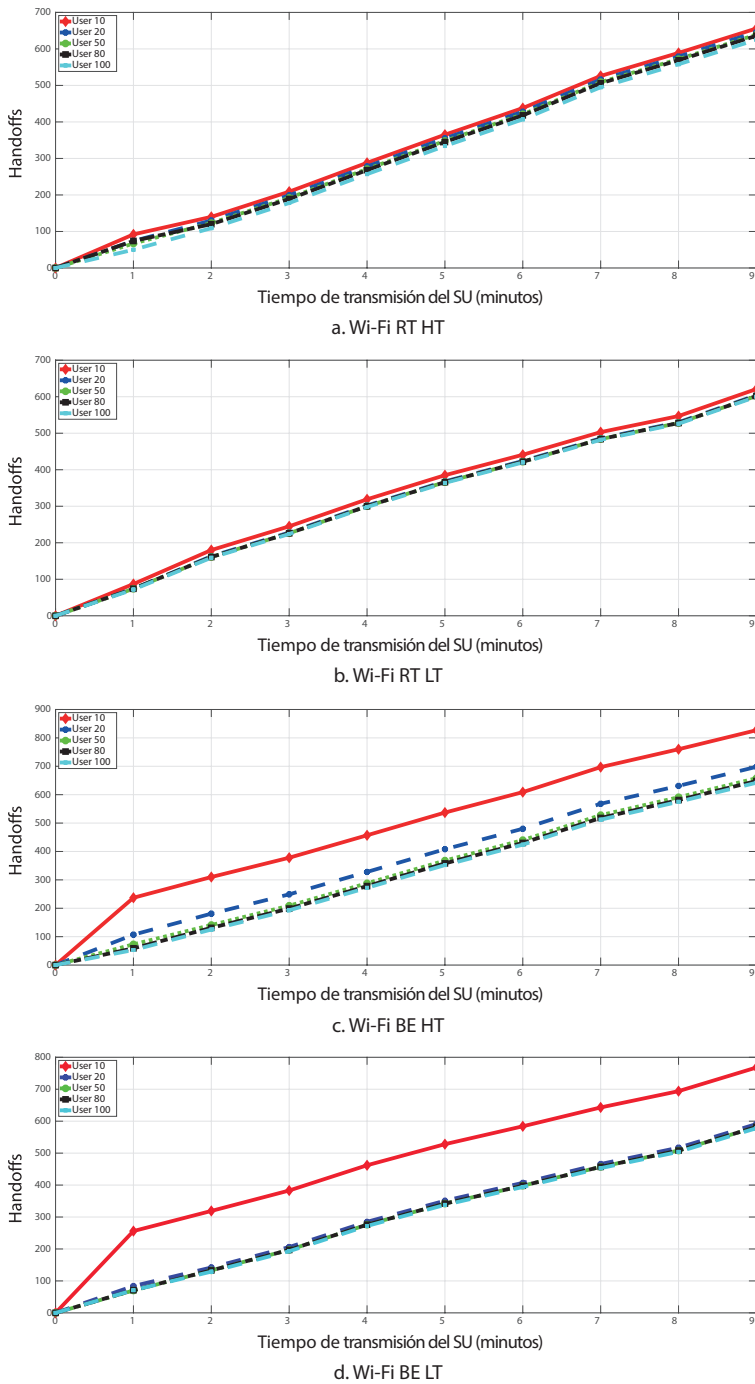
Fuente: elaboraci3n propia.

Figura 66. AAH en GSM para el algoritmo TOPSIS



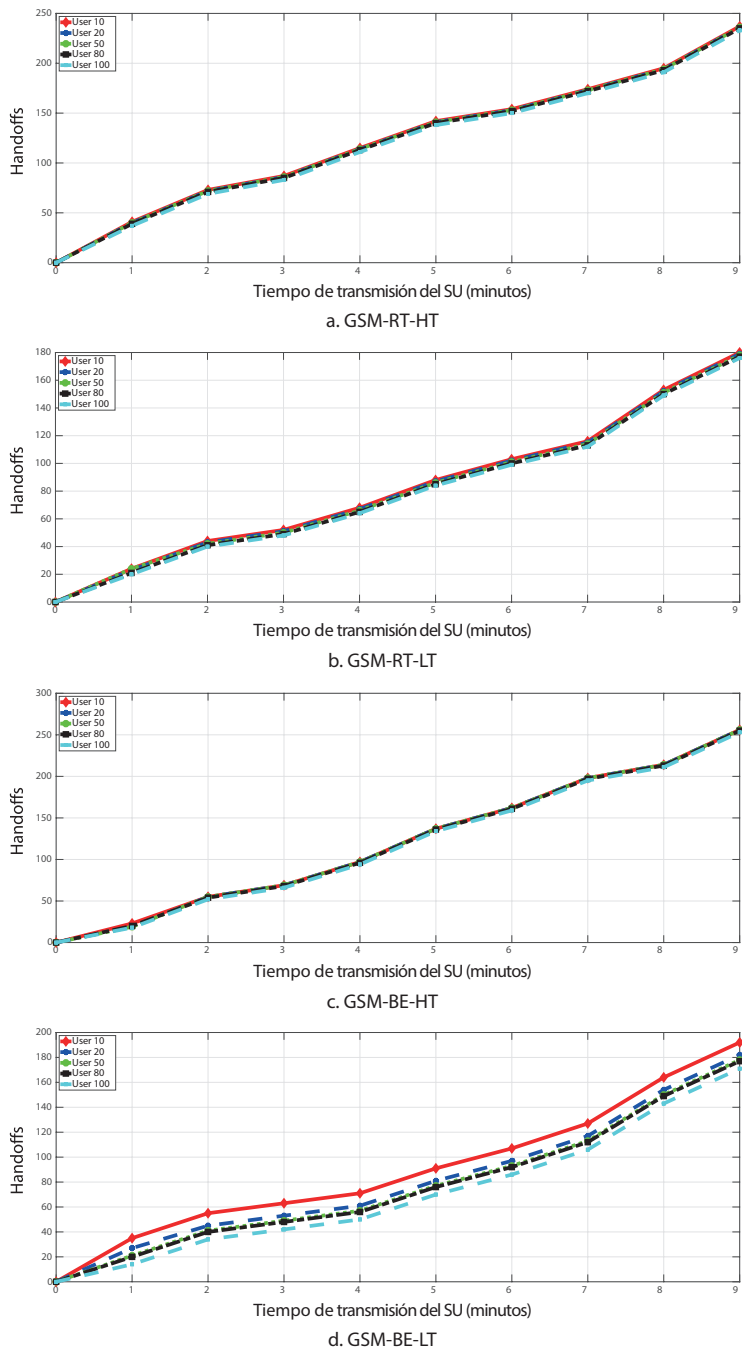
Fuente: elaboración propia.

Figura 67. AAH en Wi-Fi para el algoritmo TOPSIS




Fuente: elaboración propia.

Figura 68. AAH en GSM para el algoritmo VIKOR




Fuente: elaboración propia.


Figura 69. AAH en Wi-Fi para el algoritmo VIKOR




a. Wi-Fi RT HT



b. Wi-Fi RT LT



c. Wi-Fi BE HT



d. Wi-Fi BE LT

Fuente: elaboración propia.

Tabla 32. Valores relativos de AAH para FFAHP

FFAHP	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SU10	SU10	100	100	63,29	100	96,50	97,58	96,19
SU20	SU20	100	99,32	61,60	99,83	100	98,85	96,01
SU50	SU50	99,32	100	61,44	96,32	100	95,68	94,27
SU80	SU80	100	96,55	59,32	100	100	95,99	95,03
SU100	SU100	100	98,56	59,31	97,56	100	94,92	92,87

Fuente: elaboración propia.

Tabla 33. Valores relativos de AAH para SAW

SAW	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SU10	96,22	100	65,20	64,26	100	96,28	82,82	89,47
SU20	98,86	100	63,37	62,45	100	94,56	84,76	88,39
SU50	100	100	62,50	61,37	100	95,19	88,50	88,50
SU80	100	100	62,50	61,59	100	95,00	88,44	89,45
SU100	100	93,90	59,00	59,23	100	95,24	87,95	87,80

Fuente: elaboración propia.

Tabla 34. Valores relativos de AAH para TOPSIS

TOPSIS	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SU10	95,83	100	78,63	76,99	80,86	100	75,09	94,66
SU20	100	99,44	75,97	74,06	100	97,85	84,67	91,49
SU50	100	100	75,97	74,06	100	96,68	88,45	91,08
SU80	100	100	79,28	73,64	100	96,68	89,81	91,51
SU100	100	99,39	75,93	69,20	100	96,33	90,03	92,48

Fuente: elaboración propia.

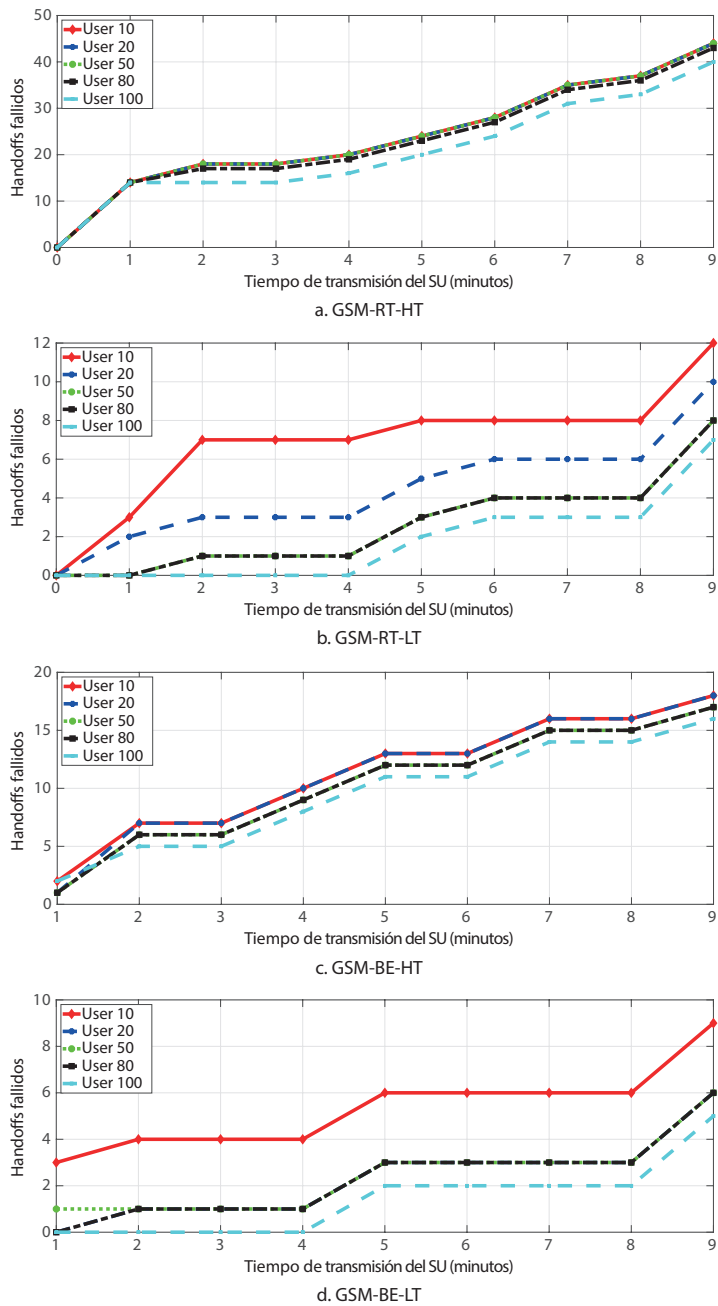
Tabla 35. Valores relativos de AAH para VIKOR

VIKOR	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SU10	93,75	100	70,31	75,95	100	95,84	91,14	84,21
SU20	98,35	100	69,92	75,85	100	97,77	90,49	90,06
SU50	100	100	69,53	75,42	100	98,11	91,20	90,62
SU80	100	100	69,41	75,32	100	98,10	91,48	91,19
SU100	100	97,16	67,59	73,39	100	98,41	90,00	90,58

Fuente: elaboración propia.


Handoffs fallidos promedio acumulado

Figura 70. AAFH en GSM para el algoritmo FFAHP




Fuente: elaboración propia.

Figura 71. AAFH en Wi-Fi para el algoritmo FFAHP




Fuente: elaboración propia.

Figura 72. AAFH en GSM para el algoritmo SAW




Fuente: elaboración propia.


Figura 73. AAFH en Wi-Fi para el algoritmo SAW




a. Wi-Fi RT HT



b. Wi-Fi RT LT



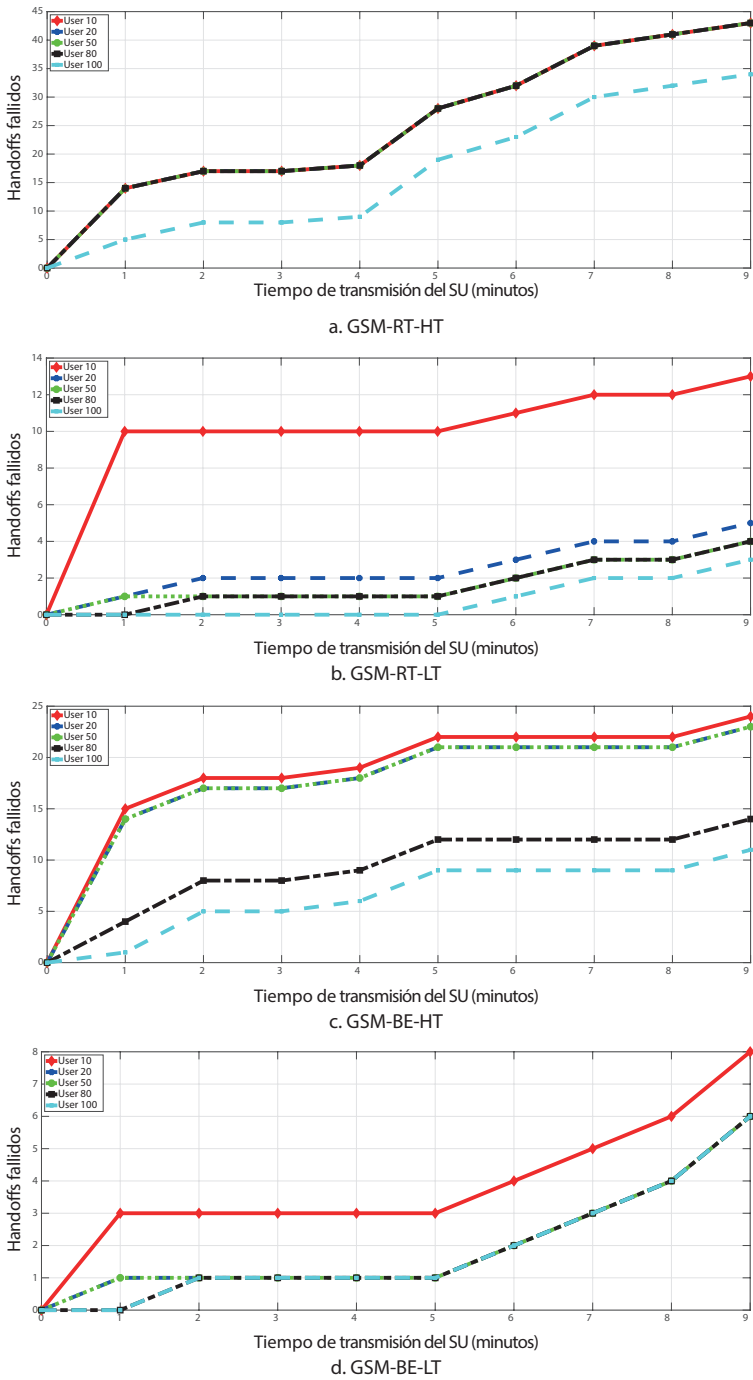
c. Wi-Fi BE HT



d. Wi-Fi BE LT


Fuente: elaboración propia.

Figura 74. AAFH en GSM para el algoritmo TOPSIS




Fuente: elaboración propia.


Figura 75. AAFH en Wi-Fi para el algoritmo TOPSIS




a. Wi-Fi RT HT



b. Wi-Fi RT LT



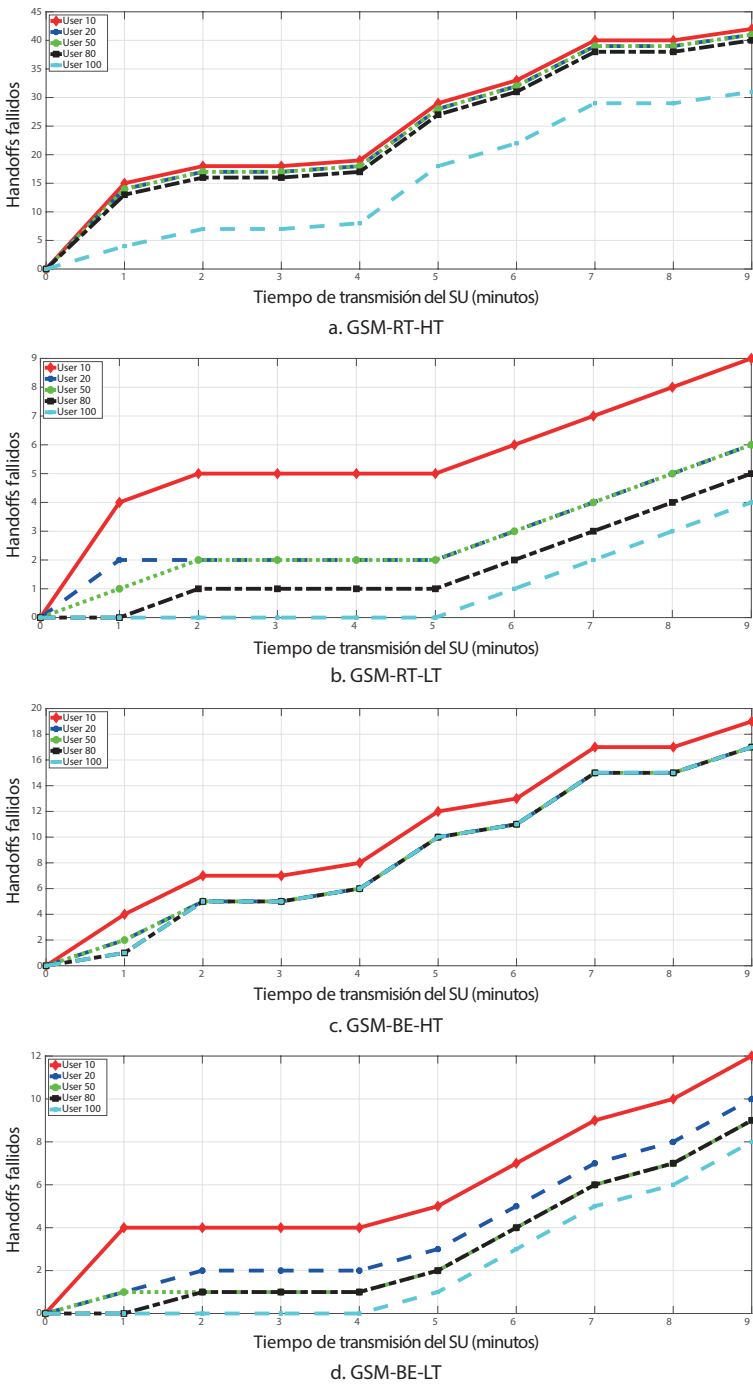
c. Wi-Fi BE HT



d. Wi-Fi BE LT

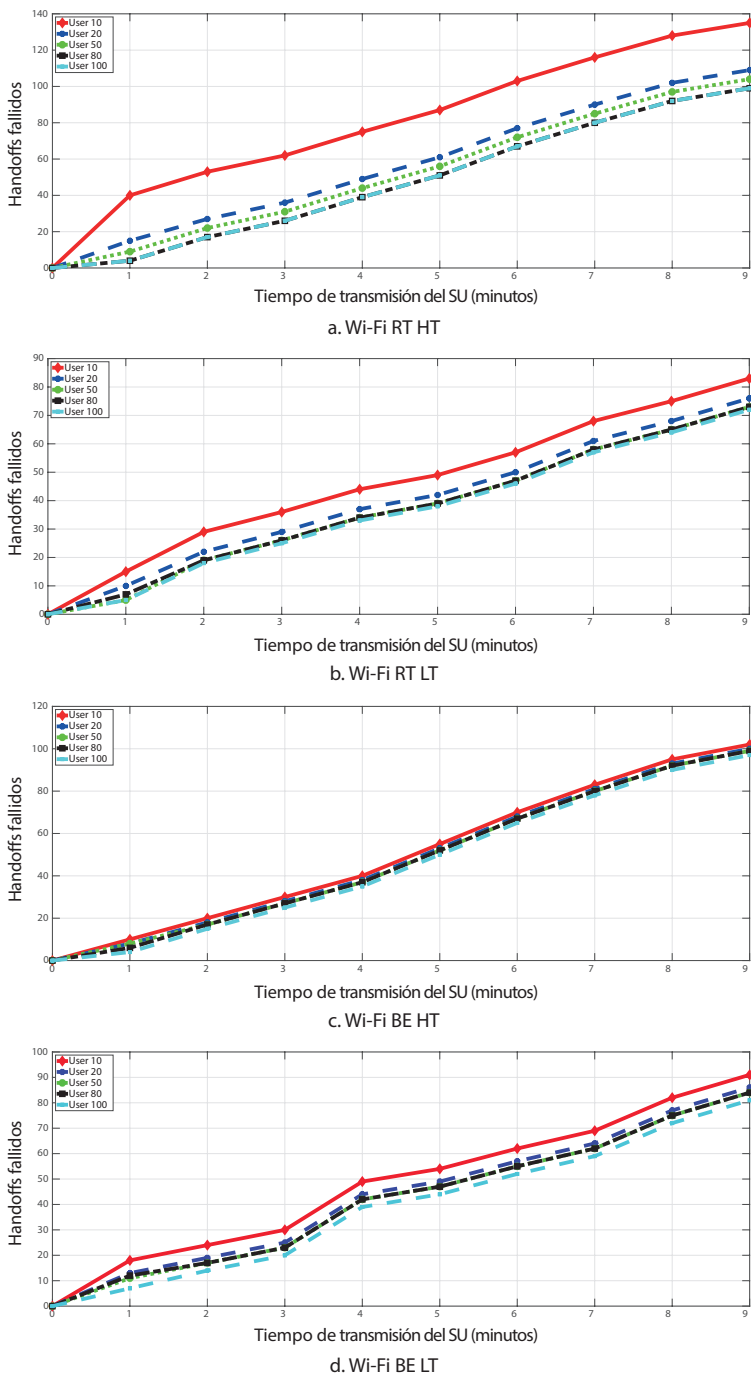
Fuente: elaboración propia.

Figura 76. AAFH en GSM para el algoritmo VIKOR



Fuente: elaboración propia.

Figura 77. AAFH en Wi-Fi para el algoritmo VIKOR



Fuente: elaboración propia.

Tabla 36. Valores relativos de AAFH para FFAHP

FFAHP	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SU10	100	75,00	50,00	20,45	100	84,35	88,99	84,35
SU20	100	60,00	33,33	13,64	100	88,35	87,50	89,22
SU50	100	75,00	35,29	13,64	100	91,67	88,00	92,63
SU80	100	75,00	35,29	13,95	100	84,04	79,80	85,87
SU100	100	71,43	31,25	12,50	100	95,18	82,29	90,80

Fuente: elaboración propia.

Tabla 37. Valores relativos de AAFH para SAW

SAW	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SU10	100	40,00	20,69	20,69	100	86,90	52,90	61,34
SU20	100	85,71	20,69	20,69	100	90,12	63,48	65,77
SU50	100	100	21,43	20,69	100	90,00	66,06	65,45
SU80	100	100	21,43	21,43	100	88,00	61,68	60,00
SU100	100	100	29,41	29,41	100	88,00	62,86	61,68

Fuente: elaboración propia.

Tabla 38. Valores relativos de AAFH para TOPSIS

TOPSIS	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SU10	100	61,54	33,33	18,60	40,65	100	44,44	81,97
SU20	83,33	100	21,74	11,63	97,85	100	65,94	88,35
SU50	66,67	100	17,39	9,30	98,91	100	87,50	90,10
SU80	66,67	100	28,57	9,30	100	100	88,12	89,00
SU100	50,00	100	27,27	8,82	100	96,63	90,53	88,66

Fuente: elaboración propia.

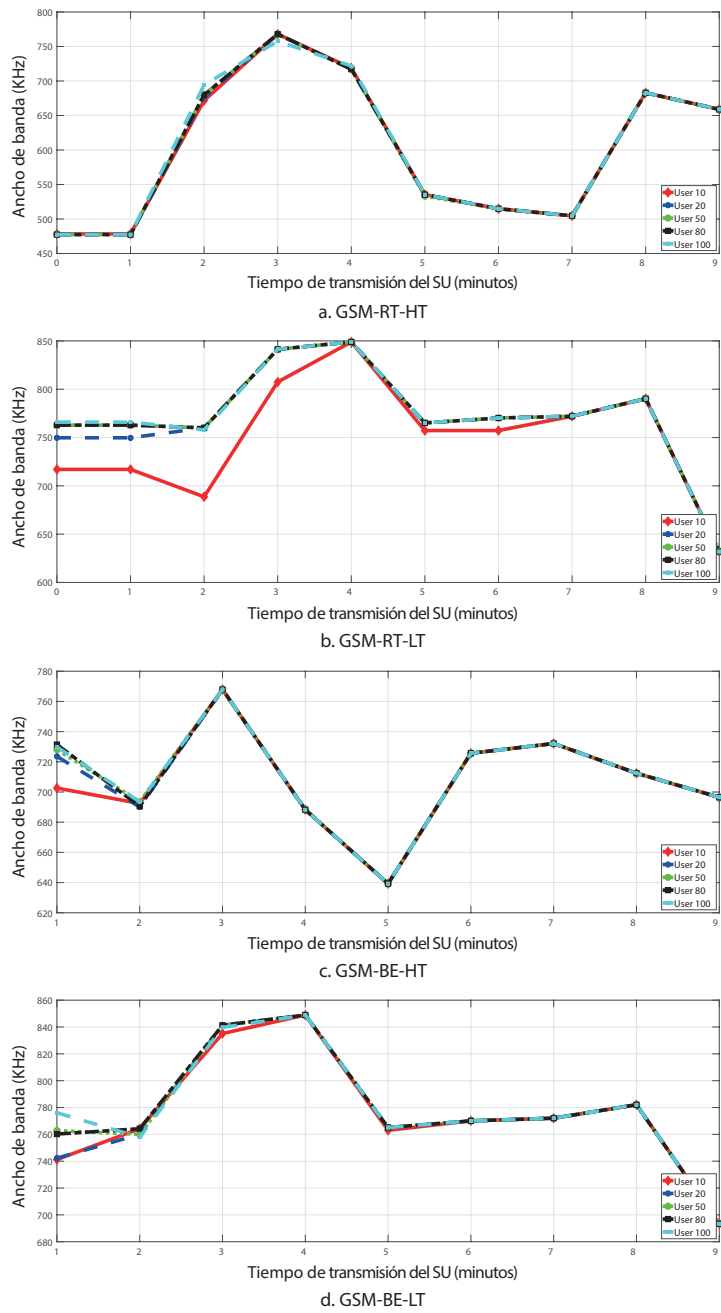
Tabla 39. Valores relativos de AAFH para VIKOR

VIKOR	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SU10	75,00	100	47,37	21,43	91,21	100	81,37	61,48
SU20	60,00	100	35,29	14,63	88,37	100	76,00	69,72
SU50	66,67	100	35,29	14,63	86,90	100	73,74	70,19
SU80	55,56	100	29,41	12,50	86,90	100	73,74	73,74
SU100	50,00	100	23,53	12,90	88,89	100	74,23	72,73

Fuente: elaboración propia.

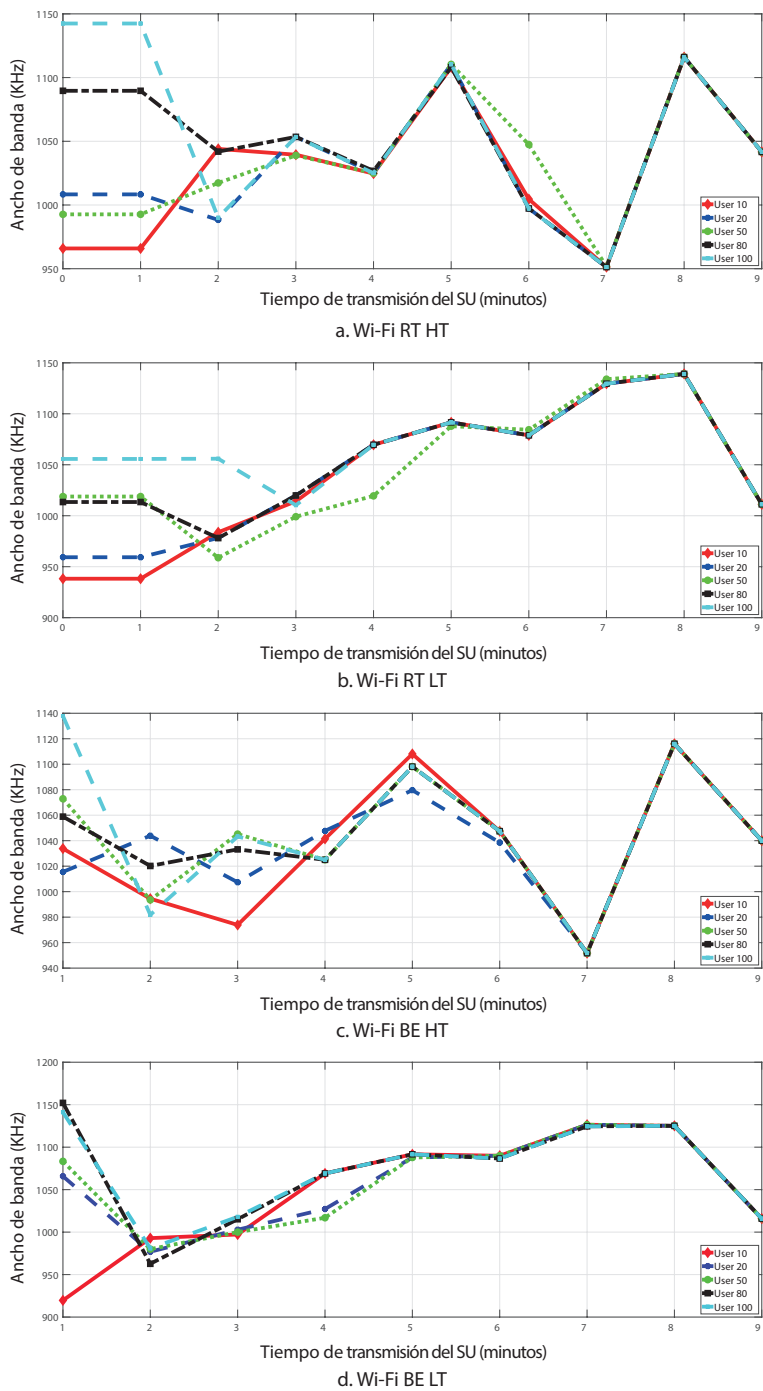
Ancho de banda promedio

Figura 78. ABW en GSM para el algoritmo FFAHP



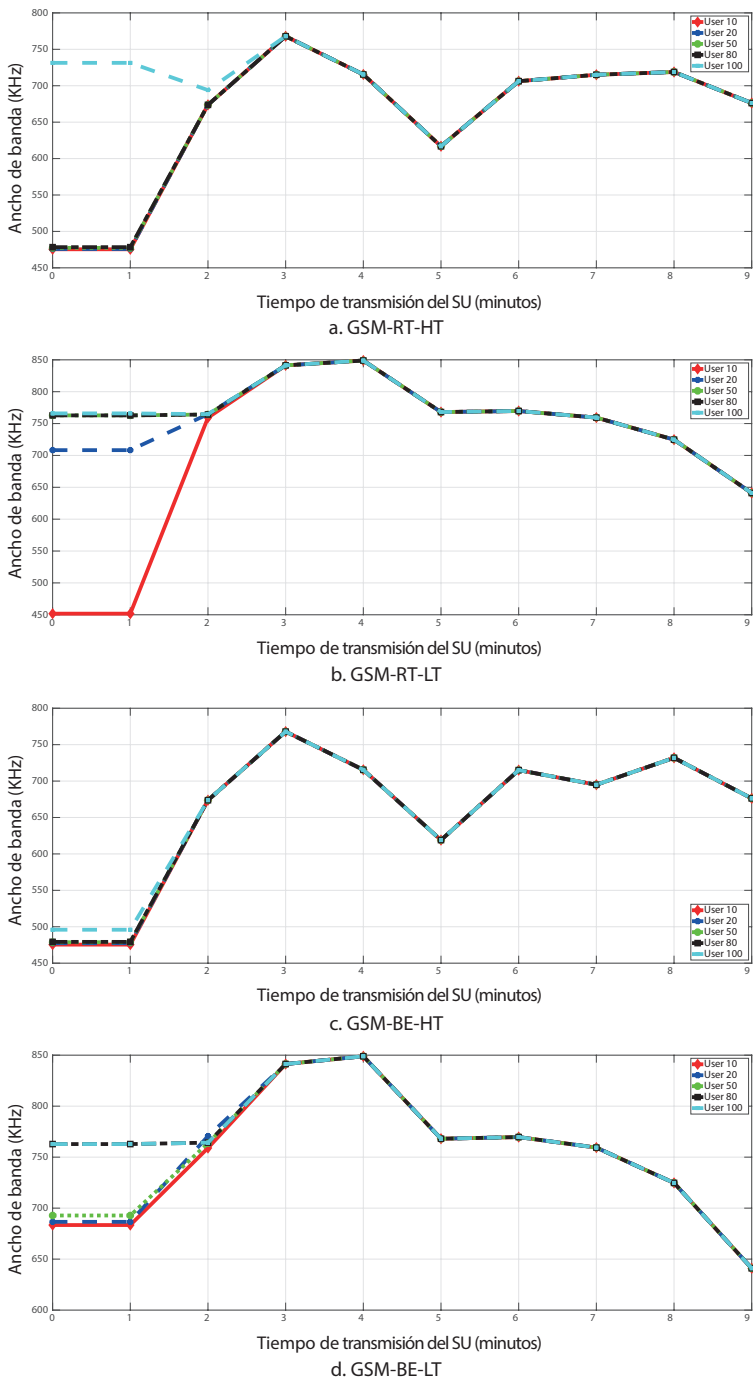
Fuente: elaboración propia.

