

Modelo de asignación espectral multiusuario para redes de radio cognitiva descentralizadas

Modelo de asignación espectral multiusuario para redes de radio cognitiva descentralizadas

César Augusto Hernández Suárez, Diego Armando Giral Ramírez,
Lizet Camila Salgado Franco



*Este libro está dedicado a mis padres,
hermanos y a ti
Diego Armando Giral Ramírez*

*A todos aquellos que día tras día luchan incansablemente
por perseguir sus sueños
César Augusto Hernández Suárez*

Agradecimiento

A Dios por darnos la sabiduría necesaria para tomar las decisiones correctas, fortaleza para no desfallecer ante las dificultades e 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 tiempo necesario para ejecutar este proyecto. Al Centro de Investigaciones y Desarrollo Científico por financiar los recursos necesarios para la divulgación y publicación de los resultados de investigación alcanzados con este proyecto.

Financiamiento

Este libro de investigación es producto de los resultados alcanzados con el proyecto “Modelo inteligente de asignación espectral con enfoque multiusuario para mejorar la eficiencia y desempeño en redes de radio cognitiva descentralizadas”, financiado por el Centro de Investigaciones y Desarrollo Científico de la Universidad Distrital Francisco José de Caldas.



UD
Editorial

E2
ESPACIOS

© Universidad Distrital Francisco José de Caldas
© Centro de Investigaciones y Desarrollo Científico
© César Augusto Hernández Suárez, Diego Armando Giral Ramírez,
Lizet Camila Salgado Franco
ISBN: 978-958-787-310-8
Primera edición, diciembre de 2021

Dirección Sección de Publicaciones

Rubén Eliécer Carvajalino C.

Coordinación editorial

Nathalie De la Cuadra N.

Corrección de estilo

Proceditor

Diagramación

Diego Abello Rico

Imagen de cubierta

Diego Abello Rico

Editorial UD

Universidad Distrital Francisco José de Caldas

Carrera 24 N°. 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 asignación espectral multiusuario para redes de radio cognitiva descentralizadas / César Augusto Hernández Suárez, Diego Armando Giral Ramírez, Lizet Camila Salgado Franco. -- 1a ed. -- Bogotá : Universidad Distrital Francisco José de Caldas, 2021. p.408 -- (Espacios)

Contiene reseña de los autores. -- Incluye referencias bibliográficas.

ISBN 978-958-787-310-8

1. Redes de radio cognitivas 2. Espectro radioeléctrico - Modelos
I. Giral Ramírez, Diego Armando II. Salgado Franco, Lizet Camila III.
Título IV. Serie

CDD: 621.384 ed. 23

CO-BoBN- a1085675

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

1. Introducción	27
1.1 Problema y motivación del proyecto de investigación	29
1.2 Justificación	31
1.3 Objetivos	32
1.4 Alcance y limitaciones	33
1.5 Modelo propuesto	36
1.6 Metodología	37
1.7 Contribuciones	38
1.8 Financiamiento	39
1.9 Organización del libro	39
2. Fundamentos teóricos	41
2.1 Radio cognitiva	41
2.2 Decisión espectral	50
2.3 Técnicas y algoritmos para la asignación espectral	68
2.4 Multiusuario	101
2.5 Estructuras colaborativas	102
2.6 Trabajos relacionados	104
3. Metodología	115
3.1 Selección de <i>software</i> y equipos	115
3.2 Tipo de red	116
3.3 Captura y procesamiento de datos de ocupación espectral	117
3.4 Nivel de tráfico	119
3.5 Modelo propuesto	125
3.6 Otros algoritmos	164

3.7 Criterios de decisión	169
3.8 Métricas de evaluación	170
4. Software de simulación desarrollado	173
4.1 Interfaz herramienta de simulación desarrollada	173
4.2 Descripción general	175
4.3 <i>Project Information Module</i>	177
4.4 Módulo colaborativo	183
4.5 Módulo multiusuario	190
4.6 <i>Parameters Module</i>	196
4.7 <i>Models module</i>	202
4.8 <i>No Predicton Module</i>	221
4.9 <i>Predicton Module</i>	227
4.10 Módulo de salida	247
5. Resultados de la investigación	249
5.1 Evaluación de los modelos no predictivos	252
5.2 Evaluación de los modelos predictivos	258
5.3 Evaluación comparativa y selección de los modelos	267
5.4 Evaluación del nivel de colaboración de los modelos	268
5.5 Evaluación con enfoque multiusuario de los modelos	281
6. Discusión	369
7. Conclusiones	377
7.1 Generales	377
7.2 Contribuciones de la investigación	379
7.3 Investigación futura	380
Referencias	383
Autores	405

Lista de figuras

Figura 1.1.	Modelo propuesto.	36
Figura 2.1.	Concepto de oportunidades espectrales.	43
Figura 2.2.	Ciclo cognitivo.	45
Figura 2.3.	Clasificación de las técnicas de detección de espectro.	45
Figura 2.4.	Arquitectura de una CRN.	47
Figura 2.5.	Arquitectura de una red.	48
Figura 2.6.	Marco de decisión del espectro.	52
Figura 2.7.	Caracterización del ambiente de radio.	56
Figura 2.8.	Clasificación de los algoritmos para la asignación de espectro.	70
Figura 2.9.	Estructura propuesta para el algoritmo FAHP.	81
Figura 2.10.	TFN para la escala de importancia de FAHP.	83
Figura 2.11.	Esquema del algoritmo FFAHP propuesto.	88
Figura 2.12.	Número difuso triangular.	90
Figura 2.13.	Escenario multiusuario.	102
Figura 2.14.	Clasificación de estrategias colaborativas.	104
Figura 3.1.	Configuración experimental para medir la ocupación espectral.	117
Figura 3.2.	Probabilidad de disponibilidad matriz de potencia.	119
Figura 3.3.	Metodología para AP objetivo.	120
Figura 3.4.	Probabilidad de disponibilidad actual.	121
Figura 3.5.	Modificaciones porcentuales bajo criterios de ETA.	123
Figura 3.6.	Probabilidad de disponibilidad para tráfico alto y bajo GSM.	124
Figura 3.7.	Modelo de asignación espectral multiusuario para redes de radio cognitiva descentralizadas.	126
Figura 3.8.	Diagrama general del módulo colaborativo.	128
Figura 3.9.	Operación particular del modelo colaborativo.	130
Figura 3.10.	Base de datos de entrada para los dos escenarios.	131

Figura 3.11.	Matriz de disponibilidad seccionado para 6 usuarios con división por fila.	133
Figura 3.12.	Matriz de entrenamiento para 3 usuarios, con 50 % de nivel de colaboración y selección aleatoria.	133
Figura 3.13.	Matriz de disponibilidad seccionado para 6 usuarios con división por columna.	134
Figura 3.14.	Matriz entrenamiento para 4 SU, con 67 % de colaboración y selección aleatoria.	135
Figura 3.15.	Diagrama general del módulo multiusuario.	138
Figura 3.16.	Ajustes para características de los usuarios.	139
Figura 3.17.	Descripción particular para las características de los usuarios.	139
Figura 3.18.	Usuarios totales en modo convencional y en modo real.	140
Figura 3.19.	Asignación de usuarios y tiempo aleatorio.	142
Figura 3.20.	Ubicación de usuarios aleatorios.	144
Figura 3.21.	Asignación de prioridad.	145
Figura 3.22.	Movilidad espectral para múltiples usuarios en modo convencional.	147
Figura 3.23.	Movilidad espectral para múltiples usuarios en modo real.	148
Figura 3.24.	Estructura del módulo predictivo.	149
Figura 3.25.	Proceso de entrenamiento de la regresión logística.	150
Figura 3.26.	Regresión logística para la predicción de disponibilidad.	151
Figura 3.27.	<i>Naive Bayes</i> para la predicción de disponibilidad.	153
Figura 3.28.	Variables de entrada y salida modelo de aprendizaje de transferencia para la extracción de características.	155
Figura 3.29.	Diagrama de bloques general para el modelo basado en <i>Deep Learning</i> .	156
Figura 3.30.	Generación de figuras para la matriz de potencia.	158
Figura 3.31.	Arquitectura red neuronal convolucional AlexNet.	159
Figura 3.32.	Entradas y salidas red neuronal convolucional AlexNet.	159
Figura 3.33.	Máquina de soporte vectorial multiclase para clasificación de imágenes.	160
Figura 3.34.	Ejemplo de clasificación para tráfico alto y tráfico bajo.	161
Figura 3.35.	Figuras con oportunidades espectrales intermedias.	161
Figura 3.36.	Procesamiento para segmentar las figuras de tráfico medio.	162
Figura 3.37.	Ranking para el modelo de aprendizaje de transferencia utilizando <i>Deep Learning</i> .	164
Figura 4.1.	Interfaz gráfica App MultiColl-DCRN.	174