Figura 79. ABW en Wi-Fi para el algoritmo FFAHP




Fuente: elaboraci3n propia.

Figura 80. ABW en GSM para el algoritmo SAW



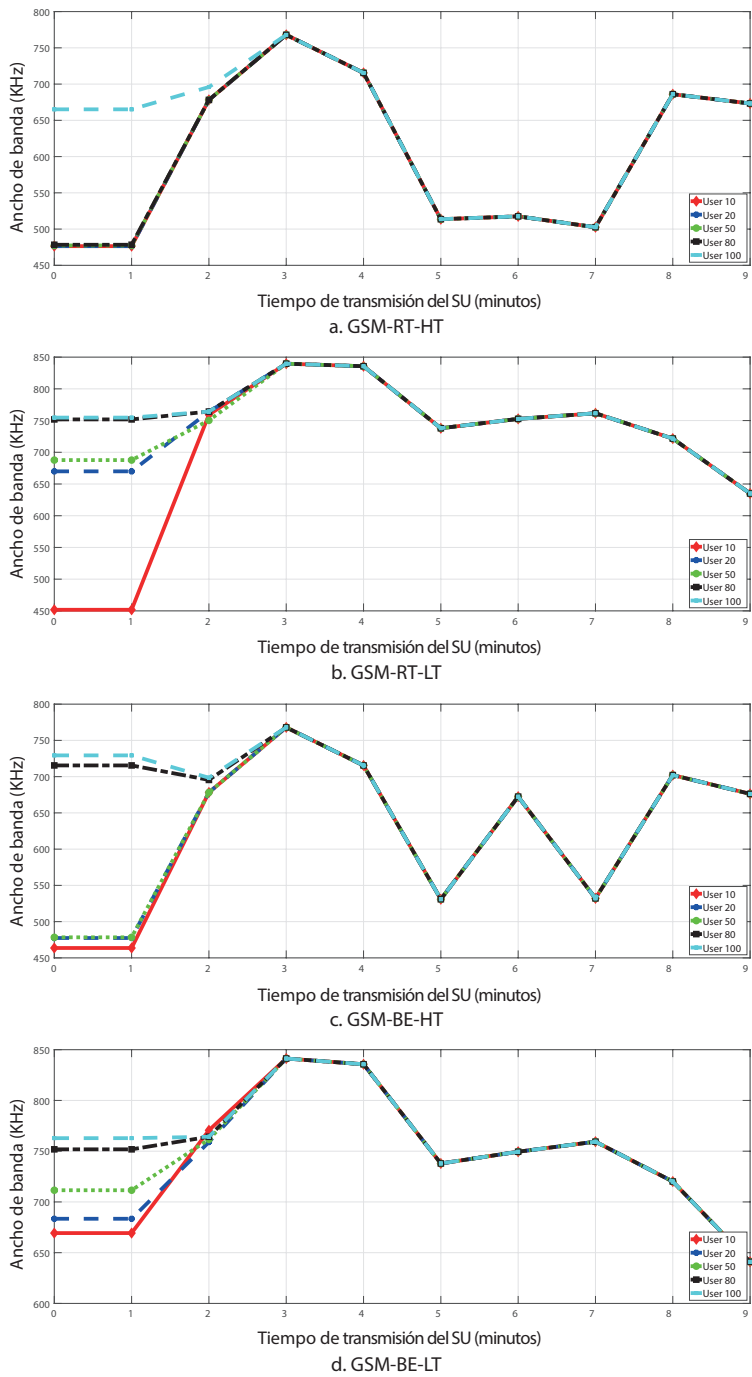
Fuente: elaboración propia.

Figura 81. ABW en Wi-Fi para el algoritmo SAW




Fuente: elaboraci3n propia.

Figura 82. ABW en GSM para el algoritmo TOPSIS




Fuente: elaboración propia.


Figura 83. ABW en Wi-Fi para el algoritmo TOPSIS




a. Wi-Fi RT HT



b. Wi-Fi RT LT



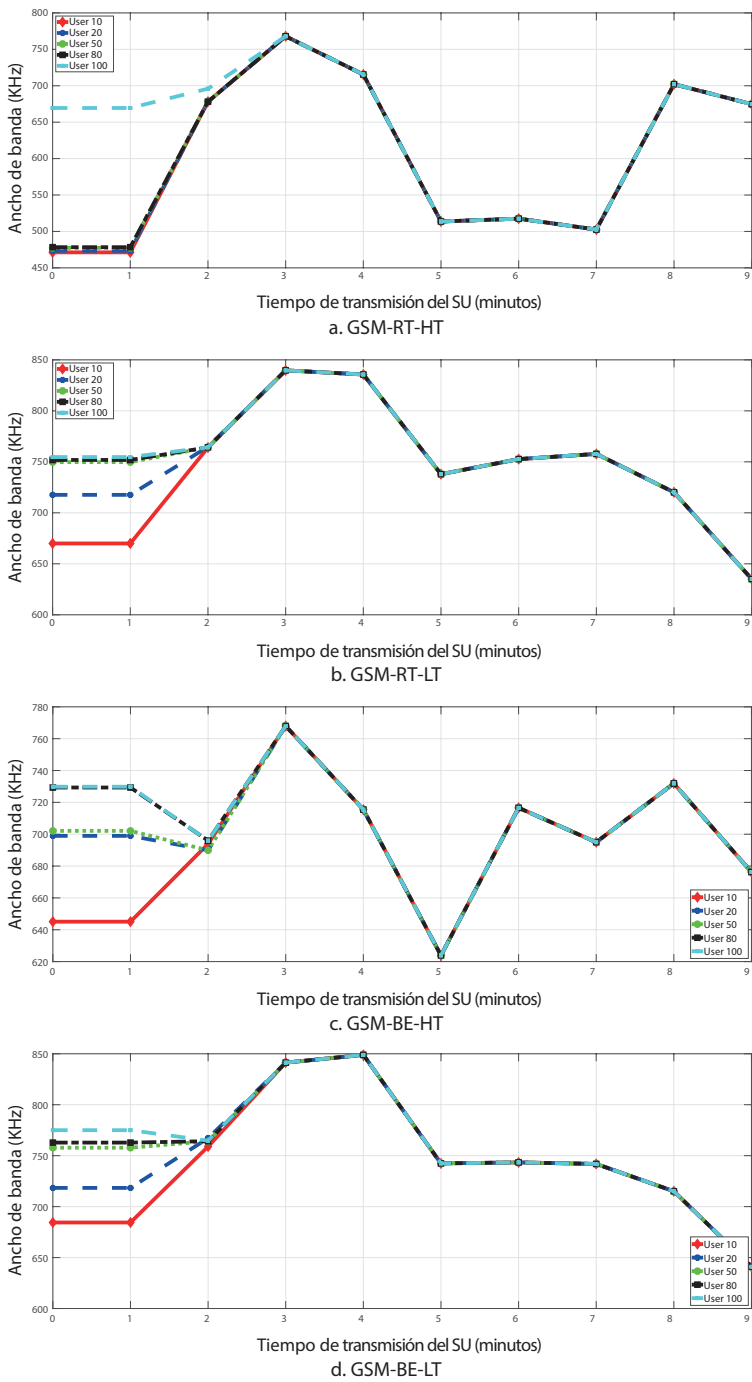
c. Wi-Fi BE HT



d. Wi-Fi BE LT


Fuente: elaboraci3n propia.

Figura 84. ABW en GSM para el algoritmo VIKOR




Fuente: elaboración propia.


Figura 85. ABW en Wi-Fi para el algoritmo VIKOR




a. Wi-Fi RT HT



b. Wi-Fi RT LT



c. Wi-Fi BE HT



d. Wi-Fi BE LT

Fuente: elaboración propia.

Tabla 40. Valores relativos de ABW para FFAHP

FFAHP	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SU10	100	96,68	91,21	77,62	100	99,23	98,72	97,96
SU20	100	99,09	91,41	77,58	100	98,69	98,14	97,40
SU50	100	99,13	91,25	77,38	100	98,94	98,58	97,64
SU80	100	99,11	91,24	77,38	100	98,42	97,38	98,15
SU100	100	99,05	91,15	77,41	100	99,74	97,81	98,55

Fuente: elaboración propia.

Tabla 41. Valores relativos de ABW para SAW

SAW	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SU10	100	93,81	87,52	87,47	100	99,25	94,90	98,21
SU20	99,50	100	86,92	86,83	100	98,50	96,04	97,13
SU50	98,16	100	85,72	85,64	100	98,01	96,49	97,71
SU80	100	100	85,74	85,66	100	99,62	97,39	97,59
SU100	99,91	100	86,10	92,47	100	99,13	97,38	97,26

Fuente: elaboración propia.

Tabla 42. Valores relativos de ABW para TOPSIS

TOPSIS	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SU10	100	93,95	83,89	81,25	93,46	100	92,76	97,14
SU20	100	99,69	84,07	81,07	99,86	100	97,38	99,81
SU50	100	99,20	83,43	80,45	99,82	99,89	99,54	100
SU80	100	99,99	89,02	79,59	98,56	99,04	100	98,69
SU100	100	99,77	89,17	84,53	98,70	99,28	100	99,43

Fuente: elaboración propia.


Tabla 43. Valores relativos de ABW para VIKOR

VIKOR	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SU10	100	99,74	93,37	81,26	100	99,56	99,82	94,76
SU20	99,99	100	93,80	80,48	99,18	100	98,54	97,87
SU50	100	99,85	92,95	79,79	99,32	100	99,03	98,93
SU80	100	99,77	93,62	79,71	99,07	100	99,49	98,48
SU100	100	99,52	93,33	84,72	99,82	100	98,75	97,91


Fuente: elaboración propia.

Retardo promedio acumulado


Figura 86. AAD en GSM para el algoritmo FFAHP




a. GSM-RT-HT



b. GSM-RT-LT



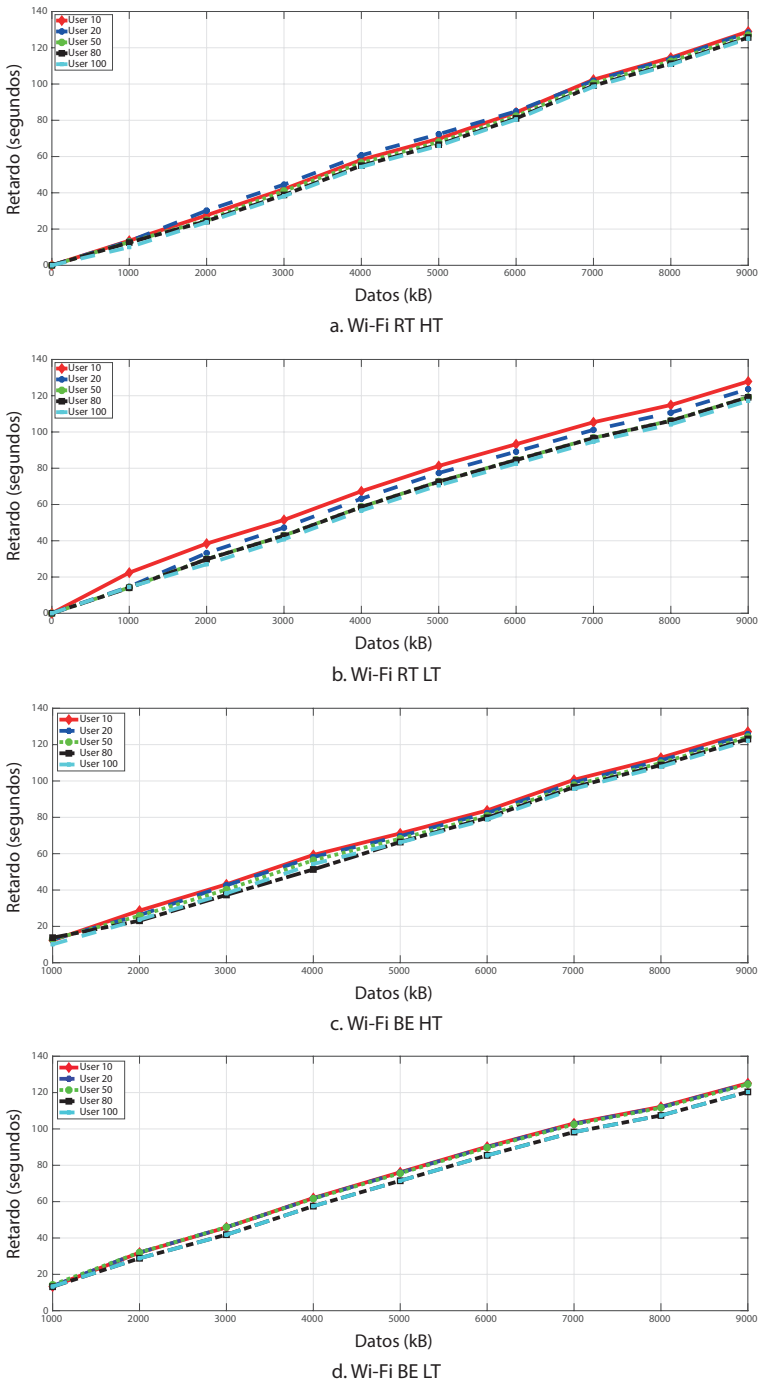
c. GSM-BE-HT



d. GSM-BE-LT


Fuente: elaboración propia.

Figura 87. AAD en Wi-Fi para el algoritmo FFAHP




Fuente: elaboraci3n propia.


Figura 88. AAD en GSM para el algoritmo SAW




a. GSM-RT-HT



b. GSM-RT-LT



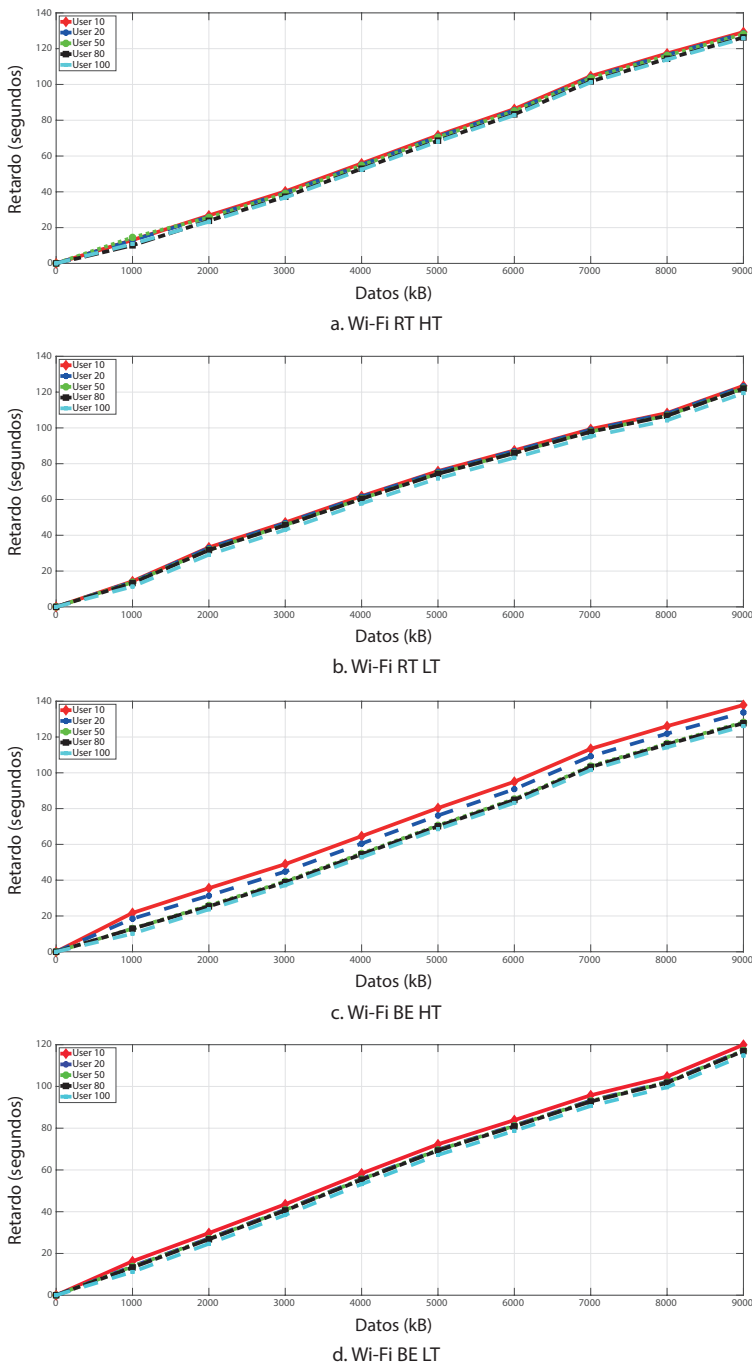
c. GSM-BE-HT



d. GSM-BE-LT

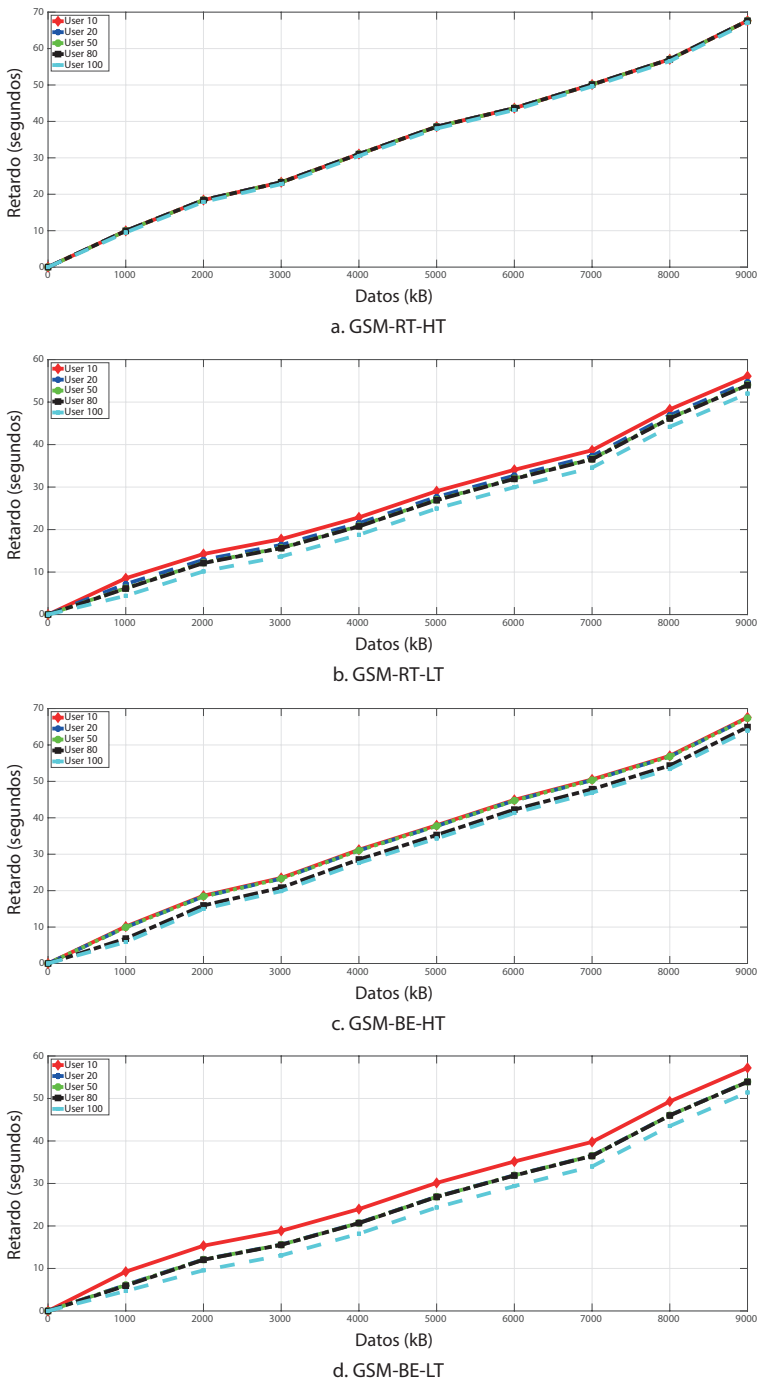
Fuente: elaboración propia.

Figura 89. AAD en Wi-Fi para el algoritmo SAW



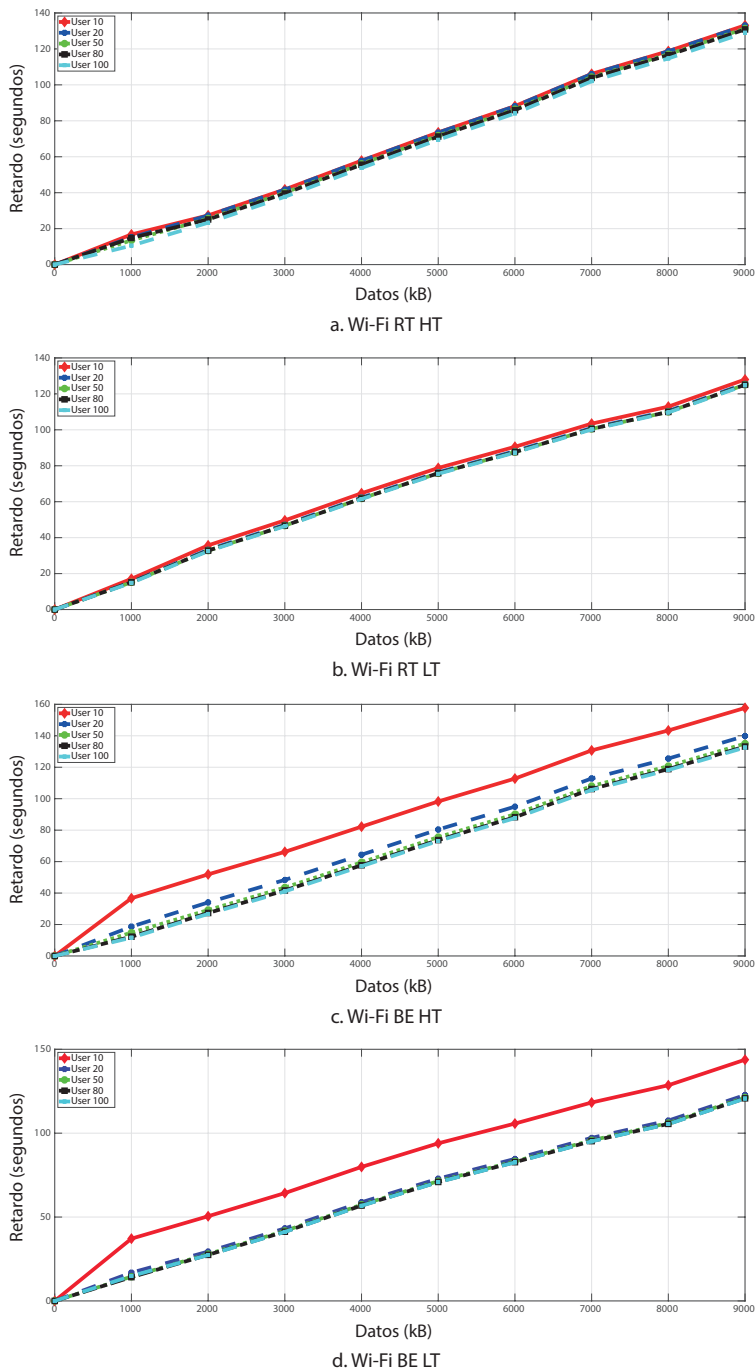
Fuente: elaboraci3n propia.

Figura 90. AAD en GSM para el algoritmo TOPSIS




Fuente: elaboración propia.

Figura 91. AAD en Wi-Fi para el algoritmo TOPSIS




Fuente: elaboraci3n propia.


Figura 92. AAD en GSM para el algoritmo VIKOR




a. GSM-RT-HT



b. GSM-RT-LT



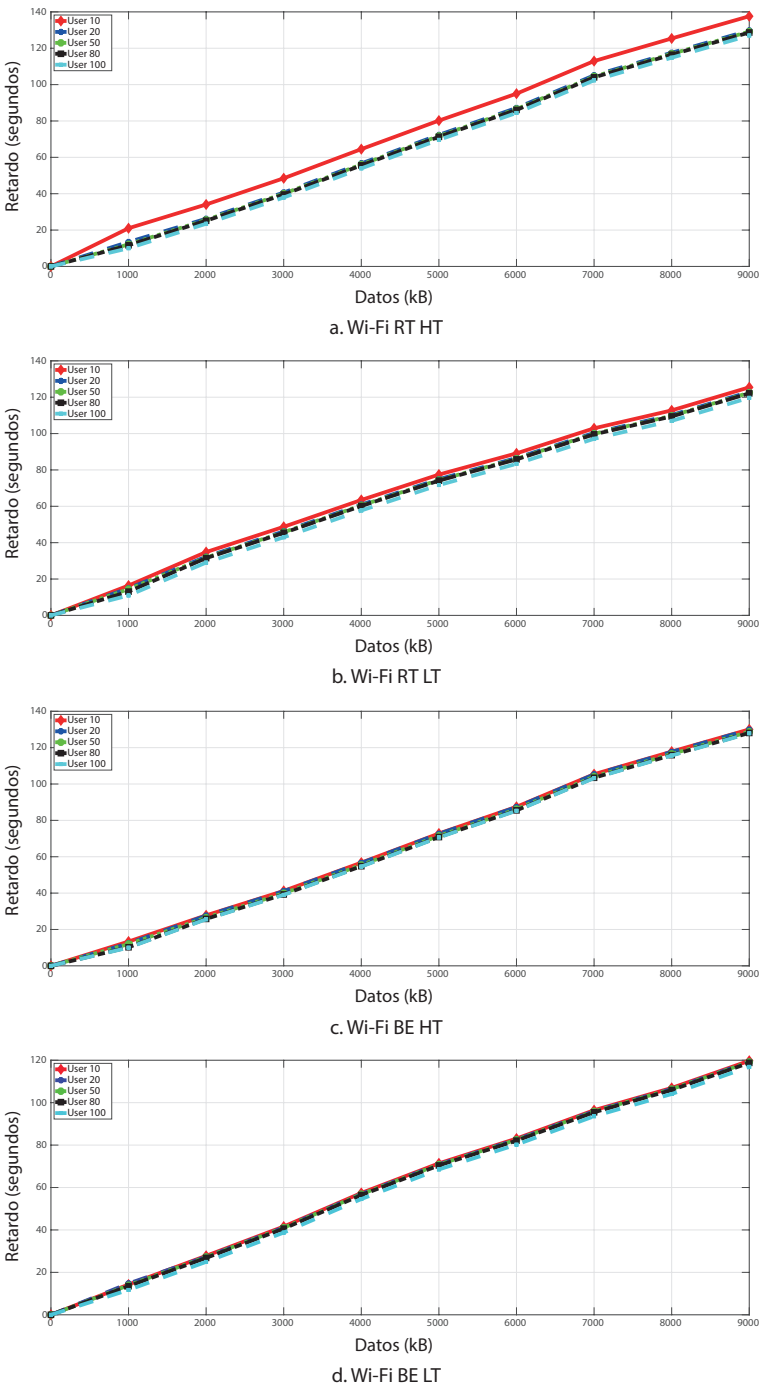
c. GSM-BE-HT



d. GSM-BE-LT

Fuente: elaboración propia.

Figura 93. AAD en Wi-Fi para el algoritmo VIKOR



Fuente: elaboraci3n propia.

Tabla 44. Valores relativos de AAD para FFAHP

FFAHP	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SU10	100	99,33	72,41	73,44	100	97,88	98,44	97,03
SU20	100	99,92	71,55	72,73	98,97	100	98,40	96,30
SU50	99,59	100	71,33	72,43	95,69	100	95,98	93,90
SU80	100	98,02	69,95	71,01	98,95	100	96,77	94,78
SU100	100	99,04	69,88	70,16	97,34	100	95,90	93,66

Fuente: elaboración propia.

Tabla 45. Valores relativos de AAD para SAW

SAW	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SU10	98,02	100	74,23	73,41	100	97,12	86,99	92,80
SU20	98,97	100	72,20	71,41	100	95,32	87,80	91,35
SU50	100	100	71,41	70,53	100	95,97	91,43	91,49
SU80	100	100	71,41	70,60	100	95,87	91,58	92,61
SU100	100	96,54	68,61	69,87	100	96,15	91,07	91,27

Fuente: elaboración propia.

Tabla 46. Valores relativos de AAD para TOPSIS

TOPSIS	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SU10	98,09	100	83,02	82,95	89,01	100	81,16	96,15
SU20	100	98,60	80,10	79,79	100	97,73	87,75	92,27
SU50	100	99,76	80,06	79,75	100	96,94	89,79	92,31
SU80	100	99,85	83,04	79,70	100	96,57	90,70	92,30
SU100	100	98,85	80,39	76,59	100	96,71	91,03	93,51

Fuente: elaboración propia.