Figura 4.2.	Arquitectura por módulos APP MultiColl-DCRN.	175
Figura 4.3.	Convención de colores para la descripción de los módulos.	176
Figura 4.4.	Módulo “ <i>Project Information</i> ”.	177
Figura 4.5.	Descripción variables de entrada y salida del módulo “ <i>Project Information</i> ”.	178
Figura 4.6.	AP para la caracterización de GSM en tráfico alto.	180
Figura 4.7.	AP para la caracterización de GSM en tráfico bajo.	180
Figura 4.8.	Función “ <i>Project Path Folder</i> ”.	182
Figura 4.9.	Función “ <i>Database</i> ”.	182
Figura 4.10.	Resumen de parámetros “ <i>Collaborative Module</i> ”, <i>interfaz principal App MultiColl-DCRN</i> .	184
Figura 4.11.	Interfaz “ <i>Collaborative Module</i> ” App MultiColl-DCRN.	184
Figura 4.12.	Estructura general “ <i>Collaborative Module</i> ”.	185
Figura 4.13.	Variables de entrada y funciones “ <i>Collaborative Module</i> ”.	186
Figura 4.14.	Función “ <i>Division – Number Users</i> ”.	189
Figura 4.15.	Función “ <i>Segmentation–Users Percentage</i> ”.	190
Figura 4.16.	Resumen de parámetros “ <i>Multi-user Module</i> ”, <i>interfaz principal App MultiColl-DCRN</i> .	191
Figura 4.17.	Interfaz “ <i>Multi-user Module</i> ” App MultiColl-DCRN.	191
Figura 4.18.	Estructura general “ <i>Multi-user Module</i> ”.	192
Figura 4.19.	Variables de entrada y funciones “ <i>Multi-user Module</i> ”.	193
Figura 4.20.	Función “ <i>Multichannel Users</i> ”.	195
Figura 4.21.	Función “ <i>Random Users</i> ”.	196
Figura 4.22.	“ <i>Parameters Modules</i> ” MultiColl-DCRN.	196
Figura 4.23.	Estructura general “ <i>Parameters Module</i> ”.	197
Figura 4.24.	Variables de entrada y funciones “ <i>Parameters Module</i> ”.	198
Figura 4.25.	Función “ <i>Select Power Traffic Level</i> ”.	201
Figura 4.26.	Función “ <i>New Database</i> ”.	202
Figura 4.27.	Modelos disponibles.	202
Figura 4.28.	Módulo de técnicas de no predicción y predicción MultiColl-DCRN.	203
Figura 4.29.	Función “ <i>Initial Parameter</i> ”.	204
Figura 4.30.	Funciones “ <i>Ranking</i> ”.	207
Figura 4.31.	Algoritmos multicriterio “ <i>Handoff Models</i> ”.	210
Figura 4.32.	Algoritmo de búsqueda para el análisis de movilidad espectral.	213
Figura 4.33.	Algoritmo indicadores de predicción.	214

Figura 4.34.	Algoritmo métricas de desempeño.	215
Figura 4.35.	Ejemplo figuras algoritmo métricas de desempeño.	218
Figura 4.36.	Algoritmo métricas de predicción.	219
Figura 4.37.	Ejemplo figuras algoritmo métricas de predicción.	220
Figura 4.38.	Descripción variables de entrada y salida “ <i>No Prediction Module</i> ”.	221
Figura 4.39.	Modelo propuesto Movilidad espectral.	222
Figura 4.40.	Descripción variables de entrada y salida modelo de Movilidad espectral.	223
Figura 4.41.	Diagrama de bloques modelo no predictivo, técnica: movilidad espectral.	225
Figura 4.42.	Modelo propuesto <i>Feature Extraction</i> .	225
Figura 4.43.	Descripción variables de entrada y salida modelo <i>Feature Extraction</i> .	226
Figura 4.44.	Diagrama de bloques modelo no predictivo técnica <i>Feature Extraction</i> .	227
Figura 4.45.	Descripción variables de entrada y salida “ <i>Prediction Module</i> ”.	228
Figura 4.46.	Modelo propuesto Markov Chain.	230
Figura 4.47.	Descripción variables de entrada y salida modelo Markov Chain.	231
Figura 4.48.	Diagrama de bloques modelo no predictivo técnica <i>Markov Chain</i> .	232
Figura 4.49.	Equivalentes genéticos población específica.	233
Figura 4.50.	Modelo propuesto <i>Genetic Algorithm</i> .	235
Figura 4.51.	Descripción variables de entrada y salida <i>Genetic Algorithm</i> .	236
Figura 4.52.	Diagrama de bloques modelo no predictivo técnica <i>Genetic Algorithm</i> .	237
Figura 4.53.	Modelo propuesto <i>Naive Bayes</i> .	238
Figura 4.54.	Descripción variables de entrada y salida modelo <i>Naive Bayes</i> .	239
Figura 4.55.	Diagrama de bloques modelo no predictivo, técnica <i>Naive Bayes</i> .	240
Figura 4.56.	Modelo propuesto <i>Logistic Regression</i> .	241
Figura 4.57.	Descripción variables de entrada y salida modelo <i>Logistic Regression</i> .	242
Figura 4.58.	Diagrama de bloques modelo no predictivo, técnica <i>Logistic Regression</i> .	243
Figura 4.59.	Modelo propuesto <i>Time Series</i> .	244
Figura 4.60.	Descripción variables de entrada y salida modelo <i>Time Series</i> .	245
Figura 4.61.	Diagrama de bloques modelo no predictivo, técnica <i>Time Series</i> .	246
Figura 4.62.	Salida MultiColl-DCRN.	247
Figura 5.1.	AAH de modelos no predictivos en GSM para HT y LT.	252
Figura 5.2.	AAFH de modelos no predictivos en GSM para HT y LT.	253
Figura 5.3.	ABW de modelos no predictivos en GSM para HT y LT.	254
Figura 5.4.	AAD de modelos no predictivos en GSM para HT y LT.	255

Figura 5.5.	AAT de modelos no predictivos en GSM para HT y LT.	256
Figura 5.6.	AAH de modelos predictivos en GSM para HT y LT.	258
Figura 5.7.	AAFH de modelos predictivos en GSM para HT y LT.	259
Figura 5.8.	ABW de modelos predictivos en GSM para HT y LT.	260
Figura 5.9.	AAD de modelos predictivos en GSM para HT y LT.	261
Figura 5.10.	AAT de modelos predictivos en GSM para HT y LT.	262
Figura 5.11.	AAIH de modelos Predictivos en GSM para HT y LT.	263
Figura 5.12.	AAUH de modelos Predictivos en GSM para HT y LT.	264
Figura 5.13.	AAPH de modelos predictivos en GSM para HT y LT.	265
Figura 5.14.	AAH con 10 %, 40 %, 70 % y 100 % de colaboración para GSM con HT.	268
Figura 5.15.	AAH con 10 %, 40 %, 70 % y 100 % de colaboración para GSM con LT.	269
Figura 5.16.	AAFH con 10 %, 40 %, 70 % y 100 % de colaboración para GSM con HT.	270
Figura 5.17.	AAFH con 10 %, 40 %, 70 % y 100 % de colaboración para GSM con LT.	271
Figura 5.18.	ABW con 10 %, 40 %, 70 % y 100 % de colaboración para GSM con HT.	272
Figura 5.19.	ABW con 10 %, 40 %, 70 % y 100 % de colaboración para GSM con LT.	273
Figura 5.20.	AAD con 10 %, 40 %, 70 % y 100 % de colaboración para GSM con HT.	274
Figura 5.21.	AAD con 10 %, 40 %, 70 % y 100 % de colaboración para GSM con LT.	275
Figura 5.22.	AAT con 10 %, 40 %, 70 % y 100 % de colaboración para GSM con HT.	276
Figura 5.23.	AAT con 10 %, 40 %, 70 % y 100 % de colaboración para GSM con LT.	277
Figura 5.24:	AAIH, AAUH, AAPH con 10 %, 40 %, 70 % y 100 % de colaboración en GSM con HT.	278
Figura 5.25.	<i>Deep Learning</i> con 1 SU en HT con y sin SU aleatorios adicionales.	282
Figura 5.26.	<i>Deep Learning</i> con 1 SU en LT con y sin SU aleatorios adicionales.	283
Figura 5.27.	<i>Deep Learning</i> con 2 SU en HT con y sin SU aleatorios adicionales.	284
Figura 5.28.	<i>Deep Learning</i> con 2 SU en LT con y sin SU aleatorios adicionales.	285
Figura 5.29.	<i>Deep Learning</i> con 4 SU en HT con y sin SU aleatorios adicionales.	286
Figura 5.30.	<i>Deep Learning</i> con 4 SU en LT con y sin SU aleatorios adicionales.	287
Figura 5.31.	<i>Deep Learning</i> con 6 SU en HT con y sin SU aleatorios adicionales.	288
Figura 5.32.	<i>Deep Learning</i> con 6 SU en LT con y sin SU aleatorios adicionales.	289
Figura 5.33.	<i>Deep Learning</i> con 8 SU en HT con y sin SU aleatorios adicionales.	290
Figura 5.34.	<i>Deep Learning</i> con 8 SU en LT con y sin SU aleatorios adicionales.	291
Figura 5.35.	<i>Deep Learning</i> con 10 SU en HT con y sin SU aleatorios adicionales.	292
Figura 5.36.	<i>Deep Learning</i> con 10 SU en LT con y sin SU aleatorios adicionales.	293
Figura 5.37.	FFAHP con 1 SU en HT con y sin SU aleatorios adicionales.	294

Figura 5.38.	FFAHP con 1 SU en LT con y sin SU aleatorios adicionales.	295
Figura 5.39.	FFAHP con 2 SU en HT con y sin SU aleatorios adicionales.	296
Figura 5.40.	FFAHP con 2 SU en LT con y sin SU aleatorios adicionales.	297
Figura 5.41.	FFAHP con 4 SU en HT con y sin SU aleatorios adicionales.	298
Figura 5.42.	FFAHP con 4 SU en LT con y sin SU aleatorios adicionales.	299
Figura 5.43.	FFAHP con 6 SU en HT con y sin SU aleatorios adicionales.	300
Figura 5.44.	FFAHP con 6 SU en LT con y sin SU aleatorios adicionales.	301
Figura 5.45.	FFAHP con 8 SU en HT con y sin SU aleatorios adicionales.	302
Figura 5.46.	FFAHP con 8 SU en LT con y sin SU aleatorios adicionales.	303
Figura 5.47.	FFAHP con 10 SU en HT con y sin SU aleatorios adicionales.	304
Figura 5.48.	FFAHP con 10 SU en LT con y sin SU aleatorios adicionales.	305
Figura 5.49.	AAH de <i>Naive Bayes</i> con 1 SU en HT con y sin SU aleatorios adicionales.	306
Figura 5.50.	AAH de <i>Naive Bayes</i> con 1 SU en LT con y sin SU aleatorios adicionales.	307
Figura 5.51.	AAH de <i>Naive Bayes</i> con 2 SU en HT con y sin SU aleatorios adicionales.	308
Figura 5.52.	AAH de <i>Naive Bayes</i> con 2 SU en LT con y sin SU aleatorios adicionales.	309
Figura 5.53.	AAH de <i>Naive Bayes</i> con 4 SU en HT con y sin SU aleatorios adicionales.	310
Figura 5.54.	AAH de <i>Naive Bayes</i> con 4 SU en LT con y sin SU aleatorios adicionales.	311
Figura 5.55.	AAH de <i>Naive Bayes</i> con 6 SU en HT con y sin SU aleatorios adicionales.	312
Figura 5.56.	AAH de <i>Naive Bayes</i> con 6 SU en LT con y sin SU aleatorios adicionales.	313
Figura 5.57.	AAH de <i>Naive Bayes</i> con 8 SU en HT con y sin SU aleatorios adicionales.	314
Figura 5.58.	AAH de <i>Naive Bayes</i> con 8 SU en LT con y sin SU aleatorios adicionales.	315
Figura 5.59.	AAH de <i>Naive Bayes</i> con 10 SU en HT con y sin SU aleatorios adicionales.	316
Figura 5.60.	AAH de <i>Naive Bayes</i> con 10 SU en LT con y sin SU aleatorios adicionales.	317
Figura 5.61.	AAIH de <i>Naive Bayes</i> con 1 SU en HT con y sin SU aleatorios adicionales.	318
Figura 5.62.	AAIH de <i>Naive Bayes</i> con 1 SU en LT con y sin SU aleatorios adicionales.	319
Figura 5.63.	AAIH de <i>Naive Bayes</i> con 2 SU en HT con y sin SU aleatorios adicionales.	320
Figura 5.64.	AAIH de <i>Naive Bayes</i> con 2 SU en LT con y sin SU aleatorios adicionales.	321
Figura 5.65.	AAIH de <i>Naive Bayes</i> con 4 SU en HT con y sin SU aleatorios adicionales.	322
Figura 5.66.	AAIH de <i>Naive Bayes</i> con 4 SU en LT con y sin SU aleatorios adicionales.	323
Figura 5.67.	AAIH de <i>Naive Bayes</i> con 6 SU en HT con y sin SU aleatorios adicionales.	324
Figura 5.68.	AAIH de <i>Naive Bayes</i> con 6 SU en LT con y sin SU aleatorios adicionales.	325
Figura 5.69.	AAIH de <i>Naive Bayes</i> con 8 SU en HT con y sin SU aleatorios adicionales.	326
Figura 5.70.	AAIH de <i>Naive Bayes</i> con 8 SU en LT con y sin SU aleatorios adicionales.	327
Figura 5.71.	AAIH de <i>Naive Bayes</i> con 10 SU en HT con y sin SU aleatorios adicionales.	328