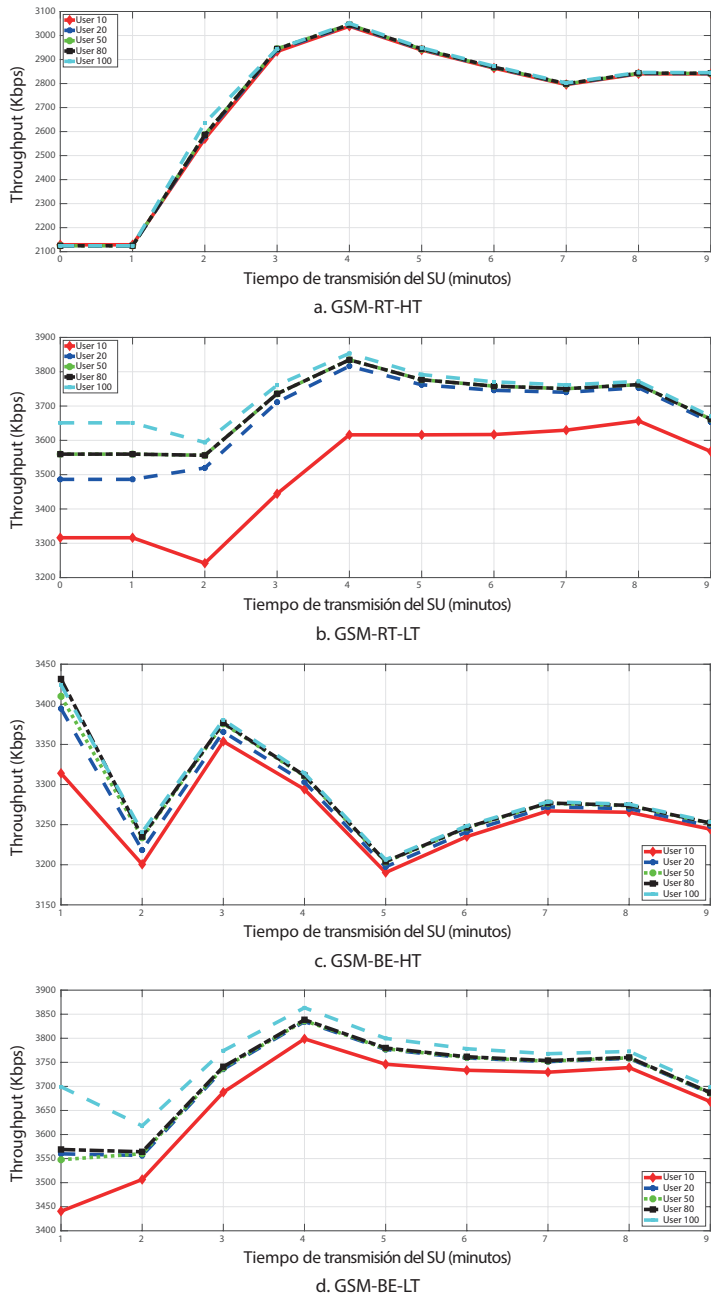
Tabla 47. Valores relativos de AAD para VIKOR

VIKOR	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SU10	95,99	100	77,78	81,19	100	95,45	92,08	87,02
SU20	99,99	100	77,88	81,12	100	97,07	91,86	91,96
SU50	100	99,07	76,88	80,09	100	97,34	92,58	92,30
SU80	100	99,43	77,03	79,99	100	97,25	92,72	92,31
SU100	100	97,50	75,63	78,95	100	97,67	91,41	92,03

Fuente: elaboración propia.


Throughput promedio acumulado

Figura 94. AAT en GSM para el algoritmo FFAHP




Fuente: elaboración propia.


Figura 95. AAT en Wi-Fi para el algoritmo FFAHP




a. Wi-Fi RT HT



b. Wi-Fi RT LT




c. Wi-Fi BE HT




d. Wi-Fi BE LT

Fuente: elaboración propia.


Figura 96. AAT en GSM para el algoritmo SAW




a. GSM-RT-HT



b. GSM-RT-LT




c. GSM-BE-HT




d. GSM-BE-LT

Fuente: elaboración propia.


Figura 97. AAT en Wi-Fi para el algoritmo SAW




a. Wi-Fi RT HT



b. Wi-Fi RT LT







c. Wi-Fi BE HT



d. Wi-Fi BE LT


Fuente: elaboraci3n propia.

Figura 98. AAT en GSM para el algoritmo TOPSIS




Fuente: elaboración propia.


Figura 99. AAT en Wi-Fi para el algoritmo TOPSIS




a. Wi-Fi RT HT



b. Wi-Fi RT LT




c. Wi-Fi BE HT




d. Wi-Fi BE LT

Fuente: elaboraci3n propia.


Figura 100. AAT en GSM para el algoritmo VIKOR




a. GSM-RT-HT



b. GSM-RT-LT



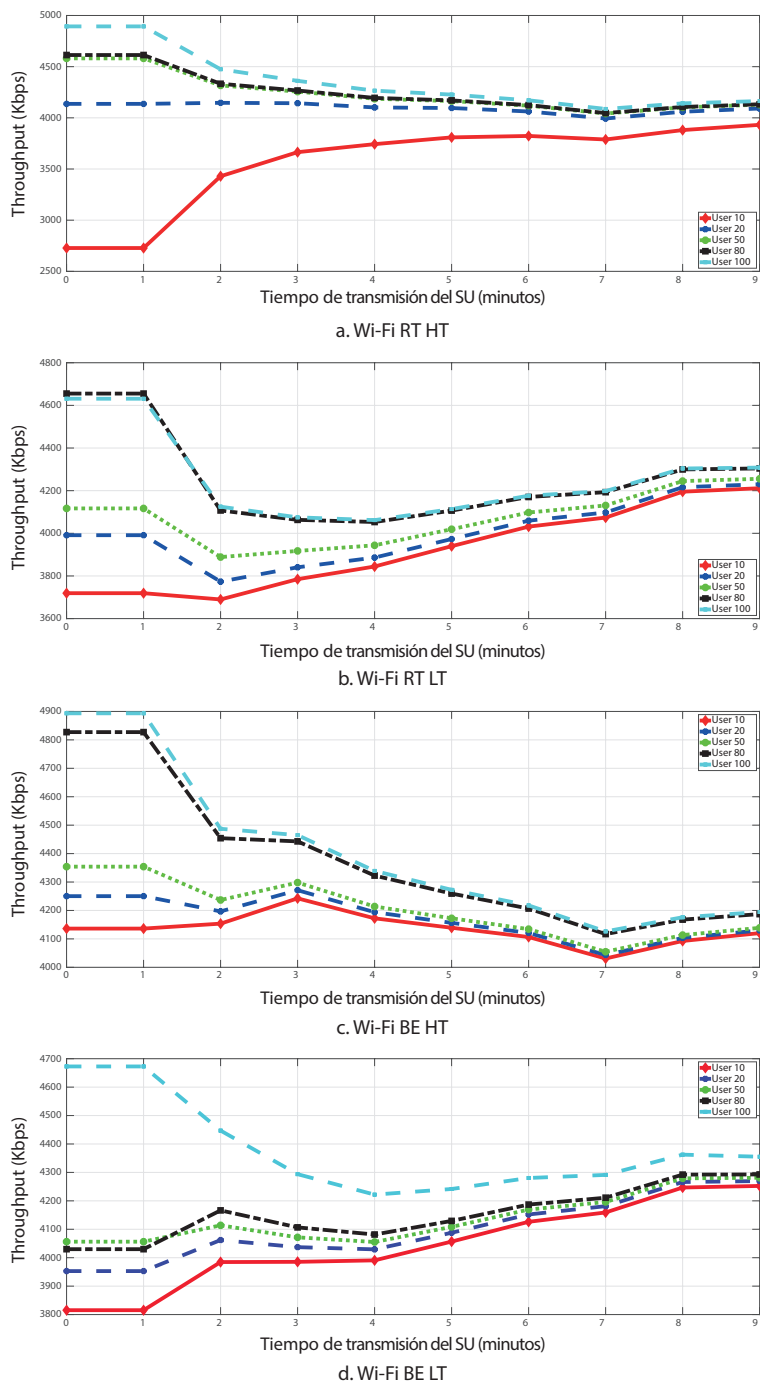
c. GSM-BE-HT



d. GSM-BE-LT

Fuente: elaboración propia.

Figura 101. AAT en Wi-Fi para el algoritmo VIKOR



Fuente: elaboraci3n propia.

Tabla 48. Valores relativos de AAT para FFAHP

FFAHP	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SU10	100	97,25	88,44	77,42	100	99,74	98,53	98,24
SU20	100	99,13	88,14	77,11	100	99,75	98,22	96,81
SU50	100	99,33	88,21	77,10	99,18	100	97,65	96,38
SU80	100	99,31	88,20	77,10	100	99,17	96,61	96,70
SU100	100	99,23	87,97	76,94	99,39	100	96,98	96,23

Fuente: elaboración propia.

Tabla 49. Valores relativos de AAT para SAW

SAW	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SU10	100	97,08	86,58	86,37	100	98,06	91,53	95,33
SU20	99,67	100	85,84	85,62	100	97,55	93,15	94,45
SU50	99,56	100	85,12	84,88	100	97,67	94,82	95,33
SU80	100	100	85,13	84,89	100	98,01	94,42	94,98
SU100	99,73	100	85,27	88,84	100	98,40	95,20	95,02

Fuente: elaboración propia.

Tabla 50. Valores relativos de AAT para TOPSIS

TOPSIS	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SU10	100	97,03	84,04	81,06	95,51	100	90,68	96,65
SU20	100	99,30	83,38	80,22	100	99,15	93,92	96,63
SU50	100	99,84	83,39	80,23	100	99,06	96,02	96,67
SU80	100	99,99	86,70	79,77	100	98,97	97,14	96,98
SU100	100	99,85	86,97	82,41	100	99,08	97,12	97,40

Fuente: elaboración propia.

Tabla 51. Valores relativos de AAT para VIKOR

VIKOR	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SU10	99,69	100	90,67	81,08	100	99,04	96,89	92,46
SU20	100	99,97	90,82	80,55	100	99,07	96,73	95,82
SU50	100	99,81	90,32	80,08	100	99,40	96,68	96,44
SU80	100	99,83	90,61	80,02	99,74	100	97,28	96,01
SU100	100	99,44	90,25	82,52	100	98,92	96,31	95,61

Fuente: elaboración propia.

Evaluación comparativa

En las tablas 52-56 se presentan los porcentajes comparativos del desempeño de cada algoritmo por nivel de colaboración para cada EM, respectivamente. Lo anterior, con el objetivo de analizar el nivel de dependencia y aporte, que representa la colaboración, y, de acuerdo con esto, seleccionar los niveles de colaboración más interesantes. En las tablas 57-61 se presentan los porcentajes comparativos del desempeño de cada algoritmo en cada uno de los ocho escenarios diseñados para dos niveles de colaboración (10% y 100%). Finalmente, en la tabla 62 se presentan los porcentajes comparativos globales del desempeño de cada algoritmo por EM, tanto para la red GSM como para Wi-Fi.

Tabla 52. Evaluación comparativa por nivel de colaboración para AAH

AAH	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
FFAHP-SU10	91,33	92,67	91,14	99,56	89,11	89,17	95,01	95,71
SAW-SU10	74,05	78,09	79,12	81,23	94,90	94,75	85,88	94,81
TOPSIS-SU10	71,35	75,54	92,31	94,14	70,31	90,18	71,34	91,92
VIKOR-SU10	71,35	77,22	84,38	94,94	93,75	93,18	93,35	88,16
FFAHP-SU20	93,84	94,56	91,14	99,56	89,70	93,18	97,04	96,33
SAW-SU20	78,29	80,35	79,12	81,23	97,12	95,24	89,94	95,87
TOPSIS-SU20	77,40	78,09	92,70	94,14	91,37	92,72	84,53	93,34
VIKOR-SU20	75,27	77,65	84,38	95,34	94,57	95,89	93,50	95,11
FFAHP-SU50	93,84	95,86	91,53	99,56	90,30	97,22	98,01	98,69

AAH	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
SAW-SU50	80,59	81,76	79,41	81,23	97,47	96,22	94,25	96,33
TOPSIS-SU50	77,40	78,53	92,70	94,14	92,78	93,02	89,67	94,37
VIKOR-SU50	76,97	78,09	84,38	95,34	94,74	96,39	94,40	95,87
FFAHP-SU80	97,86	95,86	91,53	100	94,08	97,56	98,66	99,83
SAW-SU80	80,59	81,76	79,41	81,52	98,00	96,55	94,70	97,89
TOPSIS-SU80	77,84	78,98	97,30	94,14	92,78	93,02	91,05	94,81
VIKOR-SU80	77,40	78,53	84,71	95,74	94,90	96,55	94,86	96,63
FFAHP-SU100	100	100	93,51	100	94,08	100	100	100
SAW-SU100	88,96	84,76	82,76	86,54	100	98,77	96,09	98,05
TOPSIS-SU100	83,54	84,24	100	94,94	93,43	93,33	91,90	96,48
VIKOR-SU100	80,12	78,98	85,38	96,57	96,77	98,77	95,16	97,89

Nota: la comparación de esta tabla se debe realizar solo verticalmente.

Fuente: elaboración propia.

Tabla 53. Evaluación comparativa por nivel de colaboración para AAFH

AAFH	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
FFAHP-SU10	55,56	25,00	61,11	38,64	68,04	62,61	87,16	75,65
SAW-SU10	83,33	20,00	37,93	58,62	90,41	85,71	68,84	73,11
TOPSIS-SU10	62,50	23,08	45,83	39,53	26,83	72,00	42,22	71,31
VIKOR-SU10	41,67	33,33	57,89	40,48	72,53	86,75	93,14	64,44
FFAHP-SU20	83,33	30,00	61,11	38,64	72,53	69,90	91,35	85,29
SAW-SU20	83,33	42,86	37,93	58,62	90,41	88,89	82,61	78,38
TOPSIS-SU20	83,33	60,00	47,83	39,53	70,97	79,12	68,84	84,47
VIKOR-SU20	50	50,00	64,71	41,46	76,74	94,74	95,00	79,82
FFAHP-SU50	83,33	37,50	64,71	38,64	75,00	75,00	95,00	91,58
SAW-SU50	83,33	50,00	39,29	58,62	91,67	90,00	87,16	79,09
TOPSIS-SU50	83,33	75,00	47,83	39,53	71,74	79,12	91,35	86,14
VIKOR-SU50	55,56	50,00	64,71	41,46	78,57	98,63	95,96	83,65
FFAHP-SU80	83,33	37,50	64,71	39,53	83,54	76,60	95,96	94,57
SAW-SU80	83,33	50,00	39,29	60,71	100	96,00	88,79	79,09

AAFH	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
TOPSIS-SU80	83,33	75,00	78,57	39,53	74,16	80,90	94,06	87,00
VIKOR-SU80	55,56	60,00	64,71	42,50	78,57	98,63	95,96	87,88
FFAHP-SU100	100	42,86	68,75	42,50	83,54	86,75	98,96	100
SAW-SU100	100	60,00	64,71	100	100	96,00	90,48	81,31
TOPSIS-SU100	83,33	100	100	50,00	76,74	80,90	100	89,69
VIKOR-SU100	62,50	75,00	64,71	54,84	81,48	100	97,94	87,88

Nota: la comparación de esta tabla se debe realizar solo verticalmente.

Fuente: elaboración propia.

Tabla 54. Evaluación comparativa por nivel de colaboración para ABW

ABW	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
FFAHP-SU10	99,50	97,12	99,56	84,99	96,43	95,90	96,61	96,69
SAW-SU10	96,09	91,00	92,25	92,48	96,72	96,21	93,15	97,22
TOPSIS-SU10	95,00	90,11	87,42	84,93	89,29	95,75	89,94	94,99
VIKOR-SU10	95,10	95,76	97,41	85,03	96,52	96,30	97,78	93,61
FFAHP-SU20	99,57	99,61	99,85	85,00	97,36	96,29	96,96	97,05
SAW-SU20	96,32	97,73	92,30	92,49	97,91	96,66	95,43	97,34
TOPSIS-SU20	95,21	95,83	87,81	84,93	95,54	95,89	94,55	97,74
VIKOR-SU20	96,07	97,01	98,87	85,09	97,04	98,06	97,85	98,02
FFAHP-SU50	99,86	99,95	99,97	85,03	97,43	96,61	97,48	97,37
SAW-SU50	96,39	99,14	92,34	92,53	98,78	97,03	96,74	98,80
TOPSIS-SU50	95,96	96,11	87,84	84,96	95,66	95,94	96,81	98,09
VIKOR-SU50	97,05	97,83	98,96	85,20	97,37	98,25	98,52	99,26
FFAHP-SU80	99,89	99,95	99,98	85,05	98,63	97,29	97,48	99,08
SAW-SU80	98,19	99,14	92,36	92,56	99,09	98,93	97,94	98,98
TOPSIS-SU80	97,03	97,95	94,76	84,98	96,21	96,89	99,07	98,61
VIKOR-SU80	97,18	97,89	99,81	85,23	97,92	99,05	99,79	99,63
FFAHP-SU100	100	100	100	85,18	98,74	98,70	98,01	99,60
SAW-SU100	98,19	99,22	92,83	100	100	99,35	98,83	99,55

ABW	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
TOPSIS-SU100	97,32	98,03	95,20	90,52	96,38	97,16	99,11	99,38
VIKOR-SU100	97,50	97,96	99,82	90,89	99,60	100	100	100

Nota: la comparación de esta tabla se debe realizar solo verticalmente.

Fuente: elaboración propia.

Tabla 55. Evaluación comparativa por nivel de colaboración para AAD

AAD	GSM BE-LT	GSM RT-LT	GSM BE-HT	GSM RT-HT	Wi-Fi BE-LT	Wi-Fi RT-LT	Wi-Fi BE-HT	Wi-Fi RT-HT
FFAHP-SU10	95,16	95,44	96,97	99,61	91,74	91,64	96,10	96,98
SAW-SU10	81,72	84,18	87,08	87,24	95,72	94,86	88,60	96,78
TOPSIS-SU10	79,45	81,79	94,63	95,76	79,85	91,54	77,47	93,98
VIKOR-SU10	79,82	83,96	91,02	96,22	95,88	93,39	93,95	90,91
FFAHP-SU20	96,31	97,16	96,97	99,84	91,90	94,75	97,22	97,42
SAW-SU20	84,84	86,56	87,10	87,25	97,79	95,12	91,36	97,33
TOPSIS-SU20	84,20	83,83	94,91	95,76	93,55	93,30	87,35	94,04
VIKOR-SU20	83,38	84,21	91,40	96,43	96,23	95,32	94,06	96,41
FFAHP-SU50	96,32	97,65	97,08	99,85	92,14	98,26	98,34	98,52
SAW-SU50	86,80	87,65	87,23	87,26	97,95	95,92	95,29	97,64
TOPSIS-SU50	84,25	84,87	94,92	95,77	94,69	93,68	90,48	95,24
VIKOR-SU50	84,48	84,51	91,41	96,44	96,32	95,67	94,89	96,87
FFAHP-SU80	98,66	97,65	97,12	99,87	95,38	98,36	99,24	99,53
SAW-SU80	86,80	87,65	87,23	87,36	98,17	96,03	95,65	99,05
TOPSIS-SU80	84,32	85,01	98,53	95,78	95,06	93,68	91,75	95,60
VIKOR-SU80	84,66	85,00	91,78	96,53	96,67	95,94	95,37	97,23
FFAHP-SU100	100	100	98,34	100	95,39	100	100	100
SAW-SU100	91,87	89,55	88,70	91,48	100	98,12	96,91	99,44
TOPSIS-SU100	88,39	88,22	100	96,50	95,16	93,91	92,17	96,95
VIKOR-SU100	86,49	85,15	92,05	97,33	98,22	97,90	95,53	98,49

Nota: la comparación de esta tabla se debe realizar solo verticalmente.

Fuente: elaboración propia.

Tabla 56. Evaluación comparativa por nivel de colaboración para AAT

AAT	GSM-BE-LT	GSM-RT-LT	GSM-BE-HT	GSM-RT-HT	Wi-Fi-BE-LT	Wi-Fi-RT-LT	Wi-Fi-BE-HT	Wi-Fi-RT-HT
FFAHP-SU10	99,19	97,21	99,73	88,76	95,35	95,99	97,79	98,25
SAW-SU10	95,43	93,36	93,93	95,26	98,18	97,17	93,52	98,17
TOPSIS-SU10	94,17	92,08	89,96	88,22	90,51	95,65	89,44	96,07
VIKOR-SU10	94,13	95,15	97,32	88,49	97,28	97,24	98,10	94,33
FFAHP-SU20	99,65	99,55	99,85	88,81	96,15	96,80	98,29	97,62
SAW-SU20	95,97	97,03	93,96	95,28	98,61	97,10	95,60	97,68
TOPSIS-SU20	95,15	95,21	90,18	88,22	96,27	96,34	94,10	97,57
VIKOR-SU20	95,11	95,82	98,19	88,55	97,67	97,67	98,33	98,16
FFAHP-SU50	99,68	99,77	99,95	88,82	96,27	97,96	98,64	98,11
SAW-SU50	96,71	97,88	93,99	95,29	98,77	97,37	97,47	98,76
TOPSIS-SU50	95,15	95,73	90,19	88,23	96,39	96,37	96,33	97,73
VIKOR-SU50	95,73	96,28	98,28	88,59	97,94	98,26	98,54	99,06
FFAHP-SU80	99,70	99,77	99,96	88,85	98,38	98,47	98,92	99,78
SAW-SU80	97,13	97,88	94,00	95,30	99,95	98,88	98,22	99,57
TOPSIS-SU80	95,72	96,44	94,33	88,25	96,89	96,79	97,96	98,55
VIKOR-SU80	95,82	96,39	98,69	88,61	98,20	99,38	99,69	99,15
FFAHP-SU100	100	100	100	88,92	98,47	100	100	100
SAW-SU100	97,13	98,15	94,41	100	100	99,32	99,08	99,66
TOPSIS-SU100	95,87	96,46	94,78	91,31	97,07	97,08	98,12	99,17
VIKOR-SU100	96,21	96,41	98,70	91,76	99,63	99,47	99,87	99,91

Nota: la comparación de esta tabla se debe realizar solo verticalmente.

Fuente: elaboración propia.

Tabla 57. Evaluación comparativa por escenario con colaboración de 10 % y 100 % para AAH

AAH	FFAHP-SU10	SAW-SU10	TOPSIS-SU10	VIKOR-SU10	FFAHP-SU100	SAW-SU100	TOPSIS-SU100	VIKOR-SU100
GSM-BE-LT	91,33	74,05	71,35	71,35	100	88,96	83,54	80,12
GSM-RT-LT	92,67	78,09	75,54	77,22	100	84,76	84,24	78,98
GSM-BE-HT	91,14	79,12	92,31	84,38	93,51	82,76	100	85,38
GSM-RT-HT	99,56	81,23	94,14	94,94	100	86,54	94,94	96,57

AAH	FFAHP-SU10	SAW-SU10	TOPSIS-SU10	VIKOR-SU10	FFAHP-SU100	SAW-SU100	TOPSIS-SU100	VIKOR-SU100
Wi-Fi-BE-LT	89,11	94,90	70,31	93,75	94,08	100	93,43	96,77
Wi-Fi-RT-LT	89,17	94,75	90,18	93,18	100	98,77	93,33	98,77
Wi-Fi-BE-HT	95,01	85,88	71,34	93,35	100	96,09	91,90	95,16
Wi-Fi-RT-HT	95,71	94,81	91,92	88,16	100	98,05	96,48	97,89
GSM-LT	92,00	76,07	73,445	74,285	100	86,86	83,89	79,55
GSM-HT	95,35	80,175	93,225	89,66	96,755	84,65	97,47	90,975
GSM-BE	91,235	76,585	81,83	77,865	96,755	85,86	91,77	82,75
GSM-RT	96,115	79,66	84,84	86,08	100	85,65	89,59	87,775
Wi-Fi-LT	89,14	94,825	80,245	93,465	97,04	99,385	93,38	97,77
Wi-Fi-HT	95,36	90,345	81,63	90,755	100	97,07	94,19	96,525
Wi-Fi-BE	92,06	90,39	70,825	93,55	97,04	98,045	92,665	95,965
Wi-Fi-RT	92,44	94,78	91,05	90,67	100	98,41	94,905	98,33
Score GSM	93,675	78,122	83,335	81,972	98,377	85,755	90,68	85,262
Score Wi-Fi	92,25	92,585	80,937	92,11	98,52	98,227	93,785	97,147

Nota: la comparación de esta tabla se debe realizar solo horizontalmente.

Fuente: elaboración propia.

Tabla 58. Evaluación comparativa por escenario con colaboración de 10 % y 100 % para AAFH

AAFH	FFAHP-SU10	SAW-SU10	TOPSIS-SU10	VIKOR-SU10	FFAHP-SU100	SAW-SU100	TOPSIS-SU100	VIKOR-SU100
GSM-BE-LT	55,56	83,33	62,50	41,67	100	100	83,33	62,50
GSM-RT-LT	25,00	20,00	23,08	33,33	42,86	60,00	100	75,00
GSM-BE-HT	61,11	37,93	45,83	57,89	68,75	64,71	100	64,71
GSM-RT-HT	38,64	58,62	39,53	40,48	42,50	100	50,00	54,84
Wi-Fi-BE-LT	68,04	90,41	26,83	72,53	83,54	100	76,74	81,48
Wi-Fi-RT-LT	62,61	85,71	72,00	86,75	86,75	96,00	80,90	100
Wi-Fi-BE-HT	87,16	68,84	42,22	93,14	98,96	90,48	100	97,94
Wi-Fi-RT-HT	75,65	73,11	71,31	64,44	100	81,31	89,69	87,88
GSM-LT	40,28	51,665	42,79	37,50	71,43	80,00	91,665	68,75
GSM-HT	49,875	48,275	42,68	49,185	55,625	82,355	75,00	59,775

AAFH	FFAHP-SU10	SAW-SU10	TOPSIS-SU10	VIKOR-SU10	FFAHP-SU100	SAW-SU100	TOPSIS-SU100	VIKOR-SU100
GSM-BE	58,335	60,63	54,165	49,78	84,375	82,355	91,665	63,605
GSM-RT	31,82	39,31	31,305	36,905	42,68	80,00	75,00	64,92
Wi-Fi-LT	65,325	88,06	49,415	79,64	85,145	98,00	78,82	90,74
Wi-Fi-HT	81,405	70,975	56,765	78,79	99,48	85,895	94,845	92,91
Wi-Fi-BE	77,60	79,625	34,525	82,835	91,25	95,24	88,37	89,71
Wi-Fi-RT	69,13	79,41	71,655	75,595	93,375	88,655	85,295	93,94
Score GSM	45,077	49,97	42,735	43,342	63,527	81,177	83,332	64,262
Score Wi-Fi	73,365	79,517	53,09	79,215	92,312	91,947	86,832	91,825

Nota: la comparación de esta tabla se debe realizar solo horizontalmente.

Fuente: elaboración propia.

Tabla 59. Evaluación comparativa por escenario con colaboración de 10% y 100% para ABW

ABW	FFAHP-SU10	SAW-SU10	TOPSIS-SU10	VIKOR-SU10	FFAHP-SU100	SAW-SU100	TOPSIS-SU100	VIKOR-SU100
GSM-BE-LT	99,50	96,09	95,00	95,10	100	98,19	97,32	97,50
GSM-RT-LT	97,12	91,00	90,11	95,76	100	99,22	98,03	97,96
GSM-BE-HT	99,56	92,25	87,42	97,41	100	92,83	95,20	99,82
GSM-RT-HT	84,99	92,48	84,93	85,03	85,18	100	90,52	90,89
Wi-Fi-BE-LT	96,43	96,72	89,29	96,52	98,74	100	96,38	99,60
Wi-Fi-RT-LT	95,90	96,21	95,75	96,30	98,70	99,35	97,16	100
Wi-Fi-BE-HT	96,61	93,15	89,94	97,78	98,01	98,83	99,11	100
Wi-Fi-RT-HT	96,69	97,22	94,99	93,61	99,60	99,55	99,38	100
GSM-LT	98,31	93,545	92,555	95,43	100	98,705	97,675	97,73
GSM-HT	92,275	92,365	86,175	91,22	92,59	96,415	92,86	95,355
GSM-BE	99,53	94,17	91,21	96,255	100	95,51	96,26	98,66
GSM-RT	91,055	91,74	87,52	90,395	92,59	99,61	94,275	94,425
Wi-Fi-LT	96,165	96,465	92,52	96,41	98,72	99,675	96,77	99,80
Wi-Fi-HT	96,65	95,185	92,465	95,695	98,805	99,19	99,245	100
Wi-Fi-BE	96,52	94,935	89,615	97,15	98,375	99,415	97,745	99,80

ABW	FFAHP-SU10	SAW-SU10	TOPSIS-SU10	VIKOR-SU10	FFAHP-SU100	SAW-SU100	TOPSIS-SU100	VIKOR-SU100
Wi-Fi-RT	96,295	96,715	95,37	94,955	99,15	99,45	98,27	100
Score GSM	95,292	92,955	89,365	93,325	96,295	97,56	95,267	96,542
Score Wi-Fi	96,407	95,825	92,492	96,052	98,762	99,432	98,007	99,90

Nota: la comparación de esta tabla se debe realizar solo horizontalmente.

Fuente: elaboración propia.

Tabla 60. Evaluación comparativa por escenario con colaboración de 10% y 100% para AAD

AAD	FFAHP-SU10	SAW-SU10	TOPSIS-SU10	VIKOR-SU10	FFAHP-SU100	SAW-SU100	TOPSIS-SU100	VIKOR-SU100
GSM-BE-LT	95,16	81,72	79,45	79,82	100	91,87	88,39	86,49
GSM-RT-LT	95,44	84,18	81,79	83,96	100	89,55	88,22	85,15
GSM-BE-HT	96,97	87,08	94,63	91,02	98,34	88,70	100	92,05
GSM-RT-HT	99,61	87,24	95,76	96,22	100	91,48	96,50	97,33
Wi-Fi-BE-LT	91,74	95,72	79,85	95,88	95,39	100	95,16	98,22
Wi-Fi-RT-LT	91,64	94,86	91,54	93,39	100	98,12	93,91	97,90
Wi-Fi-BE-HT	96,10	88,60	77,47	93,95	100	96,91	92,17	95,53
Wi-Fi-RT-HT	96,98	96,78	93,98	90,91	100	99,44	96,95	98,49
GSM-LT	95,30	82,95	80,62	81,89	100	90,71	88,305	85,82
GSM-HT	98,29	87,16	95,195	93,62	99,17	90,09	98,25	94,69
GSM-BE	96,065	84,40	87,04	85,42	99,17	90,285	94,195	89,27
GSM-RT	97,525	85,71	88,775	90,09	100	90,515	92,36	91,24
Wi-Fi-LT	91,69	95,29	85,695	94,635	97,695	99,06	94,535	98,06
Wi-Fi-HT	96,54	92,69	85,725	92,43	100	98,175	94,56	97,01
Wi-Fi-BE	93,92	92,16	78,66	94,915	97,695	98,455	93,665	96,875
Wi-Fi-RT	94,31	95,82	92,76	92,15	100	98,78	95,43	98,195
Score GSM	96,795	85,055	87,907	87,755	99,585	90,40	93,277	90,255
Score Wi-Fi	94,115	93,99	85,71	93,532	98,847	98,617	94,547	97,535

Nota: la comparación de esta tabla se debe realizar solo horizontalmente.

Fuente: elaboración propia.

Tabla 61. Evaluación comparativa por escenario con colaboración de 10% y 100% para AAT

AAT	FFAHP-SU10	SAW-SU10	TOPSIS-SU10	VIKOR-SU10	FFAHP-SU100	SAW-SU100	TOPSIS-SU100	VIKOR-SU100
GSM-BE-LT	99,19	95,43	94,17	94,13	100	97,13	95,87	96,21
GSM-RT-LT	97,21	93,36	92,08	95,15	100	98,15	96,46	96,41
GSM-BE-HT	99,73	93,93	89,96	97,32	100	94,41	94,78	98,70
GSM-RT-HT	88,76	95,26	88,22	88,49	88,92	100	91,31	91,76
Wi-Fi-BE-LT	95,35	98,18	90,51	97,28	98,47	100	97,07	99,63
Wi-Fi-RT-LT	95,99	97,17	95,65	97,24	100	99,32	97,08	99,47
Wi-Fi-BE-HT	97,79	93,52	89,44	98,10	100	99,08	98,12	99,87
Wi-Fi-RT-HT	98,25	98,17	96,07	94,33	100	99,66	99,17	99,91
GSM-LT	98,20	94,395	93,125	94,64	100	97,64	96,165	96,31
GSM-HT	94,245	94,595	89,09	92,905	94,46	97,205	93,045	95,23
GSM-BE	99,46	94,68	92,065	95,725	100	95,77	95,325	97,455
GSM-RT	92,985	94,31	90,15	91,82	94,46	99,075	93,885	94,085
Wi-Fi-LT	95,67	97,675	93,08	97,26	99,235	99,66	97,075	99,55
Wi-Fi-HT	98,02	95,845	92,755	96,215	100	99,37	98,645	99,89
Wi-Fi-BE	96,57	95,85	89,975	97,69	99,235	99,54	97,595	99,75
Wi-Fi-RT	97,12	97,67	95,86	95,785	100	99,49	98,125	99,69
Score GSM	96,222	94,495	91,107	93,772	97,23	97,422	94,605	95,77
Score Wi-Fi	96,845	96,76	92,917	96,737	99,617	99,515	97,86	99,72

Nota: la comparación de esta tabla se debe realizar solo horizontalmente.

Fuente: elaboración propia.

Tabla 62. Evaluación comparativa global por EM

EM	FFAHP-SU10	SAW-SU10	TOPSIS-SU10	VIKOR-SU10	FFAHP-SU100	SAW-SU100	TOPSIS-SU100	VIKOR-SU100
AAH-GSM	93,675	78,122	83,335	81,972	98,377	85,755	90,68	85,262
AAFH-GSM	45,077	49,97	42,735	43,342	63,527	81,177	83,332	64,262
ABW-GSM	95,292	92,955	89,365	93,325	96,295	97,56	95,267	96,542

EM	FFAHP-SU10	SAW-SU10	TOPSIS-SU10	VIKOR-SU10	FFAHP-SU100	SAW-SU100	TOPSIS-SU100	VIKOR-SU100
AAD-GSM	96,795	85,055	87,907	87,755	99,585	90,40	93,277	90,255
AAT-GSM	96,222	94,495	91,107	93,772	97,23	97,422	94,605	95,77
AAH-Wi-Fi	92,25	92,585	80,937	92,11	98,52	98,227	93,785	97,147
AAFH-Wi-Fi	73,365	79,517	53,09	79,215	92,312	91,947	86,832	91,825
ABW-Wi-Fi	96,407	95,825	92,492	96,052	98,762	99,432	98,007	99,90
AAD-Wi-Fi	94,115	93,99	85,71	93,532	98,847	98,617	94,547	97,535
AAT-Wi-Fi	96,845	96,76	92,917	96,737	99,617	99,515	97,86	99,72
Score GSM global	85,412	80,119	78,89	80,033	91,003	90,463	91,432	86,418
Score Wi-Fi global	90,596	91,735	81,029	91,529	97,612	97,548	94,206	97,225

Fuente: elaboración propia.

Discusión

Durante el desarrollo de la fase de evaluación y validación de los algoritmos seleccionados, se incluyeron varios parámetros de evaluación (o EM) que, aunque permiten realizar una evaluación comparativa más robusta e interesante, también hacen más difícil la tarea de presentar dicha información. Debido a lo anterior, la primera parte de la evaluación comparativa (tablas 52-56) se enfocó en contrastar el desempeño de la colaboración entre SU, para seleccionar los dos niveles más interesantes y descartar los otros tres, lo que redujo el número de combinaciones que se presentarían en las tablas de comparación. Es importante tener en cuenta que, para las tablas 52-56, la comparación solo se debe realizar verticalmente, ya que no aporta mucho el análisis de un mismo algoritmo en diferentes escenarios, pues resulta lógico suponer que el desempeño de cada métrica será mejor en una traza LT que en una HT, dado que la primera presenta un mayor número de SO; siguiendo la misma lógica, el desempeño también será mejor en una red GSM que en una Wi-Fi, ya que la segunda resulta ser mucho más caótica que la primera.

De los resultados obtenidos en las tablas 52-56, se puede observar que, si bien se evidencia una mejoría en el desempeño de cada algoritmo al aumentar el nivel de colaboración, esta mejoría no resulta ser mayor al 10% en la mayoría de los casos. Por tanto, un análisis interesante sería evaluar comparativamente cada algoritmo en todos los escenarios, teniendo en cuenta los niveles de mayor y menor colaboración, es decir, el 10% y el 100%.

De los resultados obtenidos en las tablas 57-61 se puede realizar un análisis del desempeño de cada algoritmo (incluyendo sus dos niveles de colaboración, 10% y 100%), en cada uno de los ocho escenarios diseñados, para cada EM. En este caso, la evaluación comparativa sí se realiza horizontalmente para poder comparar los algoritmos en los diferentes escenarios.

Con respecto a AAH, se observa que FFAHP-SU100 tiene el mejor desempeño en GSM, en el cual domina en tres de los cuatro escenarios, pues solo TOPSIS-SU100, en BE-HT, logra relegarlo al segundo lugar, por una diferencia del 6,5%; en Wi-Fi sucede algo similar: el mejor desempeño lo tiene FFAHP-SU100, y solo SAW, en BE-LT, logra relegarlo al cuarto lugar, con una diferencia del 6%.

Con respecto a AAFH, se observa que SAW (en BE-LT y RT-HT) y TOPSIS (en BE-HT y RT-LT) comparten el mejor desempeño en la red GSM, mientras que en la red Wi-Fi no hay un algoritmo que domine en más de un escenario. Analizando los valores promedio, el mejor desempeño lo alcanza el algoritmo FFAHP-SU100, seguido muy de cerca por SAW y VIKOR, respectivamente.

Con respecto a ABW, se observa que nuevamente FFAHP-SU100 domina en tres de los cuatro escenarios de GSM, y solo SAW, en RT-HT, logra relegarlo al quinto lugar, con una diferencia del 15%, lo que hace que, en promedio, los dos algoritmos tengan el mismo desempeño; en el caso de la red Wi-Fi, VIKOR lidera el desempeño en tres escenarios, seguido muy de cerca por SAW, que en promedio tiene el mismo desempeño que VIKOR.

Con respecto a AAD, se observa que nuevamente FFAHP-SU100 domina en tres de los cuatro escenarios de GSM, y solo VIKOR, en BE-HT, logra relegarlo al segundo lugar, con una diferencia del 1,7%; sin embargo, en promedio, FFAHP supera ampliamente a VIKOR. En el caso de Wi-Fi, FFAHP-SU100 repite el liderato en el desempeño de tres escenarios, y solo SAW, en BE-LT, logra relegarlo al quinto lugar, con una diferencia del 1,6%; sin embargo, en promedio, los dos comparten el primer lugar.

Con respecto a AAT, se repite la historia: FFAHP-SU100 domina en tres de los cuatro escenarios de GSM, y solo SAW, en RT-HT, logra relegarlo al tercer lugar, con una diferencia de tan solo 1,5%; sin embargo, en promedio, ambos ocupan el primer lugar. Para el caso de Wi-Fi, FFAHP-SU100 repite el liderato en el desempeño de tres escenarios, y solo SAW, en BE-LT, logra relegarlo al tercer lugar, con una diferencia del 1,5%; sin embargo, en promedio, los dos comparten el primer lugar junto con VIKOR.

Finalmente, los resultados obtenidos en la tabla 62 resumen el desempeño global de cada algoritmo (incluyendo sus dos niveles de colaboración, 10% y 100%), en el

nivel de EM, tanto para la red GSM como para la red Wi-Fi; se observa que el mejor desempeño de la mayor parte de las EM tanto en GSM como en Wi-Fi se lo reparten los algoritmos FFAHP y SAW; solo en el caso de AAFH-GSM, el mejor desempeño lo tiene TOPSIS, seguido de cerca por SAW, y en ABW-Wi-Fi y AAT-Wi-Fi, VIKOR comparte el primer lugar con SAW y FFAHP.

Cuando se realiza un análisis por tipo de escenario, no se evidencia un algoritmo que domine ampliamente, ya sea en todos los escenarios de tráfico alto, en todos los escenarios de tráfico bajo o en todos los escenarios con enfoque de RT o BE, por lo que es necesario realizar una ponderación para encontrar los algoritmos que mejor se desempeñan en cada red. De acuerdo con la tabla 62, en la red GSM, si sacamos de la ecuación a AAFH (lo cual no afecta significativamente, ya que el número de *handoffs* fallidos es significativamente menor al número de *handoffs* totales), el algoritmo que domina ampliamente y en solitario es FFAHP. Para el caso de la red Wi-Fi, tanto FFAHP como SAW presentan un desempeño similar. Sin embargo, con el objetivo de minimizar la complejidad del modelo, para el caso de Wi-Fi se selecciona únicamente a FFAHP.

Ahora, la pregunta es si se selecciona FFAHP-SU100 (FFAHP con un porcentaje de colaboración del 100%) o FFAHP-SU10 (FFAHP con un porcentaje de colaboración del 10%). Analizando nuevamente la tabla 62, se observa que, si dejamos por fuera la EM AAFH, en el caso de GSM, FFAHP-SU100 tiene un desempeño del 97,87%, y FFAHP-SU10, del 95,50%, una diferencia de apenas el 2% en el desempeño, pero del 90% en colaboración, lo que hace que FFAHP-SU10 sea una mejor alternativa. Haciendo un análisis similar en Wi-Fi, FFAHP-SU100 tiene un desempeño del 98,94%, mientras que FFAHP-SU10, del 94,90%, una diferencia de apenas el 4% en el desempeño, pero del 90% en colaboración, lo que hace, nuevamente, que FFAHP-10 sea una mejor alternativa.

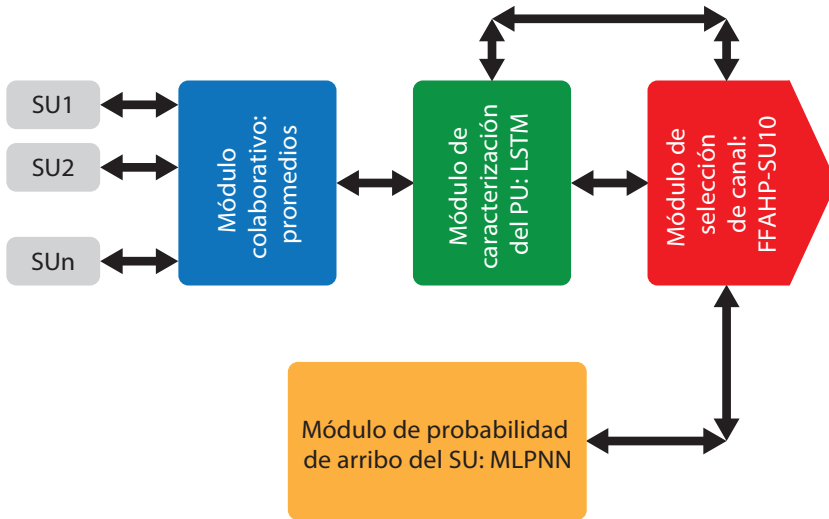
Modelo de decisión espectral colaborativo definitivo

La figura 102 describe el modelo de decisión espectral colaborativo, de acuerdo con los resultados alcanzados en cada módulo evaluado. El modelo está conformado por cuatro módulos fundamentales: 1) módulo colaborativo (intercambio de información entre SU); 2) módulo de caracterización del PU; 3) módulo de probabilidad de arribo del SU, y 4) módulo de selección de la SO.

La función de cada módulo es realizada por el algoritmo que mejor desempeño evidenció en la correspondiente evaluación de cada módulo. Los algoritmos seleccionados fueron: para el módulo colaborativo, el intercambio de información se dio a través del algoritmo de promedios; para el módulo de caracterización del PU, el

algoritmo LSTM; para el módulo de probabilidad de arribo del SU, el algoritmo MLPNN, y para el módulo de selección de canal, el algoritmo FFAHP-SU10.

Figura 102. Modelo de decisión espectral colaborativo definitivo



Fuente: elaboración propia.

Herramienta de simulación

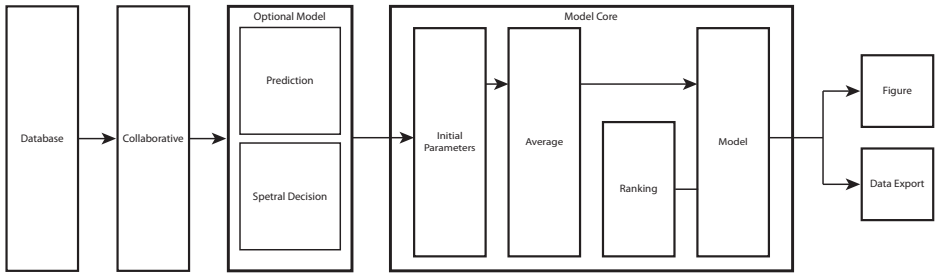
La herramienta de simulación propuesta fue desarrollada en Matlab y está diseñada para permitirle al usuario trabajar en un ambiente amigable y parametrizable según las pruebas que se requiera realizar. Esta herramienta está basada en datos de ocupación espectral reales capturados en las bandas de frecuencia GSM y Wi-Fi, a fin de incorporar el comportamiento real del usuario primario (PU) en la evaluación del desempeño del algoritmo de *handoff* espectral (SH) seleccionado. La herramienta propuesta permite seleccionar entre 16 posibles algoritmos de SH, enfocados a aplicaciones de tiempo real (RT) o mejor esfuerzo (BE), y también es posible modificarlos o incluso proponer uno propio. Además, permite configurar parámetros de interés como el porcentaje de cooperación entre usuarios secundarios (SU), el tiempo de transmisión del SU y el tipo de modulación, entre otros. La selección de frecuencia se toma a partir de los cuatro criterios de decisión (DC): probabilidad de disponibilidad (AP) del canal, tiempo estimado de disponibilidad (ETA) del canal, relación de señal a interferencia más ruido (SINR) y ancho de banda (BW). La evaluación del desempeño de los algoritmos de SH se realiza a partir de las cinco métricas de evaluación (EM): AAH, AAFH, ABW, AAD y AAT.

Descripción general

Detrás del entorno gráfico, el programa está conformado por 69 funciones, cada una de las cuales es parametrizada con diferentes valores de entrada y depende de la técnica o modelo seleccionado; un diagrama de bloques general se presenta en la figura 103.

La descripción de cada una de las variables de entrada y salida se realiza en la figura 104; este esquema permite identificar el flujo de datos entre cada uno de los bloques, desde la base de datos hasta los elementos de salida: figuras y matrices. Los bloques de color azul hacen referencia a los módulos que requieren de la parametrización del usuario en la ventana gráfica del *software*; los de color rojo, a procesos intermedios, y los de color negro, a entradas y salidas.

Figura 103. Diagrama de bloques: descripción general



Fuente: elaboración propia.

Base de datos

El programa funciona a partir de tres matrices de datos de potencia: *high*, *medium* y *low* (*traffic level*), y para dos tipos de tecnología: GSM y Wi-Fi (*load database*), cada una con seis bases de datos. Los datos son valores reales tomados en Bogotá, Colombia, en un periodo de una semana, incluyendo sábado y domingo. La cantidad de datos capturados para cada una de las tecnologías se muestra en la tabla 63.

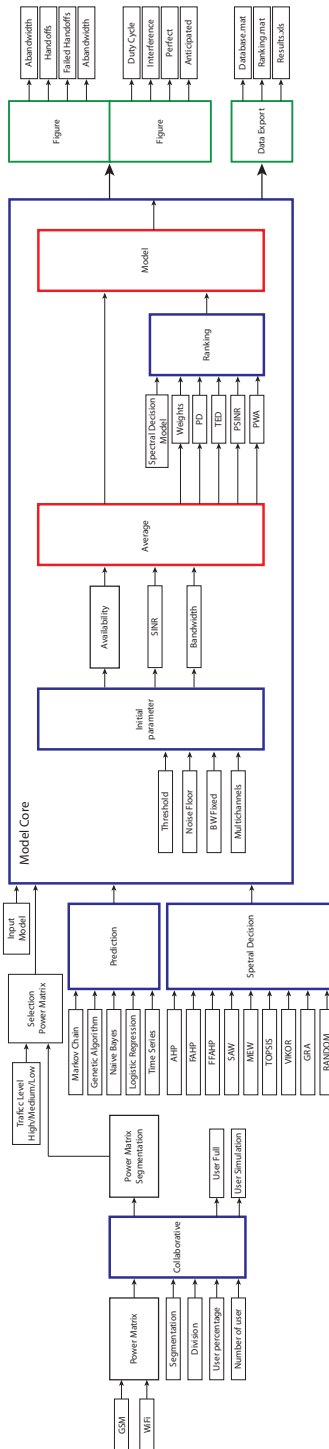
Tabla 63. Datos capturados

Tecnología	Datos capturados		
	Filas	Columnas	Datos totales
GSM	1.145.700	551	631.280.700
Wi-Fi	2.490.000	461	1.147.890.000

Fuente: elaboración propia.


La figura 105 presenta las variables de entrada para la base datos; el usuario debe seleccionar entre dos posibles tecnologías, GSM o Wi-Fi, y puede especificar el tipo de tráfico, aunque este ajuste no se requiere como criterio inicial.

Figura 104. Flujo de datos



Fuente: elaboración propia.

Figura 105. Entrada de la base de datos

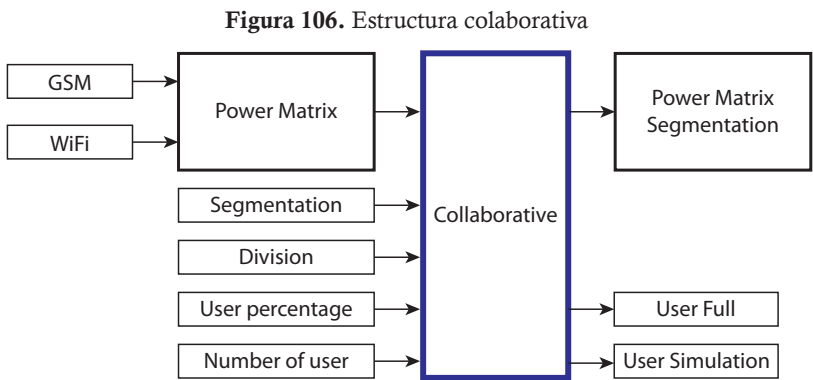


Fuente: elaboración propia.

Módulo colaborativo

Este módulo permite segmentar la matriz de potencia según el número de usuarios (figura 106), y a partir de este número se puede analizar el efecto de reducir los usuarios, ya que, además de la división, el módulo cuenta con la posibilidad de seleccionar qué porcentaje del total de usuarios estará involucrado en las respectivas simulaciones. Para caracterizar este módulo, se requieren seis variables de ajuste: el tipo de tecnología, el tipo de tráfico, el número de usuarios en los cuales se va a dividir la matriz de potencia, el porcentaje de usuarios involucrado en la simulación, el tipo de segmentación (aleatoria o continua, según el porcentaje de usuarios) y, finalmente, si la división se realiza por filas o por columnas.

Como elementos de salida, se obtienen la matriz de potencia segmentada y dos parámetros de visualización que permiten identificar el número total de usuarios y la cantidad de estos que será parte de la simulación.



Fuente: elaboración propia.

La figura 107 muestra, a la izquierda, la matriz de potencia segmentada para 100 usuarios si el porcentaje de usuarios que se quiere analizar es del 50%: la zona en color negro representa el número de usuarios que son parte de la simulación, mientras que la zona en color blanco representa información desconocida; asimismo, a la derecha, se tiene el mismo número de usuarios, pero ahora el porcentaje se reduce al 40% y se seleccionan de forma aleatoria, es decir, solo 40 usuarios serán parte de la simulación, y debido a su selección aleatoria, se obtienen secciones desconocidas no continuas.

Figura 107. Matriz de potencia segmentada



Fuente: elaboración propia.

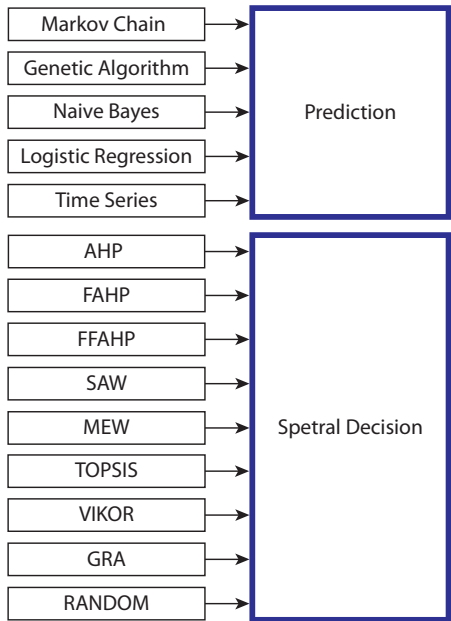
Modelos disponibles

Los usuarios del simulador tienen disponibles 14 tipos de modelos: 5 modelos para predicción y 9 modelos para el análisis de movilidad espectral (figura 108).

Estructura general de los modelos

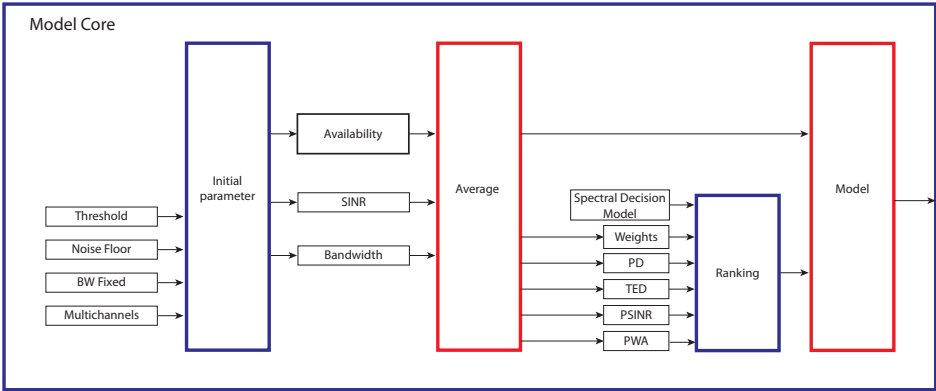
Si bien los modelos son independientes, requieren de parámetros en común, específicamente de la matriz de disponibilidad, por lo que, previo a la estructuración del modelo, se necesitan dos módulos adicionales: el que realiza la conversión de la matriz de potencia a la de disponibilidad y el que determina los promedios de los criterios para el análisis multicriterio (figura 109).

Figura 108. Modelos disponibles para predicción y movilidad espectral



Fuente: elaboración propia.

Figura 109. Descripción general de las entradas de los modelos



Fuente: elaboración propia.

Parámetros iniciales

Para establecer los parámetros iniciales de las respectivas simulaciones, el *software* cuenta con cuatro variables de entrada que deben ser parametrizadas por el usuario (tabla 64).

Tabla 64. Descripción de los parámetros de entrada iniciales

Parámetro	Descripción
<i>Threshold</i>	Umbral de decisión para determinar si una oportunidad espectral (SO) está disponible.
<i>Noise floor</i>	Piso de ruido promedio.
<i>BW fixed</i>	Ancho de banda fijo para cada canal de frecuencia.
<i>Multichannels</i>	Número máximo de canales adyacentes disponibles que se pueden agrupar para formar un solo canal.

Fuente: elaboración propia.

Disponibilidad

El *software* transforma los datos de potencia que están en un rango entre -40 y -147 a valores binarios, según la restricción dada por el valor de *threshold* —ecuación (130)—:

$$Available = \begin{cases} 1 & \text{If } Power > Threshold \\ 0 & \text{If } Power < Threshold \end{cases} \quad (130),$$

donde 1 representa una frecuencia disponible, y 0, una frecuencia no disponible. El resultado obtenido equivale a la matriz de disponibilidad y es la matriz de entrada para los diferentes modelos.

SINR

A partir del *noise floor* y de la matriz de potencia segmentada, se determina la relación de señal a interferencia más ruido (SINR) y se realiza la resta entre la matriz de datos de potencia de entrada y la variable *noise floor* ajustada por el usuario —ecuación (131)—:

$$SINR = [Power] - Noise Floor \quad (131).$$

Bandwidth

Para determinar la matriz de ancho de banda (*bandwidth*), se utilizan la matriz de disponibilidad previamente obtenida y los parámetros de *BW fixed* y *multichannels* —ecuación (132)—:

$$Bandwidth = BWfixed - (Count + Availability) \quad (132),$$

donde el valor de BW fijo es parametrizado por el usuario en la ventana principal del *software*.

Average

El módulo *average* determina los vectores de AP, ETA, PSINR y ABW (tabla 65), utilizados para realizar el análisis multicriterio de selección de canales disponibles.

Tabla 65. Vectores para el análisis multicriterio

Sigla	Promedio	Descripción
AP	Probabilidad de disponibilidad	Promedio de cada una de las columnas de la matriz de disponibilidad
ETA	Tiempo medio de disponibilidad	Promedio de ‘unos’ consecutivos de la matriz de disponibilidad
PSINR	Promedio de SINR	Promedio de cada columna de la matriz de SINR, sin tener en cuenta los ceros
ABW	Promedio de ancho de banda	Promedio de cada una de las columnas de la matriz de ancho de banda

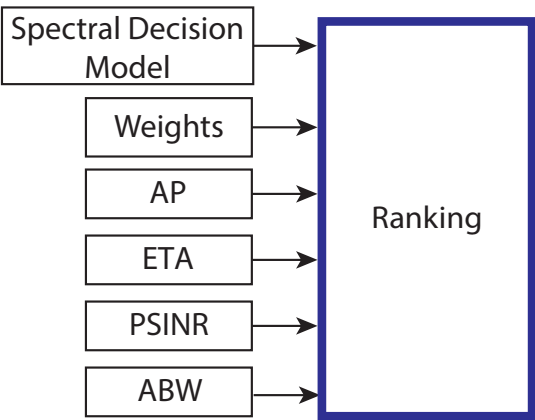
Fuente: elaboración propia.

El tamaño de cada uno de los vectores es de $1 \times n$, donde n corresponde a la cantidad de columnas de la matriz de potencia.

Ranking

El *ranking* es un módulo que utiliza análisis multicriterio para asignarles una puntuación a los diferentes canales; el objetivo es que, a partir de los vectores AP, ETA, PSINR y ABW, se puedan establecer los canales con mayor probabilidad de SO. Para obtener esta puntuación, el módulo requiere diferentes algoritmos multicriterio. La figura 110 presenta las variables de entrada necesarias para la parametrización de este módulo.

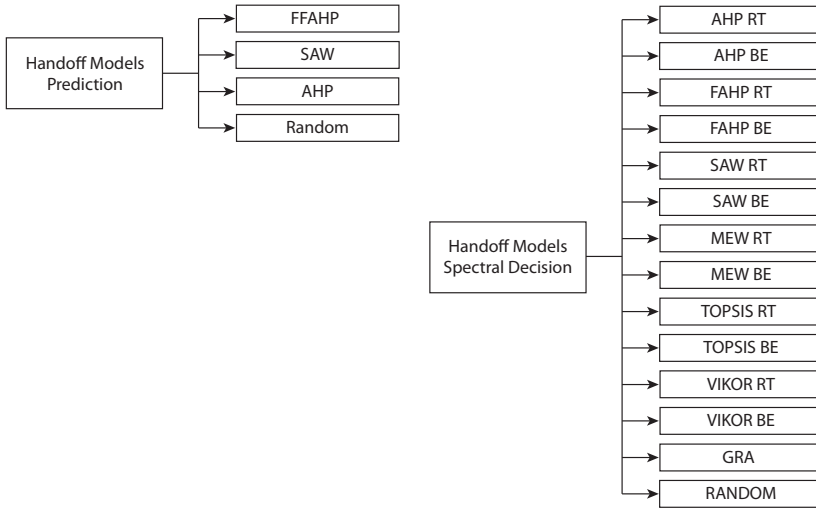
Figura 110. Variable de entrada del módulo *ranking*



Fuente: elaboración propia.

Cada técnica multicriterio corresponde a los diferentes algoritmos de *handoff models*, que el usuario puede seleccionar para cada simulación, cada uno programado de acuerdo con el estado del arte realizado sobre este tema. En total, el módulo está formado por 14 técnicas de toma de decisión multicriterio (MCDM) para el análisis de movilidad espectral y por 4 técnicas MCDM para predicción (figura 111).

Figura 111. Algoritmos de *handoff models*



Fuente: elaboración propia.

Cada uno de los *handoff models* requiere de la asignación de un vector de columna de pesos de tamaño 1×4 , que corresponde a los pesos (puntuación) que se les quiera asignar a los vectores de AP, ETA, PSINR y ABW; estos pesos pueden ser ajustados por el usuario, excepto en el modelo *random*, que genera, de manera aleatoria, el vector de puntuaciones. En general, los pesos son multiplicados matricialmente por los vectores de decisión —ecuación (133)—:

$$\begin{aligned}
 & [Weights\ Vector]_{1 \times 4} \times [P]_{4 \times n} \\
 & [Weights\ Vector]_{1 \times 4} = [W_{PD} \quad W_{TED} \quad W_{PSINR} \quad W_{PWA}] \\
 & [P]_{4 \times n} = \begin{bmatrix} PD_{1,1} & \dots & PD_{1,n} \\ TED_{2,1} & \dots & TED_{2,n} \\ PSINR_{3,1} & \dots & PSINR_{3,n} \\ PWA_{4,1} & \dots & PWA_{4,n} \end{bmatrix} \quad (133).
 \end{aligned}$$

Descripción de modelos

Cada uno de los modelos requiere como mínimo de la matriz de disponibilidad y de la puntuación entregada por el módulo *ranking*; el número de parámetros adicionales requeridos depende del tipo de estrategia a implementar, por lo que, a continuación, se realiza una descripción de las estrategias, los algoritmos de toma de decisión multicriterio, algunas técnicas para la predicción (aunque no se usaron todas) y el modelo para la movilidad espectral.


Técnicas de decisión multicriterio: FFAHP, SAW, TOPSIS y VIKOR

La movilidad espectral se realiza a través de un algoritmo de búsqueda que puede ser parametrizado a través de 16 algoritmos del *spectral decision model*, dentro de los cuales se encuentran los algoritmos seleccionados: FFAHP, SAW, TOPSIS y VIKOR. El algoritmo es el encargado de realizar los saltos de columna (frecuencias) en la matriz de disponibilidad según el vector de posiciones entregado por el módulo *ranking*; de esta forma, el algoritmo realiza saltos hasta encontrar un valor de ‘uno’ equivalente a una frecuencia disponible. Al realizar los saltos de columna, si el algoritmo encuentra un ‘uno’, automáticamente realiza un nuevo salto, pero esta vez a la siguiente fila de la matriz de disponibilidad.

Modelo propuesto

La figura 112 presenta el diagrama de bloques del modelo propuesto. Los primeros dos bloques corresponden a la información de cada uno de los canales y a la correspondiente segmentación de las matrices de potencia y disponibilidad según el número de usuarios. El área rectangular central corresponde al modelo propuesto, que está formado por un bloque con los 16 algoritmos del *spectral decision model*; un segundo bloque de *ranking*, encargado de asignar la puntuación a cada canal, y, finalmente, el bloque que realiza el análisis de movilidad espectral de acuerdo con la puntuación asignada.

Figura 112. Etapas de los algoritmos para movilidad espectral



Fuente: elaboración propia.

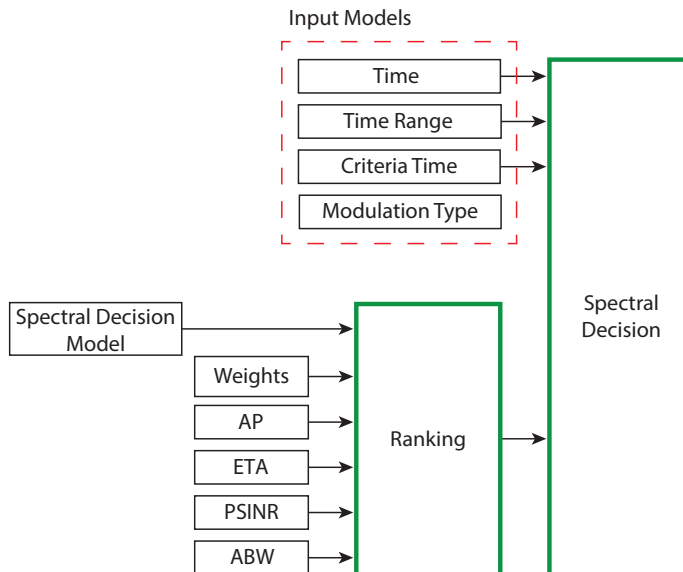
Datos de entrada

La figura 113 presenta el diagrama de bloques de los parámetros de entrada. La información pertenece a las variables de salida del módulo *average*, al ajuste del módulo *ranking* y a los parámetros de tiempo, rango y modulación.