Figura 5.72.	AAIH de <i>Naive Bayes</i> con 10 SU en LT con y sin SU aleatorios adicionales.	329
Figura 5.73.	SAW con 1 SU en HT con y sin SU aleatorios adicionales.	330
Figura 5.74.	SAW con 1 SU en LT con y sin SU aleatorios adicionales.	331
Figura 5.75.	SAW con 2 SU en HT con y sin SU aleatorios adicionales.	332
Figura 5.76.	SAW con 2 SU en LT con y sin SU aleatorios adicionales.	333
Figura 5.77.	SAW con 4 SU en HT con y sin SU aleatorios adicionales.	334
Figura 5.78.	SAW con 4 SU en LT con y sin SU aleatorios adicionales.	335
Figura 5.79.	SAW con 6 SU en HT con y sin SU aleatorios adicionales.	336
Figura 5.80.	SAW con 6 SU en LT con y sin SU aleatorios adicionales.	337
Figura 5.81.	SAW con 8 SU en HT con y sin SU aleatorios adicionales.	338
Figura 5.82.	SAW con 8 SU en LT con y sin SU aleatorios adicionales.	339
Figura 5.83.	SAW con 10 SU en HT con y sin SU aleatorios adicionales.	340
Figura 5.84.	SAW con 10 SU en LT con y sin SU aleatorios adicionales.	341
Figura 5.85.	TOPSIS con 1 SU en HT con y sin SU aleatorios adicionales.	342
Figura 5.86.	TOPSIS con 1 SU en LT con y sin SU aleatorios adicionales.	343
Figura 5.87.	TOPSIS con 2 SU en HT con y sin SU aleatorios adicionales.	344
Figura 5.88.	TOPSIS con 2 SU en LT con y sin SU aleatorios adicionales.	345
Figura 5.89.	TOPSIS con 4 SU en HT con y sin SU aleatorios adicionales.	346
Figura 5.90.	TOPSIS con 4 SU en LT con y sin SU aleatorios adicionales.	347
Figura 5.91.	TOPSIS con 6 SU en HT con y sin SU aleatorios adicionales.	348
Figura 5.92.	TOPSIS con 6 SU en LT con y sin SU aleatorios adicionales.	349
Figura 5.93.	TOPSIS con 8 SU en HT con y sin SU aleatorios adicionales.	350
Figura 5.94.	TOPSIS con 8 SU en LT con y sin SU aleatorios adicionales.	351
Figura 5.95.	TOPSIS con 10 SU en HT con y sin SU aleatorios adicionales.	352
Figura 5.96.	TOPSIS con 10 SU en LT con y sin SU aleatorios adicionales.	353
Figura 5.97.	VIKOR con 1 SU en HT con y sin SU aleatorios adicionales.	354
Figura 5.98.	VIKOR con 1 SU en LT con y sin SU aleatorios adicionales.	355
Figura 5.99.	VIKOR con 2 SU en HT con y sin SU aleatorios adicionales.	356
Figura 5.100.	VIKOR con 2 SU en LT con y sin SU aleatorios adicionales.	357
Figura 5.101.	VIKOR con 4 SU en HT con y sin SU aleatorios adicionales.	358
Figura 5.102.	VIKOR con 4 SU en LT con y sin SU aleatorios adicionales.	359
Figura 5.103.	VIKOR con 6 SU en HT con y sin SU aleatorios adicionales.	360
Figura 5.104.	VIKOR con 6 SU en LT con y sin SU aleatorios adicionales.	361
Figura 5.105.	VIKOR con 8 SU en HT con y sin SU aleatorios adicionales.	362

Figura 5.106.	VIKOR con 8 SU en LT con y sin SU aleatorios adicionales.	363
Figura 5.107.	VIKOR con 10 SU en HT con y sin SU aleatorios adicionales.	364
Figura 5.108.	VIKOR con 10 SU en LT con y sin SU aleatorios adicionales.	365

Lista de tablas

Tabla 2.1.	TFN y TFN recíproco para la escala de importancia de FAHP.	82
Tabla 2.2.	Matriz de juicios para los subcriterios de alta sensibilidad al retardo.	84
Tabla 2.3.	Matriz de juicios para los subcriterios de baja sensibilidad al retardo.	84
Tabla 2.4.	Pesos normalizados de los subcriterios de alta sensibilidad al retardo.	86
Tabla 2.5.	Pesos normalizados de los subcriterios de baja sensibilidad al retardo.	86
Tabla 2.6.	Análisis comparativo de las técnicas de asignación espectral.	98
Tabla 2.7.	Análisis de los enfoques de acuerdo con las estrategias implementadas y las limitaciones.	113
Tabla 3.1.	Especificaciones de los equipos para la monitorización del espectro.	116
Tabla 3.2.	Especificaciones del equipo de cómputo.	116
Tabla 3.3.	Configuración de los parámetros técnicos del analizador de espectro para GSM.	117
Tabla 3.4.	Estructura de la base de datos para la matriz de potencia.	125
Tabla 3.5.	Estructura de la base de datos para la matriz de disponibilidad.	125
Tabla 3.6.	Descripción de las variables de entrada para el módulo colaborativo.	129
Tabla 3.7.	Ajuste modelo colaborativo para el primer escenario.	132
Tabla 3.8.	Ajuste modelo colaborativo para el segundo escenario.	132
Tabla 3.9.	Descripción de las variables de entrada para el módulo multiusuario.	137
Tabla 3.10.	Descripción de los niveles de tráfico.	155
Tabla 3.11.	Descripción de los parámetros para la generación de la nueva zona.	163
Tabla 3.12.	Métricas utilizadas en la evaluación de los modelos.	171
Tabla 3.13.	Métricas adicionales para la evaluación de los modelos predictivos.	171
Tabla 4.1.	Descripción módulos APP MultiColl-DCRN.	176
Tabla 4.2.	Variables de entrada del módulo <i>“Project Information”</i> .	178
Tabla 4.3.	Bases de datos de ocupación espectral.	179
Tabla 4.4.	Variables de salida del módulo <i>“Project Information”</i> .	181

Tabla 4.5.	Relación de usuarios “ <i>Collaborative Module</i> ”.	186
Tabla 4.6.	Número de usuarios “ <i>Collaborative Module</i> ”.	187
Tabla 4.7.	Matriz de potencia “ <i>Collaborative Module</i> ”.	187
Tabla 4.8.	Valores por defecto “ <i>Collaborative Module</i> ”.	187
Tabla 4.9.	Variables de salida “ <i>Collaborative Module</i> ”.	187
Tabla 4.10.	Relación de usuarios “ <i>Multi-user Module</i> ”.	193
Tabla 4.11.	Número de usuarios “ <i>Multi-user Module</i> ”.	193
Tabla 4.12.	Valores por defecto “ <i>Multi-user Module</i> ”.	194
Tabla 4.13.	Variables de salida “ <i>Multi-user Module</i> ”.	194
Tabla 4.14.	Datos de entrada “ <i>Parameters Module</i> ”.	199
Tabla 4.15.	Nivel de tráfico “ <i>Parameters Module</i> ”.	199
Tabla 4.16.	Tiempo “ <i>Parameters Module</i> ”.	199
Tabla 4.17.	Matriz de potencia segmentada para entrenamiento “ <i>Parameters Module</i> ”.	199
Tabla 4.18.	Matriz de potencia para evaluación “ <i>Parameters Module</i> ”.	199
Tabla 4.19.	Valores por defecto “ <i>Parameters Module</i> ”.	200
Tabla 4.20.	Variables de salida “ <i>Parameters Module</i> ”.	200
Tabla 4.21.	Vectores para el análisis multicriterio.	207
Tabla 4.22.	Tipo de formato.	216
Tabla 4.23.	Métricas de desempeño multicriterio.	216
Tabla 4.24.	Métricas de desempeño modelos de predicción.	219
Tabla 4.25.	Indicadores de predicción Markov Chain.	232
Tabla 4.26.	Equivalentes genéticos.	233
Tabla 4.27.	Botón “ <i>Run</i> ” según modelo.	247
Tabla 5.1.	Estructura de resultados del modelo implementado.	249
Tabla 5.2.	Valores relativos de las métricas para modelos no predictivos en GSM con HT.	257
Tabla 5.3.	Valores relativos de las métricas de modelos no predictivos en GSM con LT.	257
Tabla 5.4.	Valores relativos de las métricas para modelos predictivos en GSM con HT.	266
Tabla 5.5.	Valores relativos de las métricas para Modelos Predictivos en GSM con LT.	266
Tabla 5.6.	Evaluación comparativa por nivel de colaboración para HT.	279
Tabla 5.7.	Evaluación comparativa por nivel de colaboración para LT.	280
Tabla 5.8.	Evaluación comparativa global por métrica de evaluación.	280
Tabla 5.9.	Evaluación comparativa por multiusuario para HT.	366
Tabla 5.10.	Evaluación comparativa por multiusuario para LT.	367
Tabla 5.11.	Evaluación comparativa global por tipo de tráfico.	367
Tabla 5.12.	Evaluación comparativa por multiusuario para interferencia en <i>Naive Bayes</i> .	368