La variable de entrada *time* representa un instante de tiempo y la condición de parada del algoritmo de búsqueda; es decir, el algoritmo realiza saltos de fila hasta completar el tiempo establecido.

Además de la condición de parada *time*, el modelo de movilidad tiene una variable de entrada llamada *criteria time*, que establece un criterio de tiempo para el cual el algoritmo de búsqueda saltará de acuerdo con el vector de fila de posiciones calculado inicialmente: si el tiempo de parada *time* es mayor que el *criteria time*, cuando el algoritmo de búsqueda se encuentre en el instante de tiempo $t = \text{criteria time}$, el vector de posiciones se actualizará calculando nuevamente los promedios para el mismo *spectral decision model*, pero, en este caso, para un número definido de filas de la matriz de disponibilidad, SINR y BW; la cantidad de filas es parametrizable por la entrada *time range*; las filas seleccionadas corresponden a las últimas filas utilizadas antes de la condición de *criteria time*. Esta condición permanecerá hasta que se cumpla el tiempo de simulación, por lo que, si el tiempo de parada *time* es mayor que $n \times \text{criteria time}$, el vector de posiciones se actualizará n veces.

Figura 113. Datos de entrada y salida: movilidad espectral



Fuente: elaboración propia.

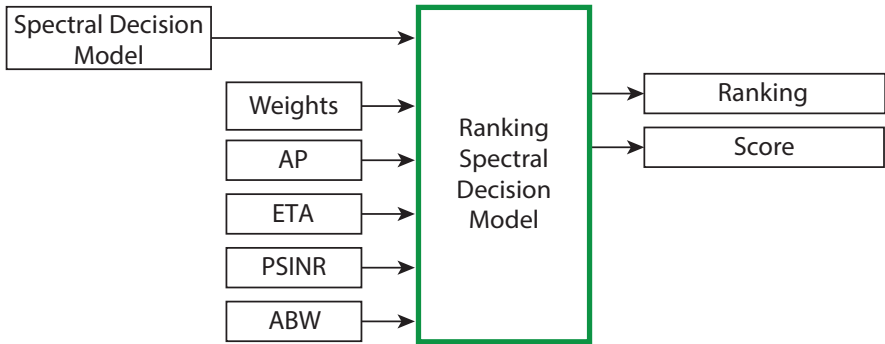
Modelos de movilidad espectral

Los modelos de movilidad espectral corresponden a los diferentes algoritmos del *spectral decision model* que el usuario puede seleccionar y dependen de la concatenación de los vectores de AP, ETA, PSINR y ABW.

Cada uno de los 16 algoritmos del *spectral decision model* requiere de la asignación de un vector de columna de pesos o puntuaciones de tamaño 1×4 , que corresponde a la variable de entrada *weights* de la figura 114; estos pesos pueden ser ajustados por el usuario para cada uno de los diferentes modelos, excepto en el modelo *random*, que genera, de manera aleatoria, el vector de puntuaciones.

El diagrama de bloques que se muestra en la figura 114 se aplica de forma general para cada una de las estrategias disponibles; la información de entrada equivale a los pesos, al modelo seleccionado y a los vectores AP, ETA, PSINR y ABW. La salida del bloque entrega dos vectores: el primero se denomina *Score* y contiene la puntuación asignada a cada canal, y el segundo es el *ranking*, que contiene, de forma descendente, los canales según la puntuación obtenida.

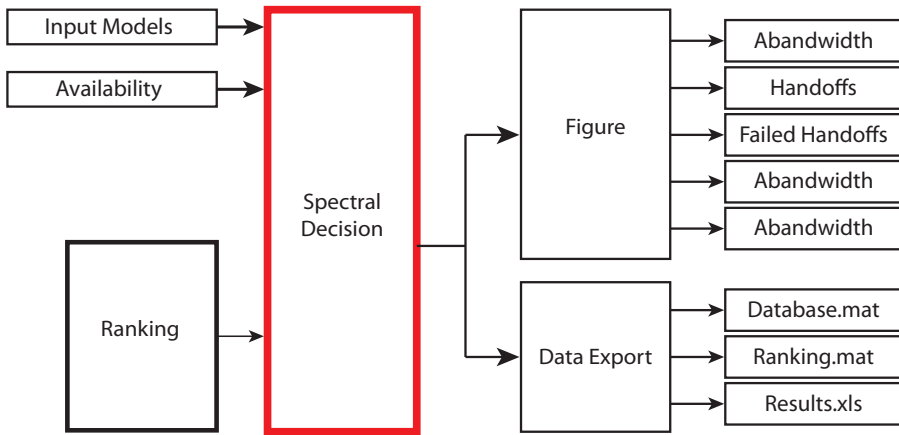
Figura 114. Variables de entrada y salida del *ranking* de decisión espectral para movilidad espectral



Fuente: elaboración propia.

Evaluación de movilidad espectral

La evaluación de movilidad espectral se realiza a través de la matriz de entrenamiento y validación. Los resultados corresponden a las figuras 62-101 (*handoffs*, *handoffs* fallidos, BW, retardo y *throughput*). Además, los saltos de columna, los saltos de fila, el tiempo, la disponibilidad y el valor de BW correspondiente a la posición de cada salto son almacenados en un vector y retroalimentados en una tabla de Excel. La figura 115 muestra el diagrama con los parámetros de salida de la evaluación de la movilidad espectral.

Figura 115. Parámetros de salida de la evaluación de la movilidad espectral

Fuente: elaboración propia.

Técnica de predicción con cadenas de Markov

Las cadenas de Markov son una técnica estocástica que se basa en el análisis de la dinámica interna del sistema; estas simulan la predicción del estado actual en un tiempo determinado a partir de los estados anteriores. Asimismo, son un proceso aleatorio que cuenta con la propiedad de que, dado el valor actual del proceso X_t , los valores futuros X_s para $s > t$ son independientes de los valores pasados X_u para $u < t$.

Modelo propuesto

El algoritmo elaborado para la evaluación de *handoff* espectral utilizando cadenas de Markov está dividido en cinco etapas (figura 116). La primera etapa corresponde a la selección de los datos de entrada; en la segunda, con el objetivo de reducir los canales de estudio para mejorar los tiempos de simulación, se realiza una selección de canales para la matriz de entrada con dos algoritmos de selección; en la tercera etapa, se realiza la construcción de la matriz de probabilidades de transición; en la cuarta, se evalúa la matriz de transición, y, finalmente, en la quinta, se procesan los resultados de la evaluación y se muestran de forma gráfica los indicadores relevantes. La descripción de cada etapa se realiza, a partir de los algoritmos implementados, por estructura, y la programación se desarrolla utilizando funciones.

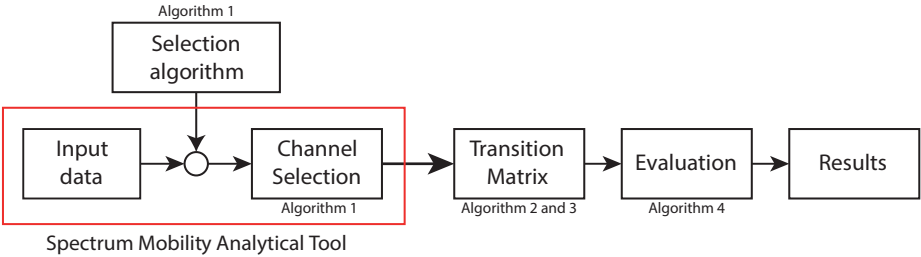
Datos de entrada y selección de canales

La figura 117 presenta el diagrama de bloques de la primera y segunda etapa. Con respecto a la primera etapa, la información de entrada pertenece a las variables de salida del módulo *average* y al ajuste del módulo *ranking*; adicionalmente, el usuario del

software debe parametrizar el tiempo, el número de canales que se va a utilizar y un porcentaje de relación para establecer cuándo una predicción es considerada como buena.

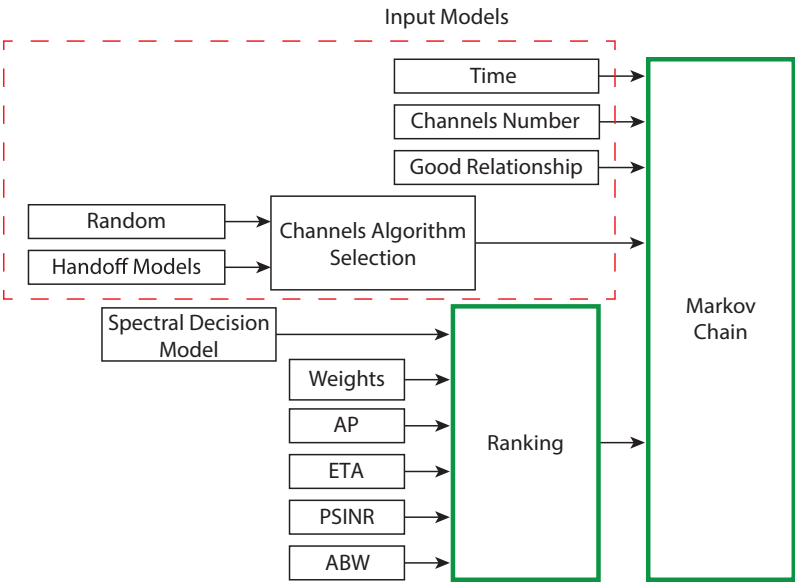
En la segunda etapa, el módulo debe seleccionar los canales (columnas) de estudio; la cantidad de canales es un parámetro conocido, ya que corresponde al valor ajustado en *channels number*, sin embargo, se requiere establecer cómo y cuáles canales seleccionar, y para esto se utilizan dos técnicas: la primera utiliza el *ranking* FFAHP, y la segunda hace una selección aleatoria basada en un modelo de distribución normal.

Figura 116. Etapas del algoritmo de la cadena de Markov



Fuente: elaboración propia.

Figura 117. Datos de entrada y salida: cadenas de Markov

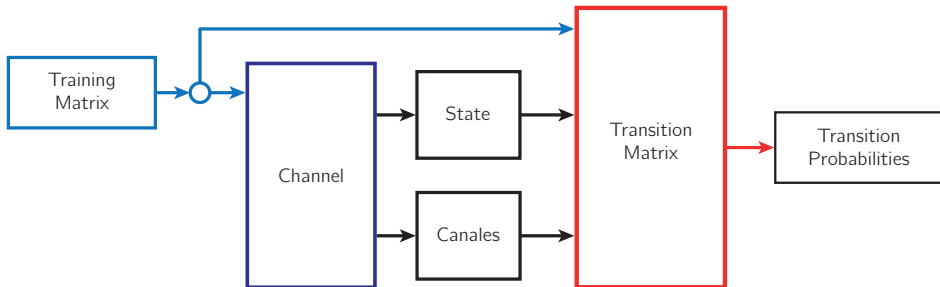


Fuente: elaboración propia.

Probabilidad de estado

La figura 118 muestra el diagrama de bloques para la tercera etapa, cuyo objetivo es determinar la matriz de probabilidades de transición; los datos de entrada corresponden a la matriz de entrenamiento, al número de canales y a un vector de estados, el cual indica los estados presentes de la matriz de entrenamiento.

Figura 118. Matriz de transición: cadenas de Markov



Fuente: elaboración propia.

La matriz de transición de entrenamiento determina las probabilidades de estado actual y futuro que son necesarias para la implementación de las cadenas, y las probabilidades de la matriz de entrenamiento serán utilizadas en la matriz de validación para cuantificar los *handoffs* espectrales. La cadena de Markov establece como requerimiento conocer el estado actual y futuro del sistema; al respecto, un estado futuro se define como *time steps* + 1.

La técnica utilizada para los estados actuales está orientada a modelar cada *time step* mediante un número entero positivo; para obtener este modelamiento, se representa cada fila de la matriz de disponibilidad de entrenamiento como un número binario, donde cada bit corresponde a un canal, y posteriormente se realiza la conversión de base 2 a base 10.

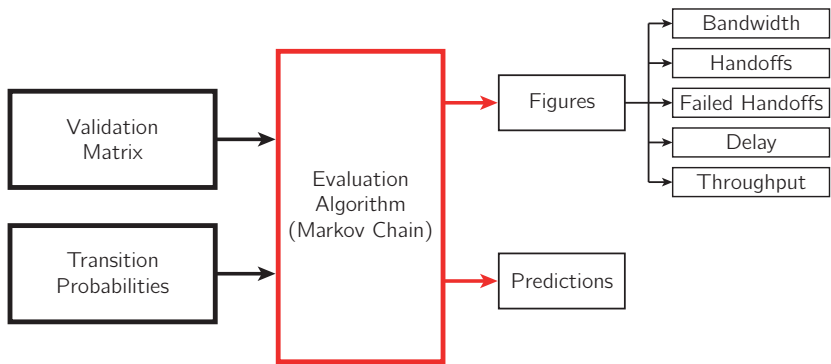
Para los estados futuros se realiza un barrido de la matriz de entrenamiento según el conjunto de estados actuales obtenidos; luego, se determinan los estados de mayor y menor ocurrencia evaluando todos los canales del *time step* futuro, y posteriormente se normalizan los resultados.

Evaluación de handoffs espectrales

La figura 119 muestra el diagrama de bloques para la cuarta etapa, cuyo propósito es analizar los *handoffs* espectrales evaluando las probabilidades de transición sobre la matriz de validación; la información que se requiere para la evaluación es la matriz de validación de la segunda etapa y la probabilidad de transición de la tercera etapa.

Los resultados se cuantifican a la salida de la evaluación a partir de la construcción de las figuras 62-101 (*handoffs*, *handoffs* fallidos, BW, retardo y *throughput*); además, se entregan indicadores asociados a las predicciones exactas, buenas, regulares y malas (tabla 66).

Figura 119. Algoritmo de evaluación: cadena de Markov



Fuente: elaboración propia.

Las figuras de salidas se construyen utilizando el *software* Spectrum Mobility Analytical Tool; los indicadores son valores porcentuales entregados en la evaluación del algoritmo (tabla 66).

Tabla 66. Indicadores de predicción

Indicador	Característica
Predicción exacta	Se define como la condición en la que la predicción del futuro es 100% acertada.
Predicción buena	Se define como la condición en la que la predicción del futuro tiene un acierto mayor al 70% y menor al 100%.
Predicción regular	Se define como la condición en la que la predicción del futuro tiene un acierto mayor al 30% y menor al 70%.
Predicción mala	Se define como la condición en la que la predicción del futuro tiene un acierto menor al 30%.

Fuente: elaboración propia.

Técnica de predicción con algoritmos genéticos

Los algoritmos genéticos son modelos de optimización inspirados en el proceso de genética y evolución; un modelo simple está integrado por una población inicial de individuos y un conjunto de operaciones que interactúan sobre la población para obtener nuevas generaciones de individuos.


La población está constituida por un conjunto de individuos representado mediante un equivalente en número binario: a la representación binaria se le llama *cromosoma*, y a cada bit dentro del cromosoma se le llama *gen*. En general, un algoritmo genético se caracteriza mediante cinco definiciones o equivalentes genéticos, descritos en la tabla 67 y representados gráficamente para una población específica en la figura 120.

Tabla 67. Equivalentes genéticos

Parámetro genético	Descripción
Alelo	Cada uno de los estados distintos que puede presentar un gen en una misma posición.
Gen	Es el valor de un alelo dentro de un arreglo.
Cromosoma	Es una colección de genes en forma de arreglo.
Posición	Es el lugar que ocupa un gen dentro del cromosoma.
Índice	Es la posición que tiene el individuo dentro de la población.

Fuente: elaboración propia.

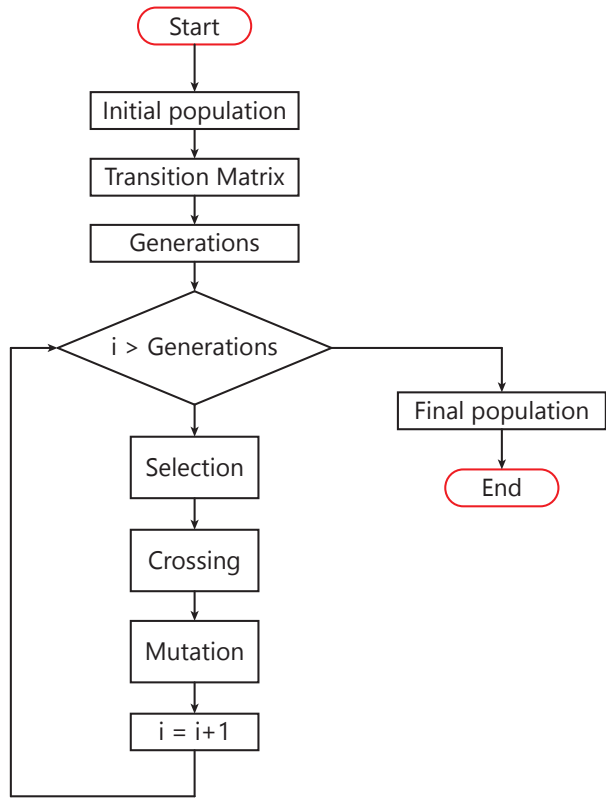
Figura 120. Equivalentes genéticos para una población específica



Fuente: elaboración propia.

El modelo genético establece una población inicial aleatoria, que es verificada por una función de transición (matriz de transición); el objetivo es asegurar que la población tenga valores coherentes; la selección, cruce y mutación construye la población final, equivalente a los datos de entrenamiento. El número de generaciones (iteraciones) se ajusta bajo parámetros de rendimiento, como tiempos de simulación; es una variable que se parametriza con criterio de prueba y error. La figura 121 presenta el diagrama de flujo del algoritmo genético.

Figura 121. Diagrama de flujo del algoritmo genético




Fuente: elaboración propia.

En la figura 122 se presenta el diagrama de bloques del modelo: los bloques de *occupation* y *processing* están asociados a la base de datos de ocupación espectral y al respectivo procesamiento que permite definir la matriz de disponibilidad para cada uno de los canales; el algoritmo propuesto está conformado por cinco subbloques.

El modelo propuesto corresponde a los bloques delimitados por el cuadrado con línea discontinua, formado por cinco algoritmos: los bloques *selection algorithm* y *channel selection* permiten seleccionar los canales (número de columnas) a partir de dos técnicas: la estrategia multivariable difusa realimentada (FFAHP) o una selección aleatoria; la variable de parametrización es el número de canales (entre 10 y 460). Los bloques *initial population*, *population operators* y *final population*, por su parte, realizan la construcción de la matriz de entrenamiento a partir de algoritmos genéticos: primero, se establece una población inicial aleatoria que tiene una descripción binaria ajustada

según el número de canales, y luego se realizan las operaciones: selección directa, cruce y mutación (tasas de mutación pequeñas) para obtener la población final, equivalente a los datos de entrenamiento.

Figura 122. Etapas del algoritmo: algoritmos genéticos



Fuente: elaboración propia.

Datos de entrada y selección de canales

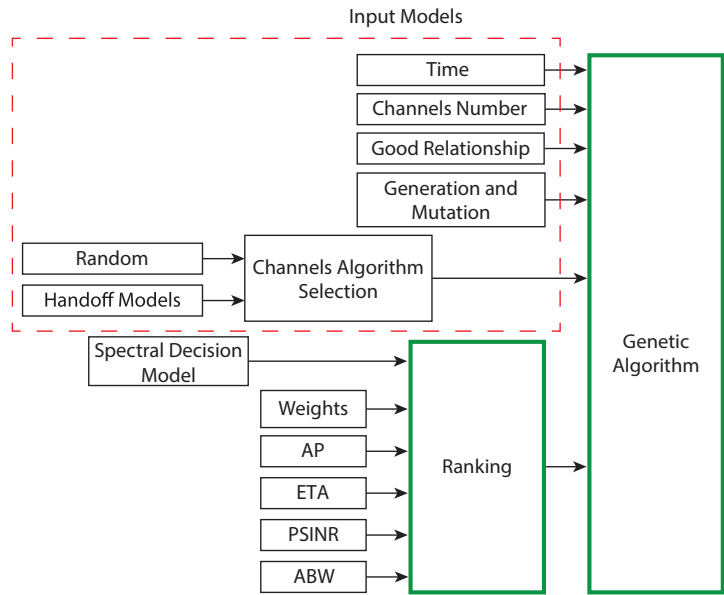
La figura 123 presenta el diagrama de bloques de los parámetros de entrada. La información pertenece a las variables de salida del módulo *average* y al ajuste del módulo *ranking*; adicionalmente, el usuario del *software* debe parametrizar el tiempo, el número de canales que se va a utilizar, un porcentaje de relación para establecer cuándo una predicción es considerada como buena, el número de generaciones que se quieren analizar y el porcentaje de mutaciones.

Así como en el modelo de cadenas de Markov, este selecciona los canales (columnas) de estudio; la cantidad de canales es un parámetro conocido, ya que corresponde al valor ajustado en *channels number*; sin embargo, se requiere establecer cómo y cuáles canales seleccionar, y para esto se utilizan dos técnicas: la primera utiliza el *ranking* FFAHP, y la segunda hace una selección aleatoria basada en un modelo de distribución normal.

Evaluación de handoffs espectrales

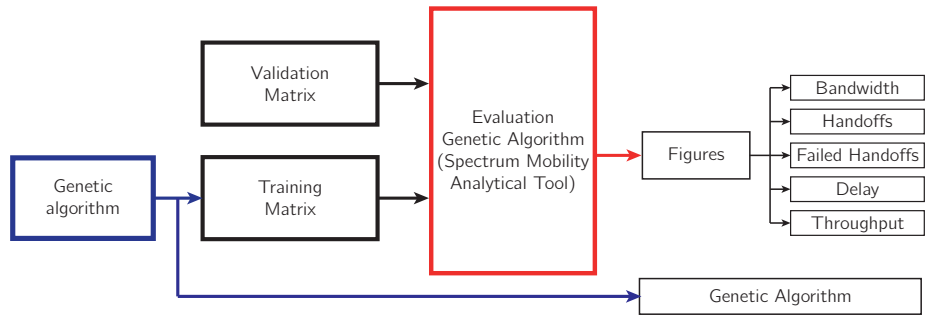
La evaluación de los *handoffs* espectrales se realiza a través de la matriz de entrenamiento y validación. Los resultados corresponden a las figuras 62-101 (*handoffs*, *handoffs* fallidos, BW, retardo y *throughput*). Aunque no hacen parte de la evaluación, se entregan datos del algoritmo genético: número de generaciones, población inicial y porcentaje de mutación, entre otros. La figura 124 muestra el diagrama de evaluación.

Figura 123. Datos de entrada y salida: algoritmos genéticos



Fuente: elaboración propia.

Figura 124. Algoritmo de evaluación: algoritmos genéticos



Fuente: elaboración propia.

Técnica de predicción con clasificador bayesiano ingenuo

Una de las principales consideraciones para la selección de modelos de predicción es que se tienen múltiples características o criterios que pueden mejorar la predicción. Esto se explica porque la formación del modelo de predicción puede tener en cuenta información o criterios como la AP y el ETA.


Una estructura basada en el clasificador bayesiano ingenuo asume que la presencia de una característica en particular no se relaciona de ninguna manera con la presencia de cualquier otra característica, incluso si una de estas características depende de la otra.

Modelo propuesto

El modelo propuesto toma como variable de entrada una matriz de entrenamiento de ocupación espectral. Antes de ser usada en el proceso de entrenamiento del predictor, la información espectral pasa por el bloque de procesamiento de información espectral, el cual convierte los datos en series dicotómicas en las que un '0' representa ocupación del canal, y un '1', disponibilidad de canal. Con este procesamiento de la información, se entrena el algoritmo bayesiano ingenuo.

La figura 125 presenta el diagrama de bloques del modelo de predicción propuesto. El primer bloque es la entrada del *spectral information processing*, que tiene la tarea de definir la ocupación o disponibilidad de cada uno de los canales, de acuerdo con la ecuación de probabilidad de falsa alarma. El área rectangular corresponde al modelo propuesto, que consta de dos algoritmos: 1) *naive bayes algorithm* (algoritmo bayesiano ingenuo) y 2) *channel allocation prediction*. Para calcular los parámetros de costo y gradiente que ajustan el predictor, la primera función utiliza como variables de entrenamiento el vector PSINR, ETA y la matriz de disponibilidad, y el segundo algoritmo asigna la ocupación de canal mediante la asignación de '1' y '0', lo cual genera, como variable de salida, una matriz de predicción de disponibilidad de BW.

Figura 125. Etapas del algoritmo bayesiano ingenuo



Fuente: elaboración propia.

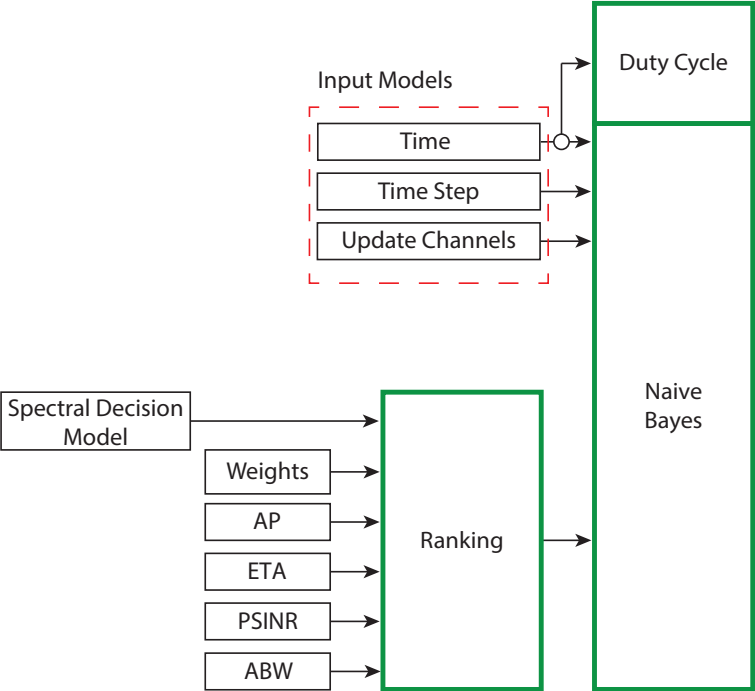
Datos de entrada

La figura 126 presenta el diagrama de bloques de los parámetros de entrada. La información pertenece a las variables de salida del módulo *average* y al ajuste del módulo *ranking*; adicionalmente, el usuario del *software* debe parametrizar el tiempo,

la relación porcentual para establecer los criterios de predicción y el tiempo de reentrenamiento.

Como se ve en la figura 126, el módulo bayesiano ingenuo permite calcular el ciclo útil, para lo cual solo se requiere ajustar el tiempo.

Figura 126. Datos de entrada y salida: algoritmo bayesiano ingenuo



Fuente: elaboración propia.

Predictor de ocupación espectral

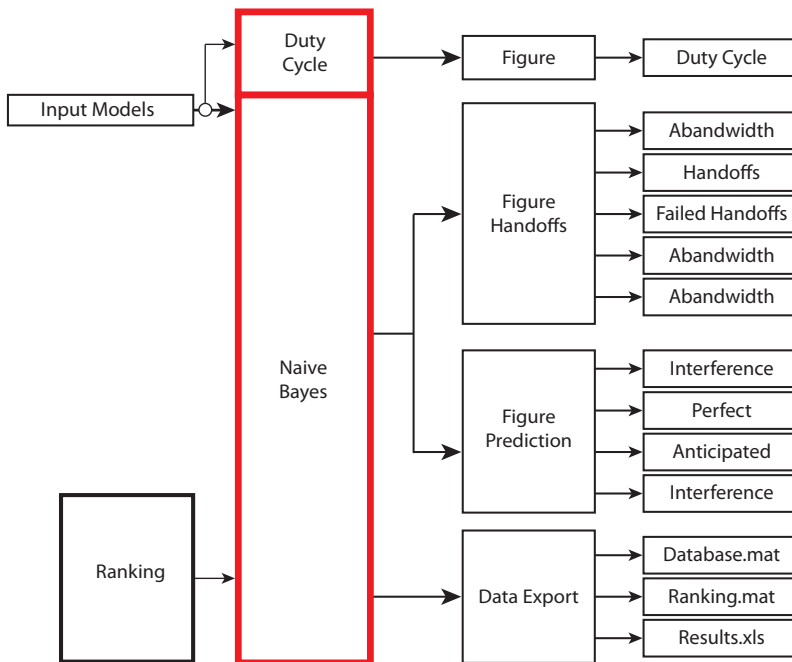
El algoritmo utiliza las probabilidades generadas a través del algoritmo bayesiano ingenuo para predecir la disponibilidad de cada canal durante el tiempo de simulación (para la predicción, se deben procesar todos los canales disponibles).

Las variables AP y ETA se consideran las probabilidades de ocupación/disponibilidad del canal. Durante el proceso, se construyen dos nuevas matrices que, junto con la función de predicción, clasifican cada fila (*time step*) en *ocupada* o *disponible*. Estas probabilidades se asignan a una matriz llamada *disponibilidad predicción*, donde los estados del canal están definidos por '1' (disponible) y '0' (ocupado). Una vez que se ha creado la matriz de predicción, es posible comparar la precisión de la predicción durante el tiempo de transmisión.

Evaluación de handoffs espectrales

La evaluación de los *handoffs* espectrales se realiza a través de la matriz de entrenamiento y validación. Adicionalmente, este modelo cuenta con métricas adicionales asociadas a la calidad de las predicciones realizadas. Por lo tanto, para el análisis de *handoffs* espectrales, los resultados corresponden a las figuras 62-101 (*handoffs*, *handoffs* fallidos, BW, retardo y *throughput*); para el análisis de predicción, utiliza el número de *handoffs* anticipados, perfectos, fallidos y la interferencia. Para el análisis de ciclo útil, el simulador entrega los resultados de acuerdo con el ajuste del tiempo. La figura 127 muestra el diagrama de evaluación.

Figura 127. Algoritmo de evaluación del clasificador bayesiano ingenuo



Fuente: elaboración propia.

Técnicas de predicción de regresión logística


La regresión logística tiene como principal ventaja el hecho de que se pueden usar diversas variables explicativas de manera simultánea. Esta característica permite conocer el impacto de las variables explicativas sobre la variable *respuesta*. Si se llegase a examinar las variables explicativas de forma independiente, ignorando la covarianza entre las variables, se podría caer en confusión.

Modelo propuesto

El modelo propuesto toma como variable de entrada una matriz de entrenamiento de ocupación espectral. Antes de ser usada en el proceso de entrenamiento del predictor, la información espectral pasa por el bloque de procesamiento de información espectral, el cual convierte los datos en series dicotómicas en las que un '0' representa ocupación del canal, y un '1', disponibilidad de canal. Con este procesamiento de la información, se entrena el algoritmo de regresión logística.

La figura 128 presenta el diagrama de bloques del modelo de predicción propuesto. El primer bloque es la entrada del *spectral information processing*, que tiene la tarea de definir la ocupación o disponibilidad de cada uno de los canales, de acuerdo con la ecuación de probabilidad de falsa alarma. El área rectangular central corresponde al modelo propuesto, que consta de dos algoritmos: 1) *logistic regression algorithm* (logaritmo de regresión logística) y 2) *channel allocation prediction*. Para calcular los parámetros de costo y gradiente que ajustan el predictor, la primera función utiliza como variables de entrenamiento el vector PSINR, ETA y la matriz de disponibilidad, y el segundo algoritmo asigna la ocupación de canal mediante la asignación de '1' y '0', lo cual genera, como variable de salida, una matriz de predicción de disponibilidad de BW.

Figura 128. Etapas del algoritmo de regresión logística



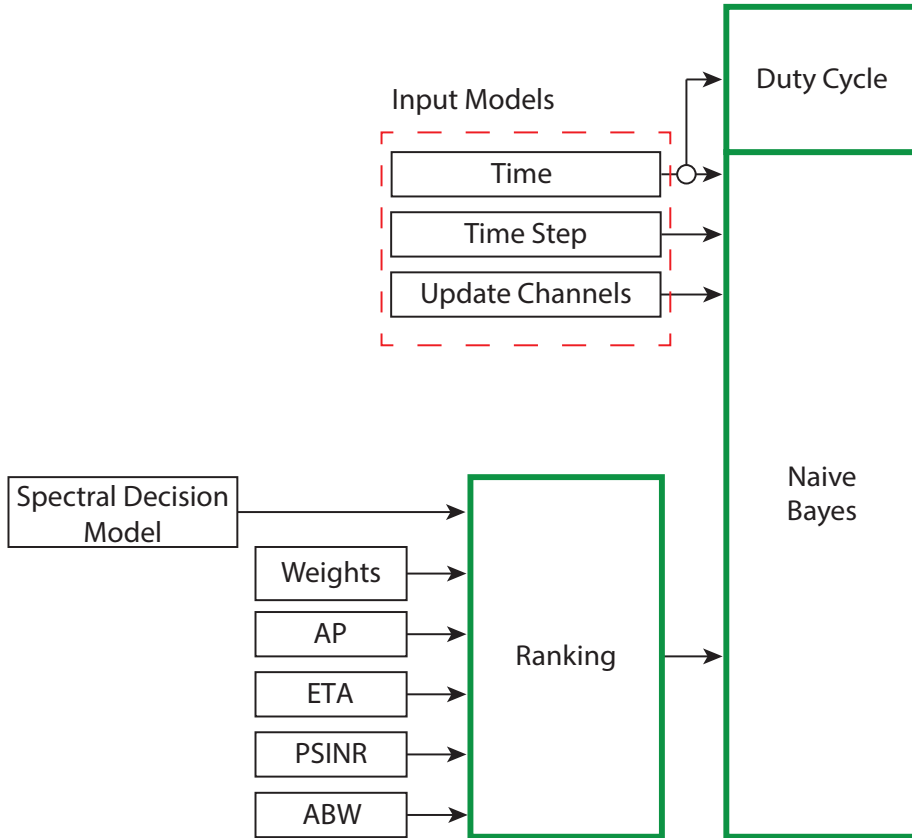
Fuente: elaboración propia.

Datos de entrada

La figura 129 presenta el diagrama de bloques de los parámetros de entrada. La información pertenece a las variables de salida del módulo *average* y al ajuste del módulo *ranking*; adicionalmente, el usuario del *software* debe parametrizar el tiempo, la relación porcentual para establecer los criterios de predicción y el tiempo de reentrenamiento.

Como se ve en la figura 129, el módulo de regresión logística permite calcular el ciclo útil, para lo cual solo se requiere ajustar el tiempo.

Figura 129. Datos de entrada y salida del algoritmo de regresión logística



Fuente: elaboración propia.

Predictor de ocupación espectral


El objetivo del algoritmo es utilizar una matriz dicotómica de entrenamiento para implementar una función $h: X \rightarrow Y$ tal que $h(x)$ sea un predictor eficaz de ocupación espectral respecto a los valores Y . La figura 130 muestra el proceso de entrenamiento del algoritmo.

Evaluación de handoffs espectrales

La evaluación de los *handoffs* espectrales se realiza a través de la matriz de entrenamiento y validación. Adicionalmente, este modelo cuenta con métricas adicionales asociadas a la calidad de las predicciones realizadas. Por lo tanto, para el análisis de *handoffs* espectrales, los resultados corresponden a las figuras 62-101 (*handoffs*, *handoffs* fallidos, BW, retardo y *throughput*); para el análisis de predicción, utiliza el número de *handoffs* anticipados, perfectos, fallidos y la interferencia, y para el análisis

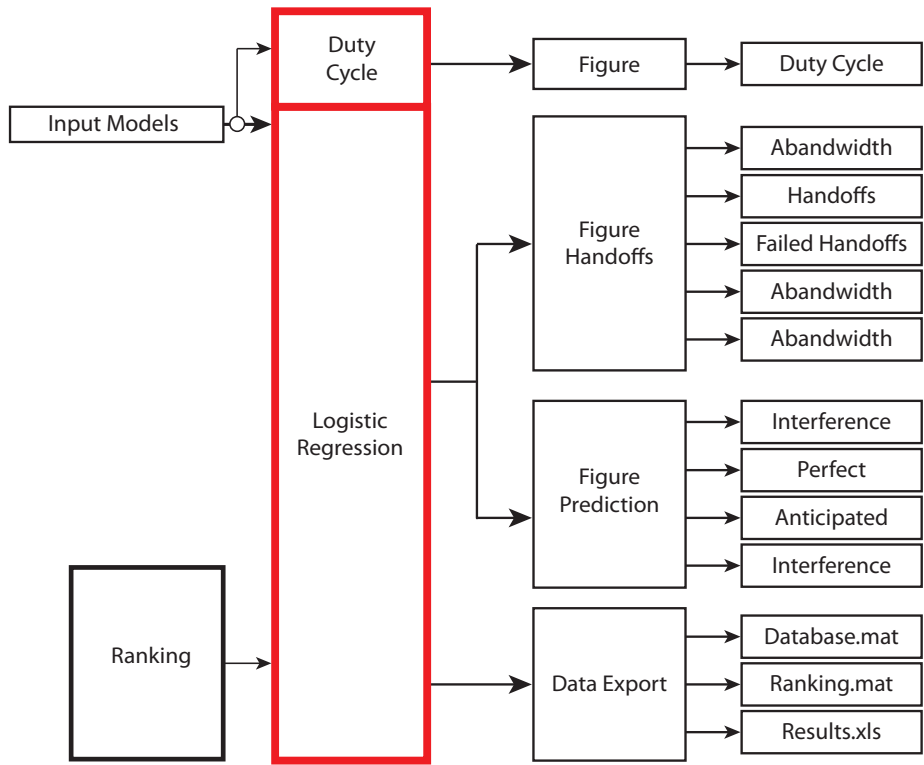
de ciclo útil, el simulador entrega los resultados de acuerdo con el ajuste del tiempo. La figura 131 muestra el diagrama de evaluación.

Figura 130. Proceso de entrenamiento del algoritmo de regresión logística



Fuente: elaboración propia.

Figura 131. Algoritmo de evaluación de la regresión logística



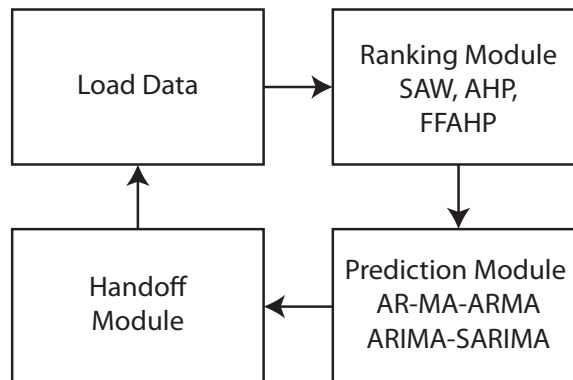
Fuente: elaboración propia.

Técnica de predicción por series de tiempo

El objetivo del modelo de transferencia proactiva pura es hacer predicciones que definan el comportamiento de los PU y dar herramientas al sistema para reaccionar antes de que ocurra el evento de interferencia. Los modelos estocásticos generan nuevos datos a partir de registros históricos mediante el ajuste de valores para diferentes retardos de varianza basados en un coeficiente de correlación en serie. Existen modelos de series temporales basados en autorregresivas (AR), promedios móviles (MA), promedios móviles autorregresivos (ARMA), promedios móviles integrados autorregresivos (ARIMA) y modelo estacionario de autorregresión integrado con media móvil (SARIMA).

El algoritmo propuesto se muestra en el diagrama de bloques de la figura 132: el módulo *load data* toma la información de la disponibilidad; el módulo de *ranking* contiene los métodos SAW, AHP, FFAHP y *random* para clasificar los canales que tienen mayores oportunidades espectrales, y el *prediction module* toma la información del canal seleccionado y aplica regresiones AR, MA, ARMA, arima y sarima para predecir la llegada del PU al canal seleccionado.

Figura 132. Etapas del algoritmo por series de tiempo

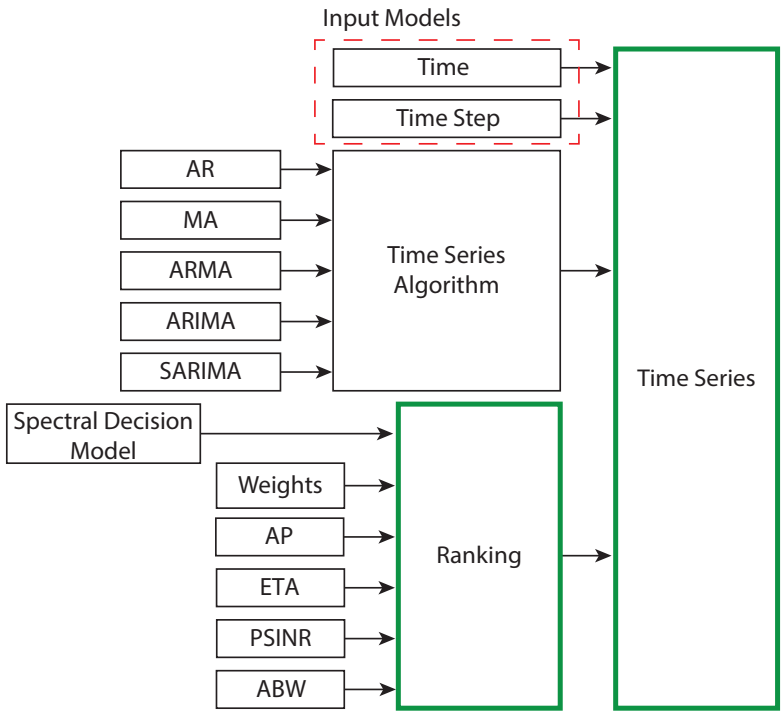


Fuente: elaboración propia.

Datos de entrada

La figura 133 presenta el diagrama de bloques de los parámetros de entrada. La información pertenece a las variables de salida del módulo *average* y al ajuste del módulo *ranking* y el modelo de serie temporal.

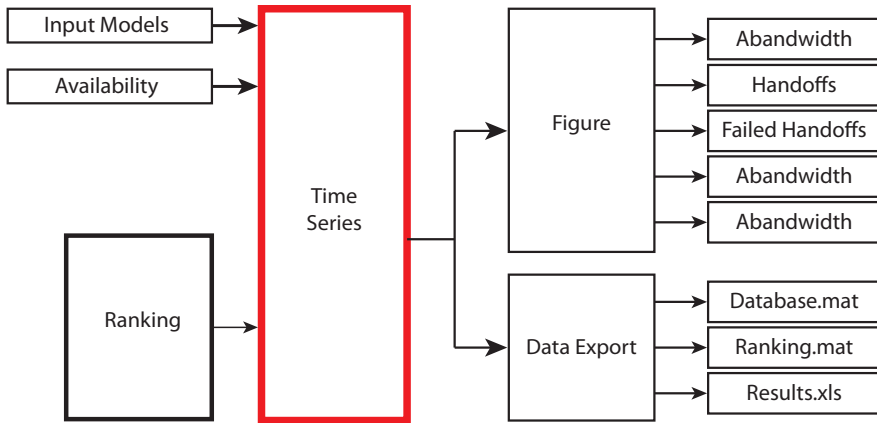
Figura 133. Datos de entrada y salida del algoritmo por series de tiempo



Fuente: elaboración propia.

Evaluación de handoffs espectrales

La evaluación de los *handoffs* espectrales se realiza a través de la matriz de entrenamiento, validación y predicción, y los resultados corresponden a las figuras 62-101 (*handoffs*, *handoffs* fallidos, BW, retardo y *throughput*). La figura 134 muestra el diagrama de evaluación.

Figura 134. Algoritmo de evaluación del algoritmo por series de tiempo

Fuente: elaboración propia.

Movilidad espectral

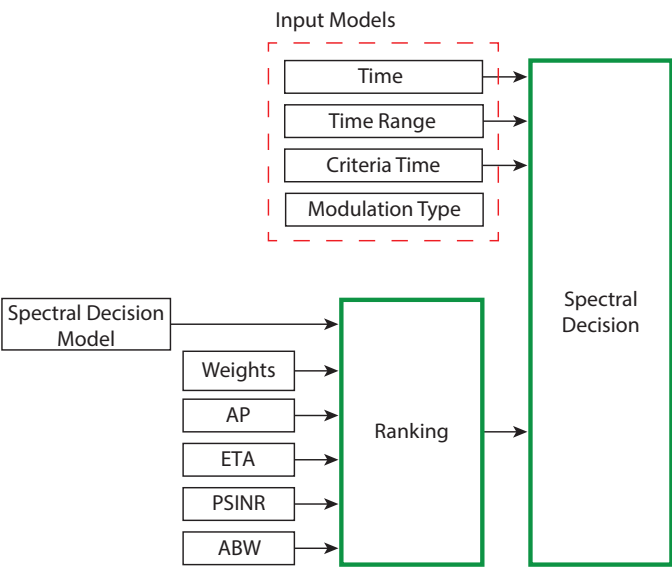
La movilidad espectral se realiza a través de un algoritmo de búsqueda encargado de realizar saltos de columna (frecuencias) en la matriz de disponibilidad según el vector de posiciones entregado por el módulo *ranking*; de esta forma, el algoritmo realiza saltos hasta encontrar un valor de ‘uno’ equivalente a una frecuencia disponible, y cada salto de columna es almacenado en un vector que será retroalimentado en forma de tabla para el usuario al final de la simulación. Al realizar los saltos de columna, si el algoritmo encuentra un ‘uno’, automáticamente realiza un nuevo salto, pero esta vez a la siguiente fila de la matriz de disponibilidad; cada fila representa un instante de tiempo y la condición de parada del algoritmo de búsqueda, que es definida por el usuario en la variable *time* del entorno gráfico; es decir, el algoritmo realiza saltos de fila hasta completar el tiempo establecido; así como los saltos de columna, los saltos de fila, el tiempo y la disponibilidad son almacenados en un vector y retroalimentados en la misma tabla del vector de saltos de columna.

Además de la condición de parada *time*, el modelo de movilidad tiene una variable de entrada llamada *criteria time*, que establece un criterio de tiempo para el cual el algoritmo de búsqueda saltará de acuerdo con el vector de fila de posiciones calculado inicialmente: si el tiempo de parada *time* es mayor que el *criteria time*, cuando el algoritmo de búsqueda se encuentre en el instante de tiempo $t = \text{criteria time}$, el vector de posiciones se actualizará calculando nuevamente los promedios para el mismo *handoff model*, pero, en este caso, para un número definido de filas de la matriz de disponibilidad, SINR y BW; la cantidad de filas es parametrizable por el usuario mediante la variable *time range* del entorno gráfico; las filas seleccionadas corresponden

a las últimas filas utilizadas antes de la condición de *criteria time*. Esta condición permanecerá hasta que se cumpla el tiempo de simulación, por lo que, si el tiempo de parada *time* es mayor que $n \times \text{criteria time}$, el vector de posiciones se actualizará n veces.

El diagrama presentado en la figura 135 muestra el flujo de datos de entrada y salida.

Figura 135. Datos de entrada y salida: movilidad espectral



Fuente: elaboración propia.

Funciones *Data_Export* y *Figure*

Cuando se cumple la condición de parada, la herramienta propuesta exporta los resultados en dos diferentes formatos: .xls (Excel) y .mat (Matlab). En la tabla 68 se muestran los archivos exportados y el tipo de archivo, de acuerdo con lo seleccionado por el usuario en la función *Data_Export*.

Tabla 68. Formatos de los archivos exportados

Archivo	Formato de exportación
<i>Results</i>	Documento en Excel (.xls)
<i>Database</i>	Documento en Matlab (.mat)
<i>Ranking</i>	Documento en Matlab (.mat)

Fuente: elaboración propia.

Los archivos de Matlab (.mat) contienen información referente a los resultados obtenidos en cada una de las funciones del algoritmo, y el archivo de Excel (.xls) contiene los saltos de columna, los saltos de fila, el tiempo, la disponibilidad y el valor de BW correspondiente a la posición de cada salto.

Finalmente, además de estos archivos, el programa genera cinco figuras que se obtienen a partir de la última función: *figure*. Para las figuras, se crean dos tipos de archivos: el primero, en formato .png, y el segundo es un archivo .fig editable en Matlab.

Tanto las figuras (.png y .fig) como los archivos exportados (.mat y .xls) se guardan en la ruta seleccionada por el usuario (*project name and project location*).

Herramienta de simulación de *handoff* espectral desarrollada

La figura 136 muestra el entorno principal de la herramienta de simulación denominada Collaborative CRN. Este *software* se desarrolló utilizando el entorno App Designer, de Matlab, y está diseñado para permitirle al usuario trabajar bajo un ambiente amigable y parametrizable según las pruebas que se requiera realizar; el *software* está dividido en ocho secciones: 1) *project name and project location*, 2) *collaborative*, 3) *traffic level*, 4) *parameters*, 5) *prediction*, 6) *spectral mobility*, 7) *close and update* y 8) *run*.

Figura 136. Interfaz de usuario del software Collaborative CRN

The screenshot displays the user interface of the Collaborative CRN software. The interface is organized into several sections:

- Top Bar:** Includes 'Help' and 'About' links.
- Project Name and Project Location:** Contains input fields for 'Project Name', 'Load Database' (with a dropdown arrow), and 'Save Folder' (with a browse button '...').
- Collaborative:** A section with a 'Traffic Level' panel containing radio buttons for 'High', 'Medium', and 'Low'. Below it is a 'User' panel with 'User Full' and 'User Simulation' options, each with an input field.
- Parameters:** A panel with a 'Default Parameters' checkbox and input fields for 'Threshold', 'Noise Floor', 'BW Fixed', and 'Multichannels'.
- Prediction:** A panel with tabs for 'Spectral Mobility', 'Markov Chain', 'Genetic Algorithm', 'Naive Bayes', 'Logistic Regression', and 'Time Series'. It includes a 'Time [minutes]' dropdown set to '0', a 'Time Step' panel with 'Channels Numbers' and 'Channel Algorithm Selection' (with a dropdown arrow), and a 'Good Relationship [%]' input field.
- Weights:** A panel with a 'Default Weight' checkbox and four input fields for 'Availability Average', 'Median Availability Time', 'PSNR', and 'Bandwidth Average'.
- Handoff Models:** A panel with a 'Handoff Models' dropdown arrow.
- Buttons:** At the bottom, there are 'Close', 'Update', and 'Run' buttons, along with a circular button.

Fuente: elaboración propia.

Conclusiones

A partir de los resultados encontrados en la investigación, el módulo de caracterización del usuario primario (PU) en función de los datos de entrada, utilizando redes neuronales recurrentes, y que está basado en *deep learning* (como es el caso de LSTM), debe ser considerado como una opción real y válida en la búsqueda de nuevas metodologías que permitan minimizar el error de modelamiento y predicción en la estimación de uso de bandas espectrales por parte de PU, pues con ello se mejora el desempeño de la etapa de decisión espectral en redes inalámbricas de radio cognitiva (CR). Esta apreciación se sustenta al validar los resultados obtenidos con LSTM frente a otras técnicas de redes neuronales, como MLPNN.

Un aspecto relevante de la investigación (contrario a lo planteado en la mayoría de las propuestas del estado del arte) es que el funcionamiento del algoritmo de caracterización LSTM fue probado con fuentes de tráfico reales (GSM y Wi-Fi) y contrastado con las técnicas de aprendizaje MLPNN y Anfis, y se alcanzaron porcentajes en la predicción que oscilan entre el 63,82% y el 97,09%, valores superiores a los entregados por MLPNN (ubicados entre el 51,86% y el 95,59%) y Anfis (que oscilan entre el 55,86% y el 96,30%), lo que prueba que la implementación de LSTM en sistemas inalámbricos reales es prometedora.

La inclusión en el Anfis de funciones de membresía basadas en *grid partition* y *c-means clustering* mejora la capacidad de modelamiento y pronóstico de uso del canal. Los resultados de la simulación permiten afirmar que el sistema propuesto tiene un mayor porcentaje de acierto en la predicción del comportamiento caótico de PU en CR que otros paradigmas como el basado en *deep learning*, llamado LSTM; no obstante, la integración de Anfis-*grid* y Anfis-FCM tiene un costo computacional agregado en tiempo de aprendizaje y en ejecución de la aplicación.

Después de realizar distintas y variadas pruebas sobre SVM (máquinas de soporte vectorial), no se ha podido llegar a un resultado útil con este sistema. La razón por la que SVM no es práctica para caracterizar y predecir PU en CR es que requiere muchos

ejemplos y la predicción que hace es fija, es decir, no tiene en cuenta distribuciones (que es probablemente lo que mejor encaja para describir una CR). No obstante, aunque la predicción sea fija, las SVM usadas permiten extraer las probabilidades de que el ejemplo aplicado sea de la clase 1 o de la clase 0; aun así, los valores obtenidos siempre fueron mayores de 0,995 para una de las dos clases, ya sea emisión o no emisión. Es por ello que SVM-2 (conocida formalmente como LibSVM) es capaz de predecir cómo se va a comportar el PU, pero de un modo equivocado, ya que, si el sistema está emitiendo en los últimos instantes grabados, la SVM detecta como predicción que esa radio estará emitiendo infinitamente. Lo mismo pasa si el estado para predecir está en no emisión: al final del ejemplo, la predicción que ofrece el algoritmo es que el PU estará sin emisión de modo permanente.

Con respecto al módulo de probabilidad de arribo de un usuario secundario (SU), a partir del modelamiento matemático, se demuestra que, para la variable *tiempo de procesamiento en la estación base (BS)*, el tiempo que tarda el sistema reactivo en asignar un canal a un SU es mayor que el requerido por un sistema proactivo, condición que favorece u optimiza el rendimiento en la etapa de toma de decisiones en CR.

Adicionalmente, los resultados muestran que el sistema es más eficiente cuando la MLPNN puede llegar a establecer un patrón en la secuencia histórica; de lo contrario, el porcentaje de acierto en la estimación de la siguiente solicitud por parte de un SU puede ser muy baja para la variable *ancho de banda (BW)*, lo que vuelve inviable su implementación debido a que los canales reservados por la BS podrían no reunir las características que realmente requieran los usuarios cognitivos.

De acuerdo con los resultados alcanzados en el módulo de selección de oportunidades espectrales (SO), se puede concluir que no hay un algoritmo que se desempeñe de forma excelente en todas las métricas de evaluación (ME) y para todos los escenarios de simulación (tipo de red, clase de aplicación y nivel de tráfico). Cada algoritmo se puede desempeñar de forma satisfactoria en determinadas ME y para ciertos escenarios, por lo que una propuesta interesante es el diseño de un módulo adaptativo multivariable de selección espectral que permita cambiar su comportamiento de acuerdo con los requerimientos de la aplicación que se esté desarrollando durante la comunicación del SU. A pesar de lo anterior, el algoritmo que mejor desempeño evidenció en promedio fue FFAHP, seguido por SAW, lo que permite corroborar la importancia de incorporar la realimentación y el aprendizaje en los algoritmos para la selección de espectro.

Con respecto al módulo de colaboración, se pudo evidenciar que el nivel de colaboración entre SU es directamente proporcional al desempeño del algoritmo; sin embargo, la tasa de mejoría no es significativamente alta: de acuerdo con los resultados,

un incremento en el nivel de colaboración entre SU del 1000% (al pasar del 10% al 100%) tan solo logra una mejoría en el desempeño del algoritmo del 10%, aproximadamente. El análisis de los resultados también mostró que el algoritmo con el mejor desempeño en el momento de intercambiar información entre SU es el método del promedio, el cual permite guardar de forma indirecta el histórico de la información anterior.

El modelo de decisión espectral colaborativo propuesto y desarrollado en esta investigación es una herramienta para la toma de decisiones que permite aprovechar efectivamente las SO en redes de radio cognitiva (CRN). Dicho modelo está conformado por cuatro módulos: 1) módulo colaborativo (intercambio de información entre SU); 2) módulo de caracterización del PU; 3) módulo de probabilidad de arribo del SU, y 4) módulo de selección de la SO. La función de cada módulo es realizada por el algoritmo que mejor desempeño evidenció en la correspondiente evaluación de cada módulo. Los algoritmos seleccionados fueron: para el módulo colaborativo, el intercambio de información se dio a través del algoritmo de promedios; para el módulo de caracterización del PU, el algoritmo LSTM; para el módulo de probabilidad de arribo del SU, el algoritmo MLPNN, y para el módulo de selección de canal, el algoritmo FFAHP-SU10. El modelo propuesto selecciona de forma dinámica e inteligente la mejor SO con base en los criterios de decisión (DC): probabilidad de disponibilidad (AP) del canal, tiempo estimado de disponibilidad (ETA) del canal, relación de señal a interferencia más ruido (SINR) y BW, que fueron seleccionados cuidadosamente a través del método Delphi modificado. La validación del desempeño del modelo propuesto se realizó a través de datos reales de ocupación espectral capturados en experimentos realizados en las bandas de frecuencia GSM y Wi-Fi. Sin embargo, la aplicación del algoritmo también se puede extender a otras bandas de frecuencia siempre que se cuente con la información estadística necesaria y suficiente.

Contribuciones de la investigación

- Diseño y desarrollo de un modelo de decisión espectral colaborativo para mejorar el desempeño de las CRN.
- Evaluación y validación de los algoritmos de decisión espectral desarrollados, con datos de ocupación espectral reales capturados en una campaña de medición realizada en la ciudad de Bogotá, Colombia.
- Evaluación y validación de los algoritmos de *handoff* espectral (SH) desarrollados, en dos tipos de redes: GSM y Wi-Fi.

- Evaluación y validación de los algoritmos de SH desarrollados, con dos tipos de enfoque: tiempo real (RT) y mejor esfuerzo (BE), de acuerdo con la clase de aplicación que puede ejecutar el SU.
- Evaluación y validación de los algoritmos de SH desarrollados, con dos niveles de tráfico de PU: alto (HT) y bajo (LT).
- Evaluación y validación de los algoritmos de SH desarrollados, en ocho diferentes escenarios de evaluación: GSM-RT-LT, GSM-RT-HT, GSM-BE-LT, GSM-BE-HT, Wi-Fi-RT-LT, Wi-Fi-RT-HT, Wi-Fi-BE-LT y Wi-Fi-BE-HT.
- Evaluación y validación de los algoritmos de SH desarrollados, bajo cinco EM: AAH, AAFH, ABW, AAD y AAT.
- Determinación de cuatro DC seleccionados cuidadosamente mediante el método Delphi modificado, para elegir la mejor SO; todos los algoritmos desarrollados trabajaron con los mismos cuatro DC, y cada DC fue calculado a partir de los datos de ocupación espectral reales.
- Diseño y desarrollo de Collaborative CRN, una herramienta de simulación novedosa para evaluar el desempeño de algoritmos de decisión espectral híbridos; está basada en los datos de ocupación espectral reales y permite modificar varios parámetros de interés para analizar el comportamiento del desempeño de cada algoritmo bajo diferentes situaciones; entre estos parámetros se destaca el nivel de colaboración entre SU.

Investigación futura

Para un trabajo futuro, se proponen tres directrices: la primera consiste en realizarle una modificación al algoritmo FFAHP para que pueda autoconfigurar los pesos de los DC con base en las estadísticas históricas recientes de estos; la segunda consiste en realizar una evaluación y validación con algoritmos de aprendizaje autónomo más relevantes en la literatura actual, como las SVM (máquinas de soporte vectorial), para realizar procesos de clasificación, y el aprendizaje por refuerzo, para desarrollar la parte de adaptación, y la tercera directriz consiste en realizar una evaluación y validación con equipos de CR que emulen una CRN en lugar de simulaciones, aun con datos de ocupación espectral reales.