LISTA DE ABREVIATURAS

ABREVIATURA	TÉRMINO
AAD	Retardo promedio acumulado
AAFH	<i>Handoff</i> fallidos promedio acumulado
AAH	<i>Handoff</i> promedio acumulado
AAIH	<i>Handoff</i> con interferencia promedio acumulado
AAPH	<i>Handoff</i> perfecto promedio acumulado
AAT	<i>Throughput</i> promedio acumulado
AAUH	<i>Handoff</i> anticipado promedio acumulado
ABW	Ancho de banda promedio
AHP	<i>Analytical Hierarchical Process</i>
AP	Probabilidad de disponibilidad
AR	Autorregresivo
ARIMA	Autorregresivo integrado de media móvil
ARMA	Autorregresivo de media móvil
ASINR	Promedio de relación señal a ruido más interferencia
BE	Mejor esfuerzo
BER	Tasa de error de bit
BW	Ancho de banda
CCC	Canal de control común
CR	Radio cognitiva
CRAHN	Redes de radio cognitiva <i>ad hoc</i>
CRN	Redes de radio cognitiva
DCRN	Redes de radio cognitivas descentralizadas
ELECTRE	<i>Elimination and Choice Expressing the Reality</i>
ETA	Tiempo medio de disponibilidad

ABREVIATURA

FAHP

FFAHP

GRA

GSM

HT

ISM

LT

MA

MAC

MANET

MAS

MCDM

MEW

PU

QoE

QoS

RRSS

RSS

RSSI

RT

SAW

SINR

SNR

SU

SVM

TFN

TOPSIS

VANET

VIKOR

Wi-Fi

TÉRMINO

Fuzzy Analytical Hierarchical Process

Feedback Fuzzy Analytical Hierarchical Process

Grey Relational Analysis

Sistema global para comunicaciones móviles

Tráfico alto

Industrial, científica y médica

Tráfico bajo

Media móvil

Control de acceso al medio

Redes móviles *adhoc*

Sistemas multiagente

Toma de decisiones multicriterio

Multiplicative Exponent Weighting

Usuario primario

Calidad de experiencia

Calidad de servicio

Fuerza relativa de la señal recibida

Fuerza de la señal recibida

Indicador de fuerza de la señal recibida

Tiempo real

Simple Additive Weighting

Relación señal a ruido más interferencia

Relación señal a ruido

Usuario secundario

Máquinas de soporte vectorial

Números difusos triangulares

Technique for Order Preference by Similarity to Ideal Solution

Redes *adhoc* vehiculares

Multi-Criteria Optimization and Compromise Solution

Wireless-Fidelity

1. Introducción

El crecimiento de las aplicaciones inalámbricas plantea nuevos desafíos a los futuros sistemas de comunicación. Según CISCO, el tráfico de datos móviles ha crecido 18 veces en los últimos cinco años y se espera que el tráfico total de datos móviles crezca a 49 exabytes por mes en 2021 (CISCO, 2021; Hernández *et al.*, 2017; Hernández *et al.*, 2015d; Kumar *et al.*, 2016; Tahir *et al.*, 2017; Wang y Liu, 2011). Lo anterior, sumado al hecho de que las políticas de asignación actuales son fijas y reguladas por el estado (Cruz-Pol *et al.*, 2018), han generado que el espectro radioeléctrico presente problemas de escasez.

Sin embargo, estudios temporales y geográficos realizados por la Comisión Federal de Comunicaciones de Estados Unidos (Federal Communications Commission, 2003) muestran que gran parte del espectro de radiofrecuencia está siendo ineficientemente utilizado. Adicionalmente, mediciones realizadas en investigaciones recientes (CISCO, 2021; Tahir *et al.*, 2017) evidencian que más del 70 % del espectro está disponible (Federal Communications Commission, 2003; IEEE, 2008). Como resultado del uso ineficiente del espectro radioeléctrico existen bandas saturadas y otras poco utilizadas.

El uso ineficiente del espectro ha promovido estrategias para mitigar este problema (Abbas *et al.*, 2015). La Radio Cognitiva (CR) surge como una tecnología para resolverlo mediante acceso dinámico al espectro, caracterizada por percibir, aprender, planificar (toma de decisiones) y actuar de acuerdo con las condiciones actuales de la red.

La Administración Nacional de la Información y las Comunicaciones define la CR como un sistema que detecta su entorno electromagnético de operación y ajusta, modifica de forma dinámica y autónoma sus parámetros

para maximizar el rendimiento, reducir la interferencia y facilitar la interoperabilidad. A diferencia de las redes tradicionales, en la CR existen dos tipos de usuarios: el usuario que de forma licenciada accede a las bandas de frecuencia, denominado licenciado o Usuario Primario (PU), y el usuario no licenciado o Usuario Secundario (SU) que utiliza el espectro de forma oportunista (Akyildiz *et al.*, 2008; Akyildiz *et al.*, 2006).

El objetivo general de una Red de Radio Cognitiva (CRN) consiste en que el SU acceda de manera oportunista a un canal de frecuencia disponible en una banda licenciada, sin generar interferencia al PU (Akyildiz *et al.*, 2008; Akyildiz *et al.*, 2006; Cheng *et al.*, 2016). Lo anterior se logra a partir de un modelo de gestión denominado ciclo cognitivo, el cual es una estructura de radio que puede reconfigurarse mediante un proceso continuo de conciencia (tanto de sí mismo como del mundo exterior), percepción, razonamiento y toma de decisiones (Haykin, 2005). El ciclo cognitivo se caracteriza por cuatro funciones principales: detección del espectro, decisión de espectro, movilidad espectral y compartición de espectro.

La decisión del espectro es el núcleo de una CRN; de forma eficiente y sin causar ningún tipo de interferencia establece mediante un conjunto de técnicas el proceso para seleccionar la oportunidad espectral más adecuada de acuerdo con los requerimientos del SU y 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.

En las CRN, el proceso de toma de decisiones se desarrolla de acuerdo con la arquitectura de la red, la cual se divide en arquitectura con o sin infraestructura (Hasegawa *et al.*, 2014; Páez *et al.*, 2017). En general, las CRN basadas en infraestructura se clasifican a su vez en centralizadas o descentralizadas, mientras las CRN sin infraestructura se denominan redes distribuidas (Masonta *et al.*, 2013). De acuerdo con lo anterior, las CRN pueden operar con varios enfoques, cada uno de los cuales presenta ventajas y desventajas; su utilización radica en función de la aplicación (Darak *et al.*, 2014).

Las Redes de Radio Cognitivas Descentralizadas (DCRN) son un modelo híbrido caracterizado por utilizar en conjunto las ventajas de las redes centralizadas y distribuidas. Las arquitecturas descentralizadas cuentan con infraestructura y su implementación es sencilla, entre otras ventajas (Darak *et al.*, 2014) por lo cual, son opciones eficientes para redes de gran tamaño (Darak *et al.*, 2017).

1.1 Problema y motivación del proyecto de investigación

Durante la última década las investigaciones sobre CRN centraron sus esfuerzos en 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). Por el contrario, 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 (Martins y Andrade, 2018; Rizk *et al.*, 2018; Tripathi *et al.*, 2019). Debido a la relevancia 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 buscan 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, 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, sin embargo, como muchas áreas de la ingeniería se ven limitadas por el sistema de aplicación. En el caso de las CRN, los modelos desarrollados se esfuerzan por solucionar problemas de arquitecturas centralizadas (Deng *et al.*, 2018; Iftikhar *et al.*, 2019; Salgado *et al.*, 2016a; Tripathi *et al.*, 2019), por tanto, 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. Aunque la observación y conocimiento global de la red presenta ventajas, para sistemas a gran escala y aplicaciones en redes de seguridad pública no es la mejor opción: el aumento en los costos de medición, la complejidad del sistema, la cantidad de información que debe controlar sumado al desequilibrio y potencial caos si la estación base llega a fallar (vulnerabilidad), la convierte en una arquitectura no factible para todas las estructuras de CRN (Pankratev *et al.*, 2019). Las redes distribuidas, como por ejemplo, las redes móviles *ad hoc* o *Mobile ad hoc network* (MANET), se caracterizan por su alta movilidad, autonomía, adaptación e independencia; sus aplicaciones se encuentran en escenarios que involucran redes *ad hoc* vehiculares (VANET) (Bujari *et al.*, 2018), 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 retardo es alto (Kongsiriwattana y Gardner-Stephen, 2017), el ancho de banda (BW) es bajo al igual que su rendimiento por las frecuentes fallas de enlace (Dhamodharavadhani, 2015; Goswami, 2017). La anterior problemática puede ser solucionada si se distribuye la responsabilidad de la información en diferentes puntos de control, criterio base de las DCRN.

En las CRN, los SU deben tomar decisiones inteligentes en función de la variación del espectro y de las acciones adoptadas por otros SU. Desde 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 —debido a la externalidad negativa de la red, cuantos más SU seleccionen el mismo canal, menor será la utilidad que cada SU pueda obtener y el número de interferencias por acceso simultáneo será mayor (Abbas *et al.*, 2015)—. Para modelar la red bajo parámetros prácticos en la realidad es necesario analizar el acceso de múltiples usuarios de forma simultánea.

El proceso de toma de decisiones entre usuarios que interactúan en un mismo entorno (multiusuario) es un problema de optimización multiobjetivo

que generalmente es difícil de analizar y resolver con los modelos clásicos de optimización (Kaur *et al.*, 2018a; 2018b). Para redes centralizadas y distribuidas (redes *ad hoc*), se encuentran metodologías con buenos resultados (Masonta *et al.*, 2013; Roy *et al.*, 2017; Yu y Xue, 2018); sin embargo, para las DCRN son pocos los trabajos de investigación realizados (Joda y Zorzi, 2015; Rizk *et al.*, 2018) y las propuestas disponibles suponen que no existe externalidad de red, es decir, que la recompensa de un SU no se ve afectada por las acciones de otros SU. Por tanto, para obtener un modelo de red más práctico en la realidad, es necesario tener en cuenta cómo afectan las decisiones tomadas por un SU, a los demás usuarios de la red.

De acuerdo con lo relevante del proceso de toma de decisiones, los múltiples inconvenientes de las arquitecturas centralizadas y distribuidas (que pueden ser solucionados al descentralizar la responsabilidad en diferentes puntos de control) y la necesidad de incluir el efecto de las decisiones de los usuarios sobre la utilidad de los otros (para poder obtener validaciones reales más útiles), este proyecto tiene como desafío dotar los nodos de una red descentralizada con la capacidad de aprender del entorno, proponiendo estrategias que permita a los SU tomar decisiones e intercambiar información de forma cooperativa o competitiva. De acuerdo con cada uno de los elementos y problemas expuestos, la pregunta de investigación planteada es ¿cómo y en qué medida se puede reducir la tasa de *handoff* espectral en redes de radio cognitiva descentralizadas con un enfoque multiusuario?

1.2 Justificación

A medida que aumenta la demanda de tecnologías inalámbricas las políticas tradicionales de regulación del espectro van quedando obsoletas. El número de dispositivos conectados a internet ha aumentado en los últimos años y se proyecta que superará los 20 mil millones de dispositivos para 2020 (Boorstin, 2016; CISCO, 2021). Adicionalmente, el uso de bandas de frecuencia como ISM (industrial, científica y médica) y las asignadas a comunicaciones móviles han experimentado una fuerte demanda de servicios, como unidades remotas, internet de las cosas y sistemas de audio y video (Martins y Andrade, 2018).

Las CRN surgieron como una solución a los problemas de asignación fija y escasez de espectro a partir del uso eficiente del recurso espectral. La decisión espectral es una función clave en los sistemas cognitivos dado que proporciona herramientas para seleccionar la oportunidad espectral (canal de frecuencia) más adecuada de acuerdo con los requerimientos del usuario, las restricciones del ambiente de radio y los efectos producidos por las acciones adoptadas por otros usuarios de la red.

El proceso de toma de decisiones se desarrolla de acuerdo con la arquitectura de implementación —centralizada, distribuida y descentralizada—. Las redes descentralizadas surgen como un modelo híbrido entre redes centralizadas y distribuidas. A pequeña escala se comportan como una arquitectura centralizada al formar redes individuales con infraestructura; a gran escala generan una red distribuida, conectando a través de enlaces adicionales las diferentes redes individuales. Estas características permiten configurar una red con infraestructura segura y de fácil implementación (Darak *et al.*, 2017; Pankratev *et al.*, 2019). En general, la red descentralizada es una opción eficiente para aplicaciones de gran tamaño y, además, es la mejor alternativa para redes de seguridad pública, servicios de redes sociales y redes de sensores inteligentes, entre otras (Darak *et al.*, 2017; Pankratev *et al.*, 2019).

Actualmente las investigaciones se enfocan en modelos con un único SU, lo cual no resulta práctico en la realidad. Por tal razón, se hace imperativo involucrar un enfoque multiusuario tanto en el diseño como en la evaluación y validación de esta propuesta.

1.3 Objetivos

El objetivo general del proyecto de investigación es desarrollar un modelo de decisión espectral multiusuario para mejorar el desempeño de redes de radio cognitiva descentralizadas, a partir de los siguientes objetivos específicos:

1. Desarrollar un ambiente de simulación para redes de radio cognitiva descentralizadas basado en datos reales de ocupación espectral.
2. Diseñar un modelo de decisión espectral multiusuario que integre las características y el comportamiento de las redes de radio cognitiva descentralizadas.

3. Validar el modelo de decisión espectral multiusuario propuesto por medio de simulaciones que integren las características de las redes de radio cognitiva descentralizadas y datos reales de ocupación espectral, para confrontarlo con modelos actuales.

1.4 Alcance y limitaciones

Son diversas las características; fenómenos, indicadores o métricas que se pueden analizar en el proceso de toma de decisiones para DCRN. El análisis particular de algunas de ellas corresponde a tesis de doctorado, por tanto, a continuación, describimos las principales limitaciones y alcances del presente proyecto de investigación.

Toma de decisiones cooperativa

- La decisión sobre el espectro implica tres funciones principales: caracterización, selección y reconfiguración. Nuestra investigación está enfocada en realizar y evaluar un modelo para selección del espectro. Caracterización y reconfiguración son temas para otros proyectos.
- Los criterios en el proceso de toma de decisiones corresponden a indicadores asociados a Calidad de Servicio (QoS), los parámetros iniciales serán: Probabilidad de disponibilidad (AP), Tiempo medio de disponibilidad (ETA), Relación señal a ruido más interferencia (SINR) y BW (Ancho de banda). Posteriormente, se analizará si se incluyen otros parámetros.
- Tuvimos en cuenta modelos de tipo cooperativo (colaborativo) sin dejar de considerar, al menos, una de las propuestas de tipo no cooperativo.
- La colaboración también puede llegar a darse entre los algoritmos utilizados dentro del modelo.