Referencias

- 3GPP. (2011). IEEE Approved Draft Standard For Information Technology. Local and metropolitan area networks. Specific requirements. Part 22: Cognitive wireless ran medium access control (MAC) and physical layer (PHY) specifications: Policies and procedures for operation in the TV bands IEEE computer society (vol. 2015). https://standards.ieee.org/standard/802_22-2019.html
- Abass, A. A. A., Mandayam, N. B. y Gajic, Z. (2017). An evolutionary game model for threat revocation in ephemeral networks. En *2017 51st Annual Conference on Information Sciences and Systems* (pp. 1-5). IEEE. <http://doi.org/10.1109/CISS.2017.7926128>
- Abbas, N., Nasser, Y. y Ahmad, K. E. (2015). Recent advances on artificial intelligence and learning techniques in cognitive radio networks. *Eurasip Journal on Wireless Communications and Networking*, (1), 1-20. <http://doi.org/10.1186/s13638-015-0381-7>
- Abdulshahed, A. M., Longstaff, A. P. y Fletcher, S. (2015). The application of Anfis prediction models for thermal error compensation on CNC machine tools. *Applied Soft Computing Journal*, 27, 158-168. <http://doi.org/10.1016/j.asoc.2014.11.012>
- Abonyi, J., Andersen, H., Nagy, L. y Szeifert, F. (1999). Inverse fuzzy-process-model based direct adaptive control. *Mathematics and Computers in Simulation*, 51(1-2), 119-132. [http://doi.org/10.1016/s0378-4754\(99\)00142-1](http://doi.org/10.1016/s0378-4754(99)00142-1)
- Abramson, N. (1981). *Teoría de la información y codificación* (5.^a ed.). Paraninfo. https://eva.udelar.edu.uy/pluginfile.php/84635/mod_resource/content/0/Teoria_de_la_Informacion_y_codificacion-Norman_Abramson_ebook-spanish_.pdf
- Adeel, A., Larijani, H. y Ahmadinia, A. (2014, 13-16 de mayo). *Performance analysis of artificial neural network-based learning schemes for cognitive radio systems in LTE-UL* [presentación en conferencia]. 2014 28th International Conference on

- Advanced Information Networking and Applications, Victoria, Estados Unidos. <http://doi.org/10.1109/WAINA.2014.116>
- Ahmed, A., Boulahia, L. M. y Gaïti, D. (2014). Enabling vertical handover decisions in heterogeneous wireless networks: A state-of-the-art and a classification. *IEEE Communications Surveys & Tutorials*, 16(2), 776-811. <http://doi.org/10.1109/SURV.2013.082713.00141>
- Ahmed, E., Gani, A., Abolfazli, S., Yao, L. J. y Khan, S. U. (2016). Channel assignment algorithms in cognitive radio networks: Taxonomy, open issues, and challenges. *IEEE Communications Surveys & Tutorials*, 18(1), 795-823. <http://doi.org/10.1109/COMST.2014.2363082>
- Akin, S. y Fidler, M. (2016). On the transmission rate strategies in cognitive radios. *IEEE Transactions on Wireless Communications*, 15(3), 2335-2350. <http://doi.org/10.1109/TWC.2015.2503272>
- Akter, L., Natarajan, B. y Scoglio, C. (2008, 3-7 de agosto). *Modeling and forecasting secondary user activity in cognitive radio networks* [presentación en conferencia]. 17th International Conference on Computer Communications and Networks, St. Thomas, Islas Virgenes, Estados Unidos. <http://doi.org/10.1109/ICCCN.2008.ECP.50>
- Akyildiz, I. F., Lee, W.-Y., Vuran, M. C. y Mohanty, S. (2006). NeXt generation/dynamic spectrum access/cognitive radio wireless networks: A survey. *Computer Networks*, 50(13), 2127-2159. <http://doi.org/10.1016/j.comnet.2006.05.001>
- Akyildiz, I. F., Lee, W.-Y., Vuran, M. C. y Mohanty, S. (2008). A survey on spectrum management in cognitive radio networks. *IEEE Communications Magazine*, 46(4), 40-48. <http://doi.org/10.1109/MCOM.2008.4481339>
- Akyildiz, I. F., Lee, W.-Y. y Chowdhury, K. R. (2009). CRAHNs: Cognitive radio ad hoc networks. *Ad Hoc Networks*, 7(5), 810-836. <http://doi.org/10.1016/j.adhoc.2009.01.001>
- Akyildiz, I. F. y Li, Y. (2006). *OCRA: OFDM-based cognitive radio networks. Broad-band and Wireless Networking Laboratory technical report*. Georgia Institute of Technology.
- Al-Amidie, M., Al-Asadi, A., Micheas, A. C. e Islam, N. E. (2019). Spectrum sensing based on Bayesian generalised likelihood ratio for cognitive radio systems with multiple antennas. *IET Communications*, 13(3), 305-311. <http://doi.org/10.1049/iet-com.2018.5276>

- Ali, A. y Hamouda, W. (2017). Advances on spectrum sensing for cognitive radio networks: Theory and applications. *IEEE Communications Surveys & Tutorials*, 19(2), 1277-1304. <http://doi.org/10.1109/COMST.2016.2631080>
- Alias, D. M. y Ragesh, G. K. (2016, 23-25 de marzo). *Cognitive radio networks: A survey* [presentación en conferencia]. 2016 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET), Chennai, India. <http://doi.org/10.1109/WiSPNET.2016.7566489>
- Almasaeid, H. M. y Kamal, A. E. (2010). Receiver-based channel allocation for wireless cognitive radio mesh networks. En *2010 IEEE Symposium on New Frontiers in Dynamic Spectrum* (pp. 1-10). IEEE. <http://doi.org/10.1109/DYSPAN.2010.5457862>
- Alnwaimi, G., Arshad, K. y Moessner, K. (2011). Dynamic spectrum allocation algorithm with interference management in co-existing networks. *IEEE Communications Letters*, 15(9), 932-934. <http://doi.org/10.1109/LCOMM.2011.062911.110248>
- Alsarhan, A. y Agarwal, A. (2009). Cluster-based spectrum management using cognitive radios in wireless mesh network. En *2009 Proceedings of 18th International Conference on Computer Communications and Networks* (pp. 1-6). IEEE. <http://doi.org/10.1109/ICCCN.2009.5235261>
- Amir, M., El-Keyi, A. y Nafie, M. (2011). Constrained interference alignment and the spatial degrees of freedom of mimo cognitive networks. *IEEE Transactions on Information Theory*, 57(5), 2994-3004. <http://doi.org/10.1109/TIT.2011.2119770>
- Amjad, M. F., Chatterjee, M. y Zou, C. C. (2016). Coexistence in heterogeneous spectrum through distributed correlated equilibrium in cognitive radio networks. *Computer Networks*, 98, 109-122. <http://doi.org/10.1016/j.comnet.2016.01.016>
- Azarfar, A., Frigon, J.-F. y Sanso, B. (2012). Improving the reliability of wireless networks using cognitive radios. *IEEE Communications Surveys & Tutorials*, 14(2), second quarter, 338-354. <http://doi.org/10.1109/SURV.2011.021111.00064>
- Baran, P. (1964). On distributed communications networks. *IEEE Transactions on Communications Systems*, 12(1), 1-9. <http://doi.org/10.1109/TCOM.1964.1088883>
- Bhowmik, M. y Malathi, P. (2019). Spectrum sensing in cognitive radio using actor-critic neural network with krill herd-whale optimization algorithm. *Wireless Personal Communications*, 105(1), 335-354. <http://doi.org/10.1007/s11277-018-6115-5>

- Bkassiny, M., Li, Y. y Jayaweera, S. K. (2013). A survey on machine-learning techniques in cognitive radios. *IEEE Communications Surveys & Tutorials*, 15(3), 1136-1159. <http://doi.org/10.1109/SURV.2012.100412.00017>
- Bolstad, W. M. (2007). *Introduction to Bayesian statistics* (2.^a ed.). John Wiley & Sons.
- Brik, V., Rozner, E., Banerjee, S. y Bahl, P. (2005). DSAP: A protocol for coordinated spectrum access. En *2005 1st IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks* (pp. 611-614). IEEE. <http://doi.org/10.1109/DYSPAN.2005.1542680>
- Bujari, A., Calafate, C. T., Cano, J.-C., Manzoni, P., Palazzi, C. E. y Ronzani, D. (2018). Flying ad-hoc network application scenarios and mobility models. *International Journal of Distributed Sensor Networks*, 13(10). <http://doi.org/10.1177/1550147717738192>
- Bütün, I., Talay, A. Ç., Altılar, D. T., Khalid, M. y Sankar, R. (2010, 21-23 de abril). *Impact of mobility prediction on the performance of cognitive radio networks* [presentación en simposio]. 2010 Wireless Telecommunications Symposium (WTS), Tampa, Estados Unidos. <http://doi.org/10.1109/WTS.2010.5479659>
- Büyüközkan, G., Kahraman, C. y Ruan, D. (2004). A fuzzy multi-criteria decision approach for software development strategy selection. *International Journal of General Systems*, 33(2-3), 259-280. <http://doi.org/10.1080/03081070310001633581>
- Büyüközkan, G. y Çifçi, G. (2012). A combined fuzzy AHP and fuzzy Topsis based strategic analysis of electronic service quality in healthcare industry. *Expert Systems with Applications*, 39(3), 2341-2354. <https://doi.org/10.1016/j.eswa.2011.08.061>
- Byun, S. S., Balasingham, I. y Liang, X. (2008, 21-24 de septiembre). *Dynamic spectrum allocation in wireless cognitive sensor networks: Improving fairness and energy efficiency* [presentación en conferencia]. 2008 IEEE 68th Vehicular Technology Conference, Calgary, Canadá. <http://doi.org/10.1109/VETEFC.2008.299>
- Cao, L. y Zheng, H. (2005). Distributed spectrum allocation via local bargaining. En *2005 Second Annual IEEE Communications Society Conference on Sensor and Ad Hoc Communications and Networks* (pp. 475-486). IEEE. <http://doi.org/10.1109/SAHCN.2005.1557100>
- Cardenas-Juarez, M., Díaz-Ibarra, M. A., Pineda-Rico, U., Arce, A. y Stevens-Navarro, E. (2016). On spectrum occupancy measurements at 2.4 GHz ISM band for cognitive radio applications. En *2016 International Conference on Electronics*,

- Communications and Computers* (pp. 25-31). IEEE. <http://doi.org/10.1109/CO-NIELECOMP.2016.7438547>
- Chang, C.-C. y Lin, C.-J. (2013). Libsvm: A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2(3), artículo 27. <http://doi.org/10.1145/1961189.1961199>
- Chang, D.-Y. (1996). Applications of the extent analysis method on fuzzy AHP. *European Journal of Operational Research*, 95(3), 649-655. [http://doi.org/10.1016/0377-2217\(95\)00300-2](http://doi.org/10.1016/0377-2217(95)00300-2)
- Chen, D., Zhang, Q. y Jia, W. (2008, 15-17 de mayo). *Aggregation aware spectrum assignment in cognitive ad-hoc networks* [presentación en conferencia]. 2008 3rd International Conference on Cognitive Radio Oriented Wireless Networks and Communications, Singapur, Singapur. <http://doi.org/10.1109/CROWN-COM.2008.4562548>
- Chen, T., Zhang, H., Maggio, G. M. y Chlamtac, I. (2007). CogMesh: A cluster-based cognitive radio network. En *2007 2nd IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks* (pp. 168-178). IEEE. <http://doi.org/10.1109/DYSPAN.2007.29>
- Chen, Y. y Oh, H.-S. (2016). A survey of measurement-based spectrum occupancy modeling for cognitive radios. *IEEE Communications Surveys & Tutorials*, 18(1), 848-859. <http://doi.org/10.1109/COMST.2014.2364316>
- Cheng, X. y Jiang, M. (2011). Cognitive radio spectrum assignment based on artificial bee colony algorithm. En *2011 IEEE 13th International Conference on Communication Technology* (pp. 161-164). IEEE. <http://doi.org/10.1109/ICCT.2011.6157854>
- Cho, J. y Lee, J. (2013). Development of a new technology product evaluation model for assessing commercialization opportunities using Delphi method and fuzzy AHP approach. *Expert Systems with Applications*, 40(13), 5314-5330. <https://doi.org/10.1016/j.eswa.2013.03.038>
- Chou, C.-T., Shankar, S., Kim, H. y Shin, K. G. (2007). What and how much to gain by spectrum agility? *IEEE Journal on Selected Areas in Communications*, 25(3), 576-588. <http://doi.org/10.1109/JSAC.2007.070408>
- Choudhary, D. y Shankar, R. (2012). An Steep-fuzzy AHP-Topsis framework for evaluation and selection of thermal power plant location: A case study from India. *Energy*, 42(1), 510-521. <https://doi.org/10.1016/j.energy.2012.03.010>

- Christian, I., Moh, S., Chung, I. y Lee, J. (2012). Spectrum mobility in cognitive radio networks. *IEEE Communications Magazine*, 50(6), 114-121. <http://doi.org/10.1109/MCOM.2012.6211495>
- Cisco. (2017). *Cisco Visual Networking Index: Global Mobile Data Traffic Forecast Update, 2016-2021 [white paper]*. https://www.ramonmillan.com/documentos/bibliografia/VisualNetworkingIndexGlobalMobileDataTrafficForecastUpdate2016_Cisco.pdf
- Cortés, J. (2011). *Metodología para la implementación de tecnologías de la información y las comunicaciones TIC's para soportar una estrategia de cadena de suministro esbelta* [tesis de maestría, Universidad Nacional de Colombia]. BDigital.
- Cruz-Pol, S., Van Zee, L., Kassim, N., Blackwell, W., Le Vine, D. y Scott, A. (2018). Spectrum management and the impact of RFI on science sensors. En *15th Specialist Meeting on Microwave Radiometry and Remote Sensing of the Environment* (pp. 52-56). IEEE. <http://doi.org/10.1109/MICRORAD.2018.843072>
- Csurgai-Horváth, L. y Bitó, J. (2011). Primary and secondary user activity models for cognitive wireless network. En *Proceedings of the 11th International Conference on Telecommunications* (pp. 189-194). IEEE. <https://ieeexplore.ieee.org/document/5969948>
- Dadallage, S., Yi, C. y Cai, J. (2016). Joint beamforming, power and channel allocation in multi-user and multi-channel underlay MISO cognitive radio networks. *IEEE Transactions on Vehicular Technology*, 65(5), 3349-3359. <http://doi.org/10.1109/TVT.2015.2440412>
- Dadios, E. P. (ed.). (2012). *Fuzzy logic: Algorithms, techniques and implementations*. In-techOpen.
- Darak, S. J., Dhabu, S., Moy, C., Zhang, H., Palicot, J. y Vinod, A. P. (2015). Low complexity and efficient dynamic spectrum learning and tunable bandwidth access for heterogeneous decentralized cognitive radio networks. *Digital Signal Processing*, 37(1), 13-23. <http://doi.org/10.1016/j.dsp.2014.12.001>
- Darak, S. J., Zhang, H., Palicot, J. y Moy, C. (2014). Efficient decentralized dynamic spectrum learning and access policy for multi-standard multi-user cognitive radio networks. En *2014 11th International Symposium on Wireless Communications Systems (ISWCS)* (pp. 271-275). Institute of Electrical and Electronics Engineers. <http://doi.org/10.1109/ISWCS.2014.693336>
- Darak, S. J., Zhang, H., Palicot, J. y Moy, C. (2017). Decision making policy for RF energy harvesting enabled cognitive radios in decentralized wireless networks. *Digital Signal Processing*, 60, 33-45. <http://doi.org/10.1016/j.dsp.2016.08.014>

- Del Ser, J., Matinmikko, M., Gil-Lopez, S. y Mustonen, M. (2010). A novel harmony search based spectrum allocation technique for cognitive radio networks. En *2007 7th International Symposium on Wireless Communication Systems* (pp. 233-237). IEEE. <http://doi.org/10.1109/ISWCS.2010.5624341>
- Delgado, M. y Rodríguez, B. (2016). Opportunities for a more efficient use of the spectrum based in cognitive radio. *IEEE Latin America Transactions*, 14(2), 610-616. <http://doi.org/10.1109/TLA.2016.743720>
- Deng, H., Huang, L., Yang, C. y Xu, H. (2018). Centralized spectrum leasing via cooperative SU assignment in cognitive radio networks. *International Journal of Communication Systems*, 31(13), artículo e3726. <http://doi.org/10.1002/dac.3726>
- Dhamodharavadhani, S. (2015). A survey on clustering based routing protocols in mobile ad hoc networks. En *2015 International Conference on Soft-Computing and Networks Security (ICSNS)* (pp. 1-6). IEEE. <http://doi.org/10.1109/ICSNS.2015.7292426>
- Ding, L., Melodia, T., Batalama, S. N., Matyjas, J. D. y Medley, M. J. (2010). Cross-layer routing and dynamic spectrum allocation in cognitive radio ad hoc networks. *IEEE Transactions on Vehicular Technology*, 59(4), 1969-1979. <http://doi.org/10.1109/TVT.2010.2045403>
- Do, C. T., Tran, N. H., Hong, C. S., Lee, S., Lee, J.-J. y Lee, W. (2013). A lightweight algorithm for probability-based spectrum decision scheme in multiple channels cognitive radio networks. *IEEE Communications Letters*, 17(3), 509-512. <http://doi.org/10.1109/LCOMM.2013.012313.122589>
- Du, K.-L. y Swamy, M. N. S. (2013). *Neural networks and statistical learning*. Springer.
- Duan, J. y Li, Y. (2011). An optimal spectrum handoff scheme for cognitive radio mobile ad hoc networks. *Advances in Electrical and Computer Engineering*, 11(3), 11-16. <http://doi.org/10.4316/aece.2011.03002>
- Dunn, J. C. (1973). A fuzzy relative of the Isodata process and its use in detecting compact well-separated clusters. *Journal of Cybernetics*, 3(3), 32-57. <http://doi.org/10.1080/01969727308546046>
- Fauzi bin Othman, M. y Yau, T. M. S. (2007). Neuro fuzzy classification and detection technique for bioinformatics problems. En *First Asia International Conference on Modelling and Simulation: Asia Modelling Symposium (AMS 2007)* (pp. 375-380). IEEE. <http://doi.org/10.1109/AMS.2007.7>
- Federal Communications Commission (FCC). (2003a). Facilitating Opportunities for Flexible, Efficient, and Reliable Spectrum Use Employing Cognitive Radio

- Technologies. <https://www.fcc.gov/document/facilitating-opportunities-flexible-efficient-and-reliable-spectrum-1>
- Federal Communications Commission (FCC). (2003b). *Notice of proposed rulemaking and order*. <https://web.cs.ucdavis.edu/~liu/289I/Material/FCC-03-322A1.pdf>
- Ferber, J. (1999). *Multi-agent systems: An introduction to distributed artificial intelligence*. Addison-Wesley.
- Flórez-López, R. y Fernández Fernández, J. M. (2008). *Las redes neuronales artificiales: fundamentos teóricos y aplicaciones prácticas*. Netbiblo.
- Forero, F. (2012). *Detección de códigos de usuarios primarios para redes de radio cognitiva en un canal de acceso CDMA* [tesis de maestría, Universidad Distrital Francisco José de Caldas].
- Fraser, A. M. (2008). *Hidden Markov models and dynamical systems*. SIAM.
- Fudenberg, D. y Tirole, J. (1991). *Game theory*. MIT Press. <https://books.google.com.co/books?id=pFPHKwXro3QC>
- Gallardo-Medina, J. R., Pineda-Rico, U. y Stevens-Navarro, E. (2009). Vikor method for vertical handoff decision in beyond 3G wireless networks. En *2009 6th International Conference on Electrical Engineering, Computing Science and Automatic Control (CCE)*. IEEE. <http://doi.org/10.1109/ICEEE.2009.539332>
- Gavrilovska, L., Atanasovski, V., Macaluso, I. y Dasilva, L. A. (2013). Learning and reasoning in cognitive radio networks. *IEEE Communications Surveys & Tutorials*, 15(4), 1761-1777. <http://doi.org/10.1109/SURV.2013.030713.00113>
- Gers, F. A. y Schmidhuber, E. (2001). LSTM recurrent networks learn simple context-free and context-sensitive languages. *IEEE Transactions on Neural Networks*, 12(6), 1333-1340. <http://doi.org/10.1109/72.963769>
- Giupponi, L. y Pérez-Neira, A. I. (2008). Fuzzy-based spectrum handoff in cognitive radio networks. En *Proceedings of the Third International Conference on Cognitive Radio Oriented Wireless Networks and Communications*. IEEE. <http://doi.org/10.1109/CROWNCOM.2008.4562535>
- Goldberg, D. E. y Holland, J. H. (1988). Genetic algorithms and machine learning. *Machine Learning*, 3(2), 95-99. <http://doi.org/10.1023/A:1022602019183>
- Goswami, M. M. (2017). AODV based adaptive distributed hybrid multipath routing for mobile AdHoc network. En *2017 International Conference on Inventive Communication and Computational Technologies* (pp. 410-414). IEEE. <http://doi.org/10.1109/ICICCT.2017.797523>

- Graves, A. (2012). *Supervised sequence labelling with recurrent neural networks*. Springer. <http://doi.org/10.1007/978-3-642-24797-2>
- Graves, A., Mohamed, A.-R. y Hinton, G. (2013). Speech recognition with deep recurrent neural networks. En *2013 IEEE International Conference on Acoustics, Speech and Signal Processing. Proceedings* (pp. 6645-6649). IEEE. <http://doi.org/10.1109/ICASSP.2013.6638947>
- Graves, A. y Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural Networks*, 18(5-6), 602-610. <http://doi.org/10.1016/j.neunet.2005.06.042>
- Green, K. C., Armstrong, J. S. y Graefe, A. (2007). Methods to elicit forecasts from groups: Delphi and prediction markets compared. *SSRN Electronic Journal*, 8, 17-20. <http://doi.org/10.2139/ssrn.1153124>
- Han, J., Kamber, M. y Pei, J. (2012). *Data mining: Concepts and techniques*. Elsevier y Morgan Kauffman.
- Hasegawa, M., Hirai, H., Nagano, K., Harada, H. y Aihara, K. (2014). Optimization for centralized and decentralized cognitive radio networks. *Proceedings of the IEEE*, 102(4), 574-584. <http://doi.org/10.1109/JPROC.2014.2306255>
- Haykin, S. (1998). *Neural networks: A comprehensive foundation* (2.^a ed.). Prentice Hall.
- He, A., Bae, K. K., Newman, T. R., Gaeddert, J., Kim, K., Menon, R., Morales-Tirado, L., Neel, J., Zhao, Y., Reed, J. H. y Tranter, W. H. (2010). A survey of artificial intelligence for cognitive radios. *IEEE Transactions on Vehicular Technology*, 59(4), 1578-1592. <http://doi.org/10.1109/TVT.2010.2043968>
- Hernández, C., Giral, D. y Páez, I. (2015a). Benchmarking of the performance of spectrum mobility models in cognitive radio networks. *International Journal of Applied Engineering Research*, 10(21), 42.189-42.196.
- Hernández, C., Giral, D. y Páez, I. (2015b). Hybrid algorithm for frequency channel selection in Wi-Fi networks. *World Academy of Science, Engineering and Technology*, 9(12), 1212-1215. <https://publications.waset.org/10002921/hybrid-algorithm-for-frequency-channel-selection-in-wi-fi-networks>
- Hernández, C., Giral, D. y Santa, F. (2015). MCDM spectrum handover models for cognitive wireless networks. *World Academy of Science, Engineering and Technology*, 9(10), 679-682. <https://publications.waset.org/10002749/mcdm-spectrum-handover-models-for-cognitive-wireless-networks>
- Hernández, C., Márquez, H. y Giral, D. (2017). Comparative evaluation of prediction models for forecasting spectral opportunities. *International Journal of En-*

- gineering and Technology*, 9(5), 3775-3782. <http://doi.org/10.21817/ijet/2017/v9i5/170905055>
- Hernández, C., Páez, I. y Giral, D. (2015). Modelo AHP-Vikor para *handoff* espectral en redes de radio cognitiva. *Tecnura*, 19(45), 29-39. <http://dx.doi.org/10.14483/udistrital.jour.tecnura.2015.3.a02>
- Hernández, C., Páez, I. y Giral, D. (2017). *Modelo adaptativo multivariable de handoff espectral para incrementar el desempeño en redes móviles de radio cognitiva*. Editorial UD.
- Hernández, C., Pedraza, L. F., Páez, I. y Rodríguez-Colina, E. (2015). Análisis de la movilidad espectral en redes de radio cognitiva. *Información Tecnológica*, 26(6), 169-186. <http://dx.doi.org/10.4067/S0718-07642015000600018>
- Hernández, C., Pedraza, L. F. y Martínez, F. H. (2016). Algoritmos para asignación de espectro en redes de radio cognitiva. *Tecnura*, 20(48), 69-88. http://www.scielo.org.co/scielo.php?pid=S0123-921X2016000200006&script=sci_abstract&tlng=es
- Hernández, C., Pedraza, L. F. y Rodríguez-Colina, E. (2016). Fuzzy feedback algorithm for the spectral handoff in cognitive radio networks. *Revista Facultad de Ingeniería de la Universidad de Antioquia*, (81), 47-62. <http://doi.org/10.17533/udea.redin.n81a05>
- Hernández, C., Salcedo, O. y Pedraza, L. F. (2009). An Arima model for forecasting Wi-Fi data network traffic values. *Ingeniería e Investigación*, 29(2), 65-69. http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0120-5609200900020001
- Hernández, C., Salgado, C., López, H. y Rodríguez-Colina, E. (2015). Multivariable algorithm for dynamic channel selection in cognitive radio networks. *Eurasip Journal on Wireless Communications and Networking*, 2015(1), artículo 216. <http://doi.org/10.1186/s13638-015-0445-8>
- Hernández, C., Salgado, C. y Salcedo, O. (2013). Performance of multivariable traffic model that allows estimating throughput mean values. *Revista Facultad de Ingeniería de la Universidad de Antioquia*, (67), 52-62. http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0120-62302013000200005
- Hernández Sampieri, R., Fernández-Collado, C. y Baptista Lucio, P. (2006). *Metodología de la investigación* (4.ª ed.). McGraw-Hill.
- Hernandez-Guillen, J., Rodríguez-Colina, E., Marcelín-Jiménez, R. y Pascoe Chalke, M. (2012). Cruam-MAC: A novel cognitive radio MAC protocol for dynamic spectrum access. En *2012 IEEE Latin-American Conference on Communications*. IEEE. <http://doi.org/10.1109/LATINCOM.2012.6505997>

- Hochreiter, S. y Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780. <http://doi.org/10.1162/neco.1997.9.8.1735>
- Hoven, N., Tandra, R. y Sahai, A. (2005). *Some fundamental limits on cognitive radio*. Wireless Foundations EECS. https://omidi.iut.ac.ir/SDR/2008/Projects/Ataei-Game_Theory_Cognitive%20Radios/References/Some%20Fundamental%20Limits%20on%20Cognitive%20Radio.pdf
- Hsieh, W. W. (2009). *Machine learning methods in the environmental sciences: Neural networks and kernels*. Cambridge University Press.
- Hübner, R. (2007). *Strategic supply chain management in process industries: An application to specialty chemicals production network design* (vol. 594). Springer.
- Iftikhar, A., Rauf, Z., Ahmed Khan, F., Shoaib Ali, M. y Kakar, M. (2019). Bayesian game-based user behavior analysis for spectrum mobility in cognitive radios. *Physical Communication*, 32, 200-208. <https://doi.org/10.1016/j.phycom.2018.12.002>
- Institute of Electrical and Electronics Engineers. (2008). *IEEE standard definitions and concepts for dynamic spectrum access: Terminology relating to emerging wireless networks, system functionality, and spectrum management* (IEEE Standard 1900.1-2008). https://standards.ieee.org/standard/1900_1-2008.html
- Issariyakul, T., Pillutla, L. S. y Krishnamurthy, V. (2009). Tuning radio resource in an overlay cognitive radio network for TCP: Greed isn't good. *IEEE Communications Magazine*, 47(7), 57-63. <http://doi.org/10.1109/MCOM.2009.5183473>
- Jain, A. K. (2010). Data clustering: 50 years beyond K-means. *Pattern Recognition Letters*, 31(8), 651-666. <http://doi.org/10.1016/j.patrec.2009.09.011>
- Jang, J.-S. R. (1993). Anfis: Adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3), 665-685. <http://doi.org/10.1109/21.256541>
- Jayaweera, S. y Christodoulou, C. (2011). *Radiobots: Architecture, algorithms and real-time reconfigurable antenna designs for autonomous, self-learning future cognitive radios*. https://digitalrepository.unm.edu/ece_rpts/36/
- Ji, Z. y Liu, K. J. R. (2007). Cognitive radios for dynamic spectrum access. Dynamic spectrum sharing: A game theoretical overview. *IEEE Communications Magazine*, 45(5), 88-94. <http://doi.org/10.1109/MCOM.2007.358854>
- Jiang, C., Chen, Y. y Liu, K. J. R. (2014). Multi-channel sensing and access game: Bayesian social learning with negative network externality. *IEEE Transactions on Wireless Communications*, 13(4), 2176-2188. <http://doi.org/10.1109/TWC.2014.022014.131209>

- Joda, R. y Zorzi, M. (2015). Decentralized heuristic access policy design for two cognitive secondary users under a primary Type-I HARQ process. *IEEE Transactions on Communications*, 63(11), 4037-4049. <http://doi.org/10.1109/TCOMM.2015.2480846>
- Kalkan, S. (2018). *Special topics in deep learning*. <http://kovan.ceng.metu.edu.tr/~sinan/DL/>
- Kanodia, V., Sabharwal, A. y Knightly, E. (2004). MOAR: A multi-channel opportunistic auto-rate media access protocol for ad hoc networks. En *First International Conference on Broadband Networks* (pp. 600-610). IEEE. <https://ieeexplore.ieee.org/document/1363848?section=abstract>
- Kasbekar, G. S. y Sarkar, S. (2010). Spectrum auction framework for access allocation in cognitive radio networks. *IEEE/ACM Transactions on Networking*, 18(6), 1841-1854. <http://doi.org/10.1109/TNET.2010.2051453>
- Kaur, A., Kaur, A. y Sharma, S. (2018). PSO based multiobjective optimization for parameter adaptation in CR based IoTs. En *2018 4th International Conference on Computational Intelligence & Communication Technology (CICIT)*. IEEE. <http://doi.org/10.1109/CIACT.2018.8480298>
- Kaya, T. y Kahraman, C. (2010). Multicriteria renewable energy planning using an integrated fuzzy Vikor & AHP methodology: The case of Istanbul. *Energy*, 35(6), 2517-2527. <https://doi.org/10.1016/j.energy.2010.02.051>
- Keller, J. M., Liu, D. y Fogel, D. B. (2016). *Fundamentals of computational intelligence: Neural networks, fuzzy systems, and evolutionary computation*. IEEE y Wiley. <http://doi.org/10.1002/9781119214403>
- Kennedy, E. P., Condon, M. y Dowling, J. (2003). Torque-ripple minimisation in switched reluctance motors using a neuro-fuzzy control strategy. En *Proceedings of the Iasted International Conference on Modelling and Simulation* (pp. 106-109). Iasted.
- Kibria, M. R., Jamalipour, A. y Mirchandani, V. (2005). A location aware three-step vertical handoff scheme for 4G/B3G networks. En *Globecom '05. IEEE Global Telecommunications Conference* (vol. 5, pp. 2752-2756). IEEE. <http://doi.org/10.1109/GLOCOM.2005.157826>
- Kim, H. y Shin, K. G. (2008). Efficient discovery of spectrum opportunities with MAC-layer sensing in cognitive radio networks. *IEEE Transactions on Mobile Computing*, 7(5), 533-545. <http://doi.org/10.1109/TMC.2007.70751>
- Kim, W., Kassler, A. J., Di Felice, M. y Gerla, M. (2010). Urban-X: Towards distributed channel assignment in cognitive multi-radio mesh networks. En *2010 IFIP wireless days*. IEEE. <http://doi.org/10.1109/WD.2010.5657733>

- Kondareddy, Y. R., Agrawal, P. y Sivalingam, K. (2008). Cognitive radio network setup without a common control channel. En *2008 IEEE Military Communications Conference*. IEEE. <http://doi.org/10.1109/MILCOM.2008.4753398>
- Kongsiriwattana, W. y Gardner-Stephen, P. (2017). Eliminating the high stand-by energy consumption of ad-hoc Wi-Fi. En *2017 IEEE Global Humanitarian Technology Conference*. IEEE. <http://doi.org/10.1109/GHTC.2017.8239229>
- Krishnamurthy, S., Thoppian, M., Venkatesan, S. y Prakash, R. (2005). Control channel based MAC-layer configuration, routing and situation awareness for cognitive radio networks. En *2005 IEEE Military Communications Conference* (vol. 1, pp. 455-460). IEEE. <http://doi.org/10.1109/MILCOM.2005.1605725>
- Krogstad, H. E. (2012). *TMA 4180. Optimizingsteori karush-kuhn-tucker theorem*. <https://folk.ntnu.no/hek/Optimering2012/kkttheoremv2012.pdf>
- Kumar, K., Prakash, A. y Tripathi, R. (2016). Spectrum handoff in cognitive radio networks: A classification and comprehensive survey. *Journal of Network and Computer Applications*, 61, 161-188. <http://doi.org/10.1016/j.jnca.2015.10.008>
- Kwok, T.-Y. y Yeung, D.-Y. (1997). Constructive algorithms for structure learning in feedforward neural networks for regression problems. *IEEE Transactions on Neural Networks*, 8(3), 630-645. <http://doi.org/10.1109/72.572102>
- Lahby, M., Leghris, C. y Abdellah, A. (2011). A hybrid approach for network selection in heterogeneous multi-access environments. En *2011 4th IFIP International Conference on New Technologies, Mobility and Security*. IEEE. <http://doi.org/10.1109/NTMS.2011.5720658>
- Lee, W.-Y. y Akyildiz, I. F. (2008). Optimal spectrum sensing framework for cognitive radio networks. *IEEE Transactions on Wireless Communications*, 7(10), 3845-3857. <http://doi.org/10.1109/T-WC.2008.070391>
- Lee, W.-Y. y Akyildiz, I. F. (2011). A spectrum decision framework for cognitive radio networks. *IEEE Transactions on Mobile Computing*, 10(2), 161-174. <http://doi.org/10.1109/TMC.2010.147>
- Lertsinsrubeetavee, A. y Malouch, N. (2016). Hybrid spectrum sharing through adaptive spectrum handoff and selection. *IEEE Transactions on Mobile Computing*, 15(11), 2781-2793. <http://doi.org/10.1109/TMC.2016.2517619>
- Li, X. y Zekavat, S. A. (2008). Traffic pattern prediction and performance investigation for cognitive radio systems. En *IEEE Wireless Communications and Networking Conference* (pp. 894-899). IEEE. <http://doi.org/10.1109/WCNC.2008.163>

- Li, Y., Shen, H. y Wang, M. (2016). Optimization spectrum decision parameters in CR using autonomously search algorithm. En *2016 IEEE 13th International Conference on Signal Processing* (pp. 1146-1151). IEEE. <http://doi.org/10.1109/ICSP.2016.7878007>
- Liu, Y. y Tewfik, A. (2014). Primary traffic characterization and secondary transmissions. *IEEE Transactions on Wireless Communications*, 13(6), 3003-3016. <http://doi.org/10.1109/TWC.2014.042914.130861>
- López Sarmiento, D. A. (2017). *Implementación de un modelo predictor para la toma de decisiones en redes inalámbricas de radio cognitiva* [tesis doctoral, Universidad Distrital Francisco José de Caldas]. Repositorio de tesis doctoral del Doctorado en Ingeniería de la Universidad Distrital Francisco José de Caldas. <https://doctoradoingenieria.udistrital.edu.co/index.php/es/inicio/documentos/repositorio-de-tesis-doctoral/item/488-implementacion-de-un-modelo-predictor-para-la-toma-de-decisiones-en-redes-inalambricas-de-radio-cognitiva>
- López Sarmiento, D. A., Rivas, E. y Gualdrón, O. E. (2015). Elementos fundamentales que componen la radio cognitiva y asignación de bandas espectrales. *Información Tecnológica*, 26(1), 23-40. <http://dx.doi.org/10.4067/S0718-07642015000100004>
- Ma, L., Shen, C.-C. y Ryu, B. (2007). Single-radio adaptive channel algorithm for spectrum agile wireless ad hoc networks. En *2007 2nd IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks* (pp. 547-558). IEEE. <http://doi.org/10.1109/DYSPAN.2007.78>
- Marinho, J. y Monteiro, E. (2012). Cognitive radio: Survey on communication protocols, spectrum decision issues, and future research directions. *Wireless Networks*, 18(2), 147-164. <http://doi.org/10.1007/s11276-011-0392-1>
- Márquez, H., Hernández, C. y Giral, D. (2017). Channel availability prediction in cognitive radio networks using naive Bayes. *Contemporary Engineering Sciences*, 10(12), 593-605. <http://doi.org/10.12988/ces.2017.7758>
- Masonta, M. T., Mzyece, M. y Ntlatlapa, N. (2013). Spectrum decision in cognitive radio networks: A survey. *IEEE Communications Surveys & Tutorials*, 15(3), 1088-1107. <http://doi.org/10.1109/SURV.2012.111412.0016>
- Masters, T. (1993). *Practical neural networks recipes in C++*. Morgan Kaufmann.
- Matinmikko, M., Del Ser, J., Rauma, T. y Mustonen, M. (2013). Fuzzy-logic based framework for spectrum availability assessment in cognitive radio systems.