Modelos multiusuario

- Con el objetivo de mejorar el algoritmo de toma de decisiones, la información a los datos de ocupación espectral registrada por cada SU durante los últimos k períodos.

- El número de usuarios incluidos dentro del ambiente de simulación estará en función de las capacidades de cómputo de los equipos con los que se cuenten para la investigación.

Características de la red y métricas de desempeño

- El número de nodos de la red propuesta se determinará a partir del nivel de procesamiento del equipo de cómputo con el que se cuente.
- No se cuenta con una red descentralizada para la medición de datos, por tanto, y teniendo en cuenta que a pequeña escala un modelo descentralizado se comporta como una arquitectura centralizada, la información será tomada de una red centralizada, se caracterizarán los nodos individuales, y posteriormente se conectarán entre sí.
- Solo se utilizará en el ambiente de simulación redes con infraestructura. Esta investigación no involucrará en su análisis estructuras de tipo distribuido como las redes *ad hoc*.
- Los canales de frecuencia se dividirán en n canales con el mismo BW.
- Se espera mejorar un número considerable de problemas para el proceso de toma de decisiones en DCRN; sin embargo, por la magnitud, complejidad del proyecto y por el requerimiento computacional exponencial que se requiere, esta investigación se compromete a mejorar el indicador de al menos una característica relevante en el desempeño de la red.
- La metodología propuesta para el análisis de toma de decisiones no contempla modelos de propagación. Se asume que la distancia entre SU es lo suficientemente cercana para que el desvanecimiento no afecte la señal.
- La metodología propuesta para el análisis de toma de decisiones no contempla enrutamiento.
- El análisis de pérdida de paquetes se tendrá en cuenta para los *time step* en donde el algoritmo no encuentra un canal objetivo para transmitir la información dentro del total de canales. No corresponde a un indicador del proceso de toma de decisiones, sin embargo, si esta característica se presenta frecuentemente, se incluirá una métrica que la describa.

- Para analizar el desempeño del modelo de toma de decisiones implementado, se utilizarán parámetros asociados a la QoS. La evaluación de calidad de experiencia (QoE) aunque es relevante, hace parte de una propuesta de trabajo futuro.
- Inicialmente se establece como métricas de desempeño parámetros de QoS tales como: número de *handoffs*, número de *handoffs* fallidos, retardo promedio, ancho de banda promedio y *throughput* promedio.

Campaña de medición

- Debido a la magnitud y complejidad de implementar una red piloto con equipos de CR, la validación del modelo de decisión espectral multiusuario propuesto se realizará por medio de simulaciones con datos de ocupación espectral experimentales que permitan emular el comportamiento real del PU, y su posterior confrontación con otras técnicas de decisión espectral. A partir de una metodología que considere zonas con alto nivel de demanda tráfico alto (HT) y con bajo nivel de demanda tráfico bajo (LT), para la ciudad de Bogotá.
- Las técnicas de detección de espectro filtro coincidente y detección cicloestacionario son, teóricamente, mejores que la de detección de energía, sin embargo, necesitan un conocimiento previo del PU y de la red, lo que significa mayor complejidad y aumento en la carga computacional. Dado que ésta última no contempla conocimiento previo del PU, es fácil de implementar por sus bajos costos computacionales, y baja complejidad. Para el presente proyecto de investigación se asume que la técnica de detección de energía entrega resultados efectivos; contemplar otra técnica o mejorarla sería otra propuesta de trabajo, como se identifica en las investigaciones actuales.
- Las bandas de frecuencia seleccionadas corresponden a la tecnología GSM, Wi-Fi e ISM, dado que resultan más sencillas de trabajar con la técnica de detección de energía.

Estructura de programación

- La simulación del modelo de toma de decisiones se desarrollará en uno de los siguientes softwares: Matlab, NS3 u OPNET, que será seleccionado

a partir de un análisis comparativo que determine cual se ajusta mejor a los requerimientos de la estrategia inteligente desarrollada.

1.5 Modelo propuesto

La figura 1.1 presenta un modelo de asignación espectral multiusuario para redes de radio cognitiva descentralizadas conformado por módulos colaborativo; multiusuario, predictivo y aprendizaje profundo (*Deep Learning*).

Para la asignación del espectro utilizando *Deep Learning* se requiere analizar la información de entrada; la cantidad de usuarios y sensibilidad de la aplicación que se está ejecutando. El módulo colaborativo es el encargado de gestionar la información de entrada. Si hay múltiples SU se utiliza el módulo multiusuario; si la aplicación que se está ejecutando tiene una sensibilidad alta al retardo se implementa el módulo predictivo. Si no hay múltiples usuarios y tampoco se presenta alta sensibilidad al retardo, la comunicación se realiza de forma directa entre el módulo colaborativo y el módulo aprendizaje profundo.

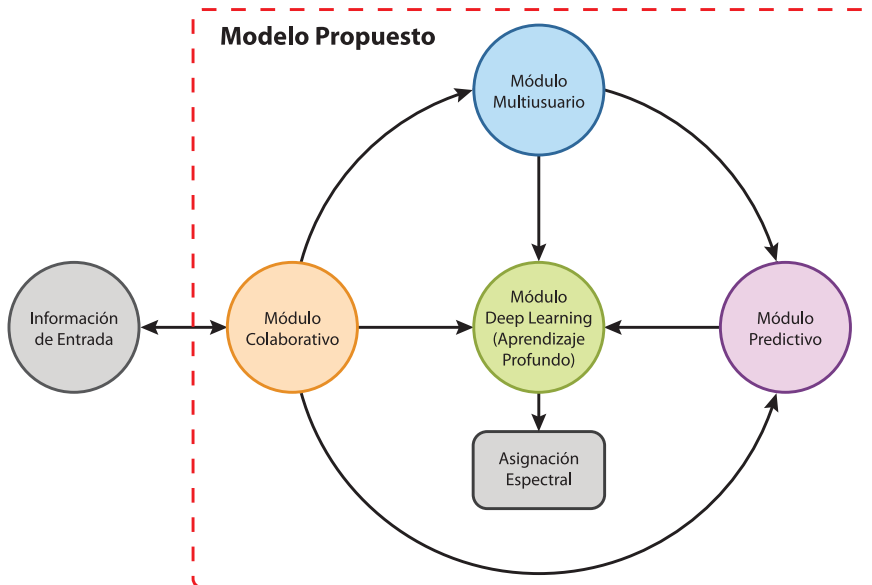


Figura 1.1. Modelo propuesto.

Fuente: elaboración propia.

1.6 Metodología

El desarrollo del presente proyecto de investigación se realizó secuencialmente por medio 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 uno de los modelos de interés en el desempeño de la movilidad espectral. El tercero, de tipo predictivo, buscó aplicar soluciones de otras situaciones al contexto de interés, y finalmente, un cuarto tipo de enfoque experimental permitió la realización de pruebas de comprobación y validez a los desarrollos efectuados (Hernández-Sampieri *et al.*, 2006).