- IEEE Journal on Selected Areas in Communications*, 31(11), 2173-2184. <http://doi.org/10.1109/JSAC.2013.131117>
- Matinmikko, M., Höyhty, M., Mustonen, M., Sarvanko, H., Hekkala, A., Katz, M., Mämmelä, A., Kiviranta, M. y Kautio, A. (2008). *Cognitive radio: An intelligent wireless communication system*. VTT Technical Research Centre of Finland.
- Meerschaert, M. M. (2013). *Mathematical modeling* (4.^a ed.). Elsevier. <http://doi.org/https://doi.org/10.1016/C2010-0-66940-9>
- Mehbodniya, A., Kaleem, F., Yen, K. K. y Adachi, F. (2012). A fuzzy MADM ranking approach for vertical mobility in next generation hybrid networks. En *IV International Congress on Ultra Modern Telecommunications and Control Systems 2012* (pp. 262-267). IEEE. <http://doi.org/10.1109/ICUMT.2012.6459676>
- Melián-Gutiérrez, L., Zazo, S., Blanco-Murillo, J. L., Pérez-Álvarez, I., García-Rodríguez, A. y Pérez-Díaz, B. (2013). HF spectrum activity prediction model based on HMM for cognitive radio applications. *Physical Communication*, 9, 199-211. <http://doi.org/10.1016/j.phycom.2012.09.004>
- Mir, U., Merghem-Boulahia, L., Esseghir, M. y Gaïti, D. (2011). Dynamic spectrum sharing for cognitive radio networks using multiagent system. En *2011 IEEE Consumer Communications and Networking Conference* (pp. 658-663). IEEE. <http://doi.org/10.1109/CCNC.2011.5766563>
- Miranda, E. (2001). Improving subjective estimates using paired comparisons. *IEEE Software*, 18(1), 87-91. <http://doi.org/10.1109/52.903173>
- Mishra, V., Tong, L. C., Chan, S. y Kumar, A. (2012). Energy aware spectrum decision framework for cognitive radio networks. En *2012 International Symposium on Electronic System Design (ISED 2012)* (pp. 309-313). IEEE. <http://doi.org/10.1109/ISED.2012.65>
- Mitola III, J. (2000). *Cognitive radio: An integrated agent architecture for software defined radio* [tesis de doctorado, Royal Institute of Technology]. <http://www.diva-portal.org/smash/get/diva2:8730/FULLTEXT01.pdf>
- Neshat, M., Adeli, A., Masoumi, A. y Sargozae, M. (2011). A comparative study on Anfis and fuzzy expert system models for concrete mix design. *International Journal of Computer Science Issues*, 8(3), 196-210. https://www.researchgate.net/publication/260979471_Comparative_Study_on_Anfis_and_Fuzzy_Expert_System_Models_for_Concrete_Mix_Design
- Nisan, N., Roughgarden, T., Tardos, É. y Vazirani, V. V. (2007). *Algorithmic game theory* (vol. 1). Cambridge University Press.

- Ormond, O., Murphy, J. y Muntean, G.-M. (2006). Utility-based intelligent network selection in beyond 3G systems. En *2006 IEEE International Conference on Communications* (vol. 4, pp. 1831-1836). IEEE. <http://doi.org/10.1109/ICC.2006.254986>
- Oyewobi, S. S. y Hancke, G. P. (2017). A survey of cognitive radio handoff schemes, challenges and issues for industrial wireless sensor networks (CR-IWSN). *Journal of Network and Computer Applications*, 97, 140-156. <http://doi.org/https://doi.org/10.1016/j.jnca.2017.08.016>
- Ozger, M. y Akan, O. B. (2016). On the utilization of spectrum opportunity in cognitive radio networks. *IEEE Communications Letters*, 20(1), 157-160. <http://doi.org/10.1109/LCOMM.2015.2504103>
- Palangi, H., Ward, R. y Deng, L. (2016). Distributed compressive sensing: A deep learning approach. *IEEE Transactions on Signal Processing*, 64(17), 4504-4518. <http://doi.org/10.1109/TSP.2016.2557301>
- Pankratev, D. A., Samsonov, A. A. y Stotckaia, A. D. (2019). Wireless data transfer technologies in a decentralized system. En *Proceedings of the 2019 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus)* (pp. 620-623). IEEE. <http://doi.org/10.1109/EIConRus.2019.8656671>
- Patil, S. K. y Kant, R. (2014). A fuzzy AHP-Topsis framework for ranking the solutions of Knowledge Management adoption in Supply Chain to overcome its barriers. *Expert Systems with Applications*, 41(2), 679-693. <http://doi.org/10.1016/j.eswa.2013.07.093>
- Pattanayak, S., Venkateswaran, P. y Nandi, R. (2013). Artificial intelligence based model for channel status prediction: A new spectrum sensing technique for cognitive radio. *International Journal of Communications, Network and System Sciences*, 6(3), 139-148. <http://doi.org/10.4236/ijcns.2013.63017>
- Pedraza, L. F., Forero, F. y Páez, I. (2014). Evaluación de ocupación del espectro radioeléctrico en Bogotá-Colombia. *Ingeniería y Ciencia*, 10(19), 127-143. <http://www.scielo.org.co/pdf/ince/v10n19/v10n19a07.pdf>
- Pedraza, L. F., Hernández, C., Galeano, K., Rodríguez-Colina, E. y Páez, I. (2016). *Ocupación espectral y modelo de radio cognitiva para Bogotá* (1.ª ed.). Editorial UD.
- Petrova, M., Mähönen, P. y Osuna, A. (2010). Multi-class classification of analog and digital signals in cognitive radios using support vector machines. En *2017th International Symposium on Wireless Communication Systems* (pp. 986-990). IEEE. <http://doi.org/10.1109/ISWCS.2010.562450>

- Petter. (2013). *Matlab mex support for Visual Studio 2013*. MathWorks. <https://www.mathworks.com/matlabcentral/fileexchange/44408-matlab-mex-support-for-visual-studio-2013-and-mbuild>
- Pham, C., Tran, N. H., Do, C. T., Moon, S. I. y Hong, C. S. (2014). Spectrum handoff model based on hidden Markov model in cognitive radio networks. En *International Conference on Information Networking* (pp. 406-411). IEEE. <http://networking.khu.ac.kr/layouts/net/publications/data/Spectrum%20Handoff%20Model%20Based%20on%20Hidden%20Markov%20Model%20in%20Cognitive%20Radio%20Networks.pdf>
- Pinto, L. R. M. y Correia, L. H. A. (2018). Analysis of machine learning algorithms for spectrum decision in cognitive radios. En *2018 15th International Symposium on Wireless Communication Systems (ISWCS)* (pp. 1-6). IEEE. <http://doi.org/10.1109/ISWCS.2018.849106>
- Pla, V., Vidal, J.-R., Martinez-Bauset, J. y Guijarro, L. (2010). Modeling and characterization of spectrum white spaces for underlay cognitive radio networks. En *2010 IEEE International Conference on Communications*. IEEE. <http://doi.org/10.1109/ICC.2010.5501788>
- Powell, V. y Lehe, L. (s.f.). Principal component analysis explained visually. <https://setosa.io/ev/principal-component-analysis/>
- Rahimian, N., Georghiades, C. N., Shakir, M. Z. y Qaraqe, K. A. (2014). On the probabilistic model for primary and secondary user activity for OFDMA-based cognitive radio systems: Spectrum occupancy and system throughput perspectives. *IEEE Transactions on Wireless Communications*, 13(1), 356-369. <http://doi.org/10.1109/TWC.2013.120213.130658>
- Ramírez Pérez, C. y Ramos Ramos, V.-M. (2010). Handover vertical: un problema de toma de decisión múltiple. En *Congreso Internacional sobre Innovación y Desarrollo Tecnológico (Ciindet)* (pp. 727-733).
- Ramírez Pérez, C. y Ramos Ramos, V.-M. (2013). On the effectiveness of multi-criteria decision mechanisms for vertical handoff. En *IEEE 27th International Conference on Advanced Information Networking and Applications* (pp. 1157-1164). IEEE. <http://doi.org/10.1109/AINA.2013.114>
- Ramzan, M. R., Nawaz, N., Ahmed, A., Naeem, M., Iqbal, M. y Anpalagan, A. (2017). Multi-objective optimization for spectrum sharing in cognitive radio networks: A review. *Pervasive and Mobile Computing*, 41, 106-131. <http://doi.org/https://doi.org/10.1016/j.pmcj.2017.07.01>

- Rizk, Y., Awad, M. y Tunstel, E. W. (2018). Decision making in multiagent systems: A survey. *IEEE Transactions on Cognitive and Developmental Systems*, 10(3), 514-529. <http://doi.org/10.1109/TCDS.2018.2840971>
- Rodriguez, A. B., Ramirez, L. J. y Chahuan, J. (2015). Nueva generación de heurísticas para redes de fibra óptica WDM (*wavelength división multiplexing*) bajo tráfico dinamico. *Información Tecnológica*, 26(5), 135-142. <http://dx.doi.org/10.4067/S0718-07642015000500017>
- Rodríguez-Colina, E., Ramirez, P. y Carrillo, C. E. (2011). Multiple attribute dynamic spectrum decision making for cognitive radio networks. En *2011 8th International Conference on Wireless and Optical Communications Networks*. IEEE. <http://doi.org/10.1109/WOCN.2011.587296>
- Roy, A., Midya, S., Majumder, K., Phadikar, S. y Dasgupta, A. (2017). Optimized secondary user selection for quality of service enhancement of two-tier multi-user cognitive radio network: A game theoretic approach. *Computer Networks*, 123, 1-18. <http://doi.org/10.1016/j.comnet.2017.05.002>
- Saaty, T. L. (1990). How to make a decision: The analytic hierarchy process. *European Journal of Operational Research*, 48(1), 9-26. [http://doi.org/10.1016/0377-2217\(90\)90057-I](http://doi.org/10.1016/0377-2217(90)90057-I)
- Sadanandan, A. (2011). CSVIMPORT. <https://www.mathworks.com/matlabcentral/fileexchange/23573-csvimport>
- Safavian, S. R. y Landgrebe, D. (1991). A survey of decision tree classifier methodology. *IEEE Transactions on Systems, Man, and Cybernetics*, 21(3), 660-674. <http://doi.org/10.1109/21.97458>
- Salcedo, D. (2006). *Predicción del IBC utilizando redes neuronales con wavelets* [tesis de pregrado, Universidad de los Andes (Venezuela)]. http://bdigital.ula.ve/storage/pdftesis/pregrado/tde_arquivos/8/TDE-2007-05-30T05:58:36Z-288/Publico/Dulmar%20Salcedo.pdf
- Saleem, Y. y Rehmani, M. H. (2014). Primary radio user activity models for cognitive radio networks: A survey. *Journal of Network and Computer Applications*, 43, 1-16. <https://doi.org/10.1016/j.jnca.2014.04.001>
- Salgado, C. (2014). *Algoritmo multivariable para la selección dinámica del canal de backup en redes de radio cognitiva basado en el método fuzzy analitical hierarchical process* [tesis de maestría, Universidad Distrital Francisco José de Caldas].

- Salgado, C., Márquez, H. y Gómez, V. (2016). Técnicas inteligentes en la asignación de espectro dinámica para redes inalámbricas cognitivas. *Tecnura*, 20(49), 135-153. <https://doi.org/10.14483/udistrital.jour.tecnura.2016.3.a09>
- Salgado, C., Mora, S. y Giral, D. (2016). Collaborative algorithm for the spectrum allocation in distributed cognitive networks. *International Journal of Engineering and Technology*, 8(5), 2288-2299. <http://doi.org/10.21817/ijet/2016/v8i5/160805091>
- Samui, P. (2015). *Handbook of research on advanced computational techniques for simulation-based engineering*. IGI Global.
- Sarmiento, D. A. L., Rivas, E. y García, N. Y. G. (2016). Implementing a simulator of wireless cognitive radio network primary users. *International Journal of Applied Engineering Research*, 11(2), 967-975.
- Siddique, N. y Adeli, H. (2013). *Computational intelligence: Synergies of fuzzy logic, neural networks and evolutionary computing*. Wiley. <http://doi.org/10.1002/9781118534823>
- Song, Q. y Jamalipour, A. (2005). A network selection mechanism for next generation networks. En *2005 IEEE International Conference on Communications* (vol. 2, pp. 1418-1422). IEEE. <http://doi.org/10.1109/ICC.2005.1494578>
- Soto, J., Castillo, O. y Soria, J. (2010). Chaotic time series prediction using ensembles of Anfis. En O. Castillo, J. Kacprzyk y W. Pedrycz (eds.), *Soft computing for intelligent control and mobile robotics* (pp. 287-301). Springer. http://doi.org/10.1007/978-3-642-15534-5_18
- Sriram, K. y Whitt, W. (1986). Characterizing superposition arrival processes in packet multiplexers for voice and data. *IEEE Journal on Selected Areas in Communications*, 4(6), 833-846. <http://doi.org/10.1109/JSAC.1986.1146402>
- Stevens-Navarro, E., Gallardo-Medina, R., Pineda-Rico, U. y Acosta-Elias, J. (2012). Application of MADM method Vikor for vertical handoff in heterogeneous wireless networks. *Ieice Transactions on Communications*, 95(2), 599-602. <http://doi.org/10.1587/transcom.E95.B.599>
- Stevens-Navarro, E., Lin, Y. y Wong, V. W. S. (2008). An MDP-based vertical handoff decision algorithm for heterogeneous wireless networks. *IEEE Transactions on Vehicular Technology*, 57(2), 1243-1254. <http://doi.org/10.1109/TVT.2007.907072>
- Stevens-Navarro, E., Martinez-Morales, J. D. y Pineda-Rico, U. (2012). Evaluation of vertical handoff decision algorithms based on MADM methods for

- heterogeneous wireless networks. *Journal of Applied Research and Technology*, 10(4), 534-548. <https://core.ac.uk/download/pdf/27220545.pdf>
- Stevens-Navarro, E. y Wong, V. W. S. (2006). Comparison between vertical handoff decision algorithms for heterogeneous wireless networks. En *2006 IEEE 63rd Vehicular Technology Conference* (vol. 2, pp. 947-951). IEEE. <http://doi.org/10.1109/VETECS.2004.138897>
- Sun, B., Feng, H., Chen, K. y Zhu, X. (2016). A deep learning framework of quantized compressed sensing for wireless neural recording. *IEEE Access*, 4, 5169-5178. <http://doi.org/10.1109/ACCESS.2016.2604397>
- Sundermeyer, M., Ney, H. y Schlüter, R. (2015). From feedforward to recurrent LSTM neural networks for language modeling. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 23(3), 517-529. <http://doi.org/10.1109/TASLP.2015.2400218>
- Sutton, R. S. y Barto, A. G. (1998). Reinforcement learning: An introduction. *IEEE Transactions on Neural Networks*, 9(5), 1054. <http://doi.org/10.1109/TNN.1998.712192>
- Tabassam, A. A. y Suleman, M. U. (2012). Game theory in wireless and cognitive radio networks: Coexistence perspective. En *2012 IEEE Symposium on Wireless Technology and Applications (ISWTA 2012)* (pp. 177-181). IEEE. <http://doi.org/10.1109/ISWTA.2012.6373837>
- Tahir, M., Hadi Habaebi, M. e Islam, M. R. (2017). Novel distributed algorithm for coalition formation for enhanced spectrum sensing in cognitive radio networks. *AEU: International Journal of Electronics and Communications*, 77, 139-148. <http://doi.org/https://doi.org/10.1016/j.aeue.2017.04.033>
- Taj, M. I. y Akil, M. (2011). Cognitive radio spectrum evolution prediction using artificial neural networks based multivariate time series modelling. En *17th European Wireless 2011. Sustainable Wireless Technologies*. VDE. <https://ieeexplore.ieee.org/document/5898018>
- Tanino, T., Tanaka, T. e Inuiguchi, M. (eds.). (2003). *Multi-objective programming and goal programming: Theory and applications* (vol. 21). Springer.
- Tragos, E. Z., Zeadally, S., Fragkiadakis, A. G. y Siris, V. A. (2013). Spectrum assignment in cognitive radio networks: A comprehensive survey. *IEEE Communications Surveys & Tutorials*, 15(3), 1108-1135. <http://doi.org/10.1109/SURV.2012.121112.00047>

- Trigui, E., Esseghir, M. y Merghem-Boulahia, L. (2012). Multi-agent systems negotiation approach for handoff in mobile cognitive radio networks. En *2012 5th International Conference on New Technologies, Mobility and Security (NTMS 2012)*. IEEE. <http://doi.org/10.1109/NTMS.2012.6208687>
- Tripathi, S., Upadhyay, A., Kotyan, S. y Yadav, S. (2019). Analysis and comparison of different fuzzy inference systems used in decision making for secondary users in cognitive radio network. *Wireless Personal Communications*, 104(3), 1175-1208. <http://doi.org/10.1007/s11277-018-6075-9>
- Tsiropoulos, G. I., Dobre, O. A., Ahmed, M. H. y Baddour, K. E. (2016). Radio resource allocation techniques for efficient spectrum access in cognitive radio networks. *IEEE Communications Surveys & Tutorials*, 18(1), 824-847. <http://doi.org/10.1109/COMST.2014.2362796>
- Tumuluru, V. K., Wang, P. y Niyato, D. (2010). A neural network based spectrum prediction scheme for cognitive radio. En *2010 IEEE International Conference on Communications*. IEEE. <http://doi.org/10.1109/ICC.2010.5502348>
- Uyanik, G. S., Canberk, B. y Oktug, S. (2012). Predictive spectrum decision mechanisms in cognitive radio networks. En *2012 IEEE Globecom Workshops*. <http://doi.org/10.1109/GLOCOMW.2012.6477703>
- Valenta, V., Maršálek, R., Baudoin, G., Villegas, M., Suarez, M. y Robert, F. (2010). Survey on spectrum utilization in Europe: Measurements, analyses and observations. En *2010 Proceedings of the Fifth International Conference on Cognitive Radio Oriented Wireless Networks and Communications*. IEEE. <http://doi.org/10.4108/ICST.CROWNCOM2010.922>
- Valero Verdú, S. y Senabre Blanes, C. (2013). *Aplicación de un modelo de red neuronal no supervisado a la clasificación de consumidores eléctricos*. Club Universitario.
- Vásquez, H., Hernández, C. y Páez, I. (2015). Proactive spectrum handoff model with time series prediction. *International Journal of Applied Engineering Research*, 10(21), 42.259-42.264.
- Vasudeva, A. y Sood, M. (2018). Survey on sybil attack defense mechanisms in wireless ad hoc networks. *Journal of Network and Computer Applications*, 120, 78-118. <http://doi.org/https://doi.org/10.1016/j.jnca.2018.07.006>
- Veeriah, V., Zhuang, N. y Qi, G.-J. (2015). Differential recurrent neural networks for action recognition. En *2015 IEEE International Conference on Computer Vision (ICCV)*. IEEE. <http://doi.org/10.1109/ICCV.2015.46>

- Velmurugan, T. (2014). Performance based analysis between k-Means and fuzzy C-Means clustering algorithms for connection oriented telecommunication data. *Applied Soft Computing*, 19, 134-146. <http://doi.org/10.1016/j.asoc.2014.02.011>
- Wang, B. y Liu, K. J. R. (2011). Advances in cognitive radio networks: A survey. *IEEE Journal of Selected Topics in Signal Processing*, 5(1), 5-23. <http://doi.org/10.1109/JSTSP.2010.209321>
- Wang, C.-W. y Wang, L.-C. (2009). Modeling and analysis for proactive-decision spectrum handoff in cognitive radio networks. En *2009 IEEE International Conference on Communications*. IEEE. <http://doi.org/10.1109/ICC.2009.5199189>
- Wang, J., Ghosh, M. y Challapali, K. (2011). Emerging cognitive radio applications: A survey. *IEEE Communications Magazine*, 49(3), 74-81. <http://doi.org/10.1109/MCOM.2011.5723803>
- Wang, L.-C., Wang, C.-W. y Adachi, F. (2011). Load-balancing spectrum decision for cognitive radio networks. *IEEE Journal on Selected Areas in Communications*, 29(4), 757-769. <http://doi.org/10.1109/JSAC.2011.110408>
- Wang, L.-C., Wang, C.-W. y Chang, C.-J. (2012). Modeling and analysis for spectrum handoffs in cognitive radio networks. *IEEE Transactions on Mobile Computing*, 11(9), 1499-1513. <http://doi.org/10.1109/TMC.2011.155>
- Wang, P., Ansari, J., Petrova, M. y Mähönen, P. (2016). CogMAC+: A decentralized MAC protocol for opportunistic spectrum access in cognitive wireless networks. *Computer Communications*, 79, 22-36. <http://doi.org/https://doi.org/10.1016/j.comcom.2015.09.016>
- Wang, X. Y., Wong, A. y Ho, P.-H. (2010). Dynamically optimized spatiotemporal prioritization for spectrum sensing in cooperative cognitive radio. *Wireless Networks*, 16(4), 889-901. <http://doi.org/10.1007/s11276-009-0175->
- Wei, Q., Farkas, K., Prehofer, C., Mendes, P. y Plattner, B. (2006). Context-aware handover using active network technology. *Computer Networks*, 50(15), 2855-2872. <http://doi.org/10.1016/j.comnet.2005.11.002>
- Wei, Y., Li, X., Song, M. y Song, J. (2008). Cooperation radio resource management and adaptive vertical handover in heterogeneous wireless networks. En *International Conference on Natural Computation* (vol. 5, pp. 197-201). IEEE. <http://doi.org/10.1109/ICNC.2008.504>
- Willkomm, D., Machiraju, S., Bolot, J. y Wolisz, A. (2008). Primary users in cellular networks: A large-scale measurement study. En *2008 IEEE Symposium on New*

- Frontiers in Dynamic Spectrum Access Networks* (pp. 401-411). IEEE. <http://doi.org/10.1109/DYSPAN.2008.48>
- Winston, O., Thomas, A. y Okelloodongo, W. (2013). Optimizing neural network for TV idle channel prediction in cognitive radio using particle swarm optimization. En *Fifth International Conference on Computational Intelligence, Communication Systems and Networks (CICSyN 2013)* (pp. 25-29). IEEE. <http://doi.org/10.1109/CICSYN.2013.68>
- Woods, W. A. (1986). Important issues in knowledge representation. *Proceedings of the IEEE*, 74(10), 1322-1334. <http://doi.org/10.1109/PROC.1986.13634>
- Wooldridge, M. (2009). *An introduction to multiagent systems*. John Wiley & Sons.
- Wu, Y., Yang, Q., Liu, X. y Kwak, K. S. (2016). Delay-constrained optimal transmission with proactive spectrum handoff in cognitive radio networks. *IEEE Transactions on Communications*, 64(7), 2767-2779. <http://doi.org/10.1109/TCOMM.2016.2561936>
- Xenakis, D., Passas, N. y Merakos, L. (2014). Multi-parameter performance analysis for decentralized cognitive radio networks. *Wireless Networks*, 20(4), 787-803. <https://doi.org/10.1007/s11276-013-0635-4>
- Xing, X., Jing, T., Cheng, W., Huo, Y. y Cheng, X. (2013). Spectrum prediction in cognitive radio networks. *IEEE Wireless Communications*, 20(2), 90-96. <http://doi.org/10.1109/MWC.2013.6507399>
- Xing, X., Jing, T., Huo, Y., Li, H. y Cheng, X. (2013). Channel quality prediction based on Bayesian inference in cognitive radio networks. En *2013 Proceedings IEEE Infocom* (pp. 1465-1473). IEEE. <http://doi.org/10.1109/INFCOM.2013.6566941>
- Xu, G. y Lu, Y. (2006). Channel and modulation selection based on support vector machines for cognitive radio. En *2006 IEEE International Conference on Wireless Communications, Networking and Mobile Computing*. IEEE. <http://doi.org/10.1109/WiCOM.2006.181>
- Yang, S.-F. y Jung-ShyrWu. (2008). A IEEE 802.21 handover design with QOS provision across WLAN and WMAN. En *2008 International Conference on Communications, Circuits and Systems* (pp. 548-552). IEEE. <http://doi.org/10.1109/ICC-CAS.2008.4657833>
- Yang, S.-J. y Tseng, W.-C. (2013). Design novel weighted rating of multiple attributes scheme to enhance handoff efficiency in heterogeneous wireless networks. *Computer Communications*, 36(14), 1498-1514. <http://doi.org/10.1016/j.comcom.2013.06.005>

- Yao, Y., Hu, Q., Yu, H. y Grzymala-Busse, J. W. (eds.). (2015). *Rough sets, fuzzy sets, data mining, and granular computing* (vol. 2639). Tianjin, China: Springer.
- Yarkan, S. y Arslan, H. (2007). Binary time series approach to spectrum prediction for cognitive radio. En *2007 IEEE 66th Vehicular Technology Conference* (pp. 1563-1567). IEEE. <http://doi.org/10.1109/VETECF.2007.332>
- Yifei, W., Yinglei, T., Li, W., Mei, S. y Xiaojun, W. (2013). QoS provisioning energy saving dynamic access policy for overlay cognitive radio networks with hidden Markov channels. *China Communications*, 10(12), 92-101. <http://doi.org/10.1109/CC.2013.6723882>
- Yonghui, C. (2010). Study of the Bayesian networks. En *2010 International Conference on E-Health Networking, Digital Ecosystems and Technologies* (vol. 1, pp. 172-174). IEEE. <http://doi.org/10.1109/EDT.2010.5496612>
- Yoon, K. y Hwang, C.-L. (1995). *Multiple attribute decision making: An introduction* (vol. 104). Sage.
- Youssef, M. E., Nasim, S., Wasi, S., Khisal, U. y Khan, A. (2018). Efficient cooperative spectrum detection in cognitive radio systems using wavelet fusion. En *2018 International Conference on Computing, Electronic and Electrical Engineering*. IEEE. <http://doi.org/10.1109/ICECUBE.2018.8610981>
- Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3), 338-353. [http://doi.org/10.1016/S0019-9958\(65\)90241-X](http://doi.org/10.1016/S0019-9958(65)90241-X)
- Zapata, J. A., Arango, M. D. y Adarme, W. (2012). Applying fuzzy extended analytical hierarchy (Feahp) for selecting logistics software. *Ingeniería e Investigación*, 32(1), 94-99. <http://www.revistas.unal.edu.co/index.php/ingeninv/article/view/28521/33581>
- Zapata Muñoz, D. F. y Anzola Rojas, C. (2016). *Diseño de un algoritmo MAC para la asignación equitativa de espectro en redes inalámbricas de radio cognitiva* [tesis de pregrado, Universidad Distrital Francisco José de Caldas]. RIUD. <http://repository.udistrital.edu.co/bitstream/11349/3754/1/AnzolaRojasCamilo2016.pdf>
- Zhang, H., Nie, Y., Cheng, J., Leung, V. C. M. y Nallanathan, A. (2017). Sensing time optimization and power control for energy efficient cognitive small cell with imperfect hybrid spectrum sensing. *IEEE Transactions on Wireless Communications*, 16(2), 730-743. <http://doi.org/10.1109/TWC.2016.2628821>
- Zhang, W. (2004). Handover decision using fuzzy MADM in heterogeneous networks. En *2004 IEEE Wireless Communications and Networking Conference* (vol. 4, pp. 653-658). IEEE. <http://doi.org/10.1109/WCNC.2004.1311263>

- Zhang, Y., Tay, W. P., Li, K. H., Esseghir, M. y Gaïti, D. (2016). Opportunistic spectrum access with temporal-spatial reuse in cognitive radio networks. En *IEEE International Conference on Acoustics, Speech and Signal Processing* (pp. 3661-3665). IEEE. <https://sigport.org/documents/opportunistic-spectrum-access-temporal-spatial-reuse-cognitive-radio-networks>
- Zhao, Y., Mao, S., Neel, J. O. y Reed, J. H. (2009). Performance evaluation of cognitive radios: Metrics, utility functions, and methodology. *Proceedings of the IEEE*, 97(4), 642-658. <http://doi.org/10.1109/JPROC.2009.2013017>
- Zheng, H. y Cao, L. (2005). Device-centric spectrum management. En *IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks* (pp. 56-65). IEEE. <http://doi.org/10.1109/DYSPAN.2005.1542617>

César Augusto Hernández Suárez

Ingeniero electrónico con especialización en Interconexión de Redes; magíster en Ciencias de la Información y las Comunicaciones de la Universidad Distrital Francisco José de Caldas, y doctor en Ingeniería de la Universidad Nacional de Colombia. Profesor titular de la Universidad Distrital Francisco José de Caldas, adscrito a los programas de Tecnología en Electricidad de Media y Baja Tensión e Ingeniería Eléctrica de la Facultad Tecnológica. Investigador Sénior de Colciencias, director del grupo de investigación SIREC con categoría A1 de Colciencias, e integrante de los grupos de investigación Gidenutas (A1 de Colciencias) e Internet Inteligente (A de Colciencias), en los que lidera investigaciones sobre sistemas y redes cognitivas y aplicaciones tecnológicas que contribuyen a mejorar la calidad de vida de comunidades vulnerables. Ha realizado publicaciones de patentes, libros de investigación y artículos en el área de las telecomunicaciones en revistas indexadas de categoría nacional e internacional.

Danilo Alfonso López Sarmiento

Ingeniero electrónico, magíster en Teleinformática y doctor en Ingeniería de la Universidad Distrital Francisco José de Caldas. Profesor asociado de la Universidad Distrital Francisco José de Caldas, adscrito a la Facultad de Ingeniería. Investigador Junior de Colciencias, integrante del grupo de investigación Internet Inteligente y LIDER con categoría A de Colciencias. Ha realizado publicaciones de libros de investigación y artículos en el área de las telecomunicaciones en revistas indexadas de categoría nacional e internacional.

Diego Armando Giral Ramírez

Ingeniero eléctrico de la Universidad Distrital Francisco José de Caldas, magíster en Ingeniería Eléctrica de la Universidad de los Andes y candidato a doctor en Ingeniería de la Universidad Distrital Francisco José de Caldas. Profesor asistente de la Universidad Distrital Francisco José de Caldas, adscrito a los programas de Tecnología en Electricidad de Media y Baja Tensión e Ingeniería Eléctrica de la Facultad Tecnológica. Investigador Junior de Colciencias, integrante del grupo de investigación SIREC con categoría A1 de Colciencias. Ha realizado publicaciones de libros de investigación y artículos en el área de las telecomunicaciones y sistemas de potencia en revistas indexadas de categoría nacional e internacional.

Este libro se
terminó de imprimir
en noviembre de 2020
en la Editorial UD,
Bogotá, Colombia