La metodología de la presente investigación se estructuró de la siguiente forma. Primero, se realizó un estudio del estado del arte que permitió identificar los aspectos más importantes para el tema de asignación espectral multiusuario en las DCRN, así como sus algoritmos más relevantes en la literatura actual. Con base en el análisis de la información anterior se diseñó una metodología para la evaluación del desempeño de la movilidad en redes móviles de CR. Luego, 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. A continuación, se realizó procesamiento de los datos capturados para construir bases de datos con información organizada sobre el comportamiento del PU y 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)—. Posteriormente, se determinaron criterios de decisión para la selección de las mejores oportunidades espectrales y se calcularon sus valores históricos a partir de la información de las bases de datos, complementando las mismas. Consecuentemente, se seleccionaron y desarrollaron los algoritmos de asignación espectral multiusuario más relevantes en la literatura actual. Luego, se diseñaron y desarrollaron varios algoritmos para cada uno de los módulos del modelo de asignación espectral multiusuario propuesto.

Con base en los resultados de desempeño de los algoritmos se construyó el modelo de asignación espectral multiusuario propuesto. Gracias al análisis del estado del arte de las CRN se diseñaron ocho métricas de evaluación

para evaluar el desempeño de los algoritmos propuestos en esta investigación, así como los seleccionados de la literatura actual, y se propusieron varios escenarios de evaluación. Luego, se diseñó y desarrolló un simulador que permite evaluar cuantitativamente el desempeño de los algoritmos, considerando el comportamiento real del PU. Con los resultados obtenidos a partir de los simuladores se realizó una evaluación comparativa de desempeño en cada una de las métricas de evaluación. Por último, se realizaron ajustes y modificaciones al modelo propuesto con base en el análisis comparativo.

1.7 Contribuciones

- Diseño y desarrollo de un modelo de asignación espectral multiusuario para mejorar el desempeño de las redes de radio cognitiva descentralizadas.
- Diseño y desarrollo de un módulo colaborativo para el intercambio de información entre SU con el objetivo de realizar una asignación espectral multiusuario inteligente.
- Diseño y desarrollo de un módulo multiusuario para acceso simultáneo de varios SU a las oportunidades espectrales.
- Diseño y desarrollo de un módulo predictivo que reduce el nivel de interferencia entre los SU y los PU.
- 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 desarrollados en una red GSM.
- Evaluación y validación de los algoritmos desarrollados, con dos niveles de tráfico de PU: HT y LT.
- Evaluación y validación de los algoritmos desarrollados, en cuatro diferentes escenarios de evaluación: GSM-LT-Convencional, GSM-HT-Convencional, GSM-LT-Real, GSM-HT-Real.
- Evaluación y validación de los algoritmos desarrollados bajo ocho métricas de evaluación:
- Retardo promedio acumulado (AAD)

- *Handoff* fallidos promedio acumulado (AAFH)
- *Handoff* promedio acumulado (AAH)
- *Handoff* con interferencia promedio acumulado (AAIH)
- *Handoff* perfecto promedio acumulado (AAPH)
- *Throughput* promedio acumulado (AAT)
- *Handoff* anticipado promedio acumulado (AAUH)
- Ancho de banda promedio (ABW)
- Determinación de cuatro criterios de decisión seleccionados cuidadosamente para elegir la mejor oportunidad espectral. Todos los algoritmos desarrollados trabajaron con los mismos cuatro criterios. Cada criterio de decisión es 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 asignación espectral multiusuario para DCRN, basada en datos de ocupación espectral reales, que permite modificar varios parámetros de interés para analizar el comportamiento y desempeño de cada algoritmo bajo diferentes situaciones, donde destaca el nivel de colaboración y número de SU simultáneos, denominada “MultiColl-DCRN”.

1.8 Financiamiento

El presente libro es producto de los resultados alcanzados con el proyecto de investigación “Modelo inteligente de asignación espectral con enfoque multiusuario para mejorar la eficiencia y desempeño en redes de radio cognitiva descentralizadas”, auspiciado por el Centro de Investigaciones y Desarrollo Científico de la Universidad Distrital Francisco José de Caldas.

1.9 Organización del libro

A partir de este punto el lector encontrará, en el segundo capítulo, los fundamentos teóricos de la CR; la decisión espectral, los algoritmos de asignación espectral, acceso multiusuario, estructuras colaborativas y una revisión de la literatura actual sobre modelos de asignación espectral multiusuarios

colaborativos para DCRN. El tercer capítulo describe la metodología desarrollada; los equipos, la red, el tratamiento de los datos, el modelo propuesto, los algoritmos seleccionados y la metodología de evaluación. El capítulo cuatro describe en detalle el software de simulación desarrollado. La quinta sección presenta los resultados: los módulos no predictivo, predictivo, colaborativo y multiusuario; la evaluación integral y el modelo propuesto definitivo. El sexto capítulo aborda la discusión de los resultados. Finalmente, la última sección, expone conclusiones.

2. Fundamentos teóricos

El desarrollo de este proyecto de investigación está totalmente enfocado en la radio cognitiva. Por tal razón, el presente capítulo se subdivide en cinco secciones. La primera sección aborda los fundamentos de la CR; la segunda, se enfoca en los aspectos teóricos de la decisión espectral, la tercera, presenta los algoritmos más relevantes de la asignación espectral. La cuarta sección presenta una revisión de la literatura actual sobre modelos de decisión espectral para CRN, y finalmente, la quinta, muestra algunas herramientas de simulación de *handoff* espectral.

2.1 Radio cognitiva

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

Según estudios realizados por la Comisión Federal de Comunicaciones de Estados Unidos (Federal Communications Commission, 2003) se ha evidenciado que gran parte del espectro de radiofrecuencia está siendo ineficazmente utilizado. Basado en variaciones temporales y geográficas, la utilización del espectro asignado es ineficiente (Federal Communications Commission, 2003; IEEE Standards Coordinating Committee 41 on Dynamic Spectrum, 2008). Incluso mediciones más actuales muestran que más del 70% del espectro no está siendo utilizado (Hoven *et al.*, 2005; Pedraza *et al.*, 2016).

La utilización ineficiente y esporádica del espectro, junto a su incremento de demanda, han hecho que se degrade la QoS en varias redes y aplicaciones inalámbricas, como las comunicaciones móviles, lo cual ha motivado el desarrollo de investigaciones recientes que han encontrado solución al problema: la tecnología clave que permite materializar las técnicas de acceso dinámico al espectro es la radio cognitiva (Akyildiz *et al.*, 2008; Tsiropoulos *et al.*, 2016).

El concepto fue creado por Joseph Mitola III en 1999: “punto en el cual las *Personal Digital Assistant* 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 y Maguire, 1999). Sin embargo, varias entidades importantes han dado su punto de vista al respecto. Según la Administración Nacional de la Información y las Comunicaciones, 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 como: maximizar el rendimiento, reducir la interferencia o facilitar la interoperabilidad”; de acuerdo con la Unión Internacional de Telecomunicaciones, “es 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”. Según el Instituto de Ingenieros Eléctricos y Electrónicos (IEEE) “es un tipo de radio que puede detectar de forma autónoma y razonar sobre su entorno y adaptarse acorde a este” (IEEE Standards Coordinating Committee 41 on Dynamic Spectrum, 2008). Según la Comisión Federal de Comunicaciones, CR es una radio que “puede cambiar los parámetros del transmisor basado en la interacción con su entorno” (Federal Communications Commission, 2003).

La radio cognitiva tiene la capacidad de proveer un gran ancho de banda a usuarios móviles a través de arquitecturas inalámbricas heterogéneas, aumentando significativamente la eficiencia espectral, debido a que permite que usuarios secundarios compartan el espectro con usuarios primarios

(Akyildiz *et al.*, 2008) a partir de la oportunidad como se muestra en la figura 2.1; es decir, utilizan las porciones del espectro que no están siendo usadas en ese momento (Delgado y Rodríguez, 2016; Ozger y Akan, 2016).

La figura 2.1 describe el concepto de oportunidad espectral a través de una gráfica en tres dimensiones cuyos ejes son potencia, frecuencia y tiempo. Cada bloque gris de la figura es un PU haciendo uso de una porción del espectro de frecuencia dado por el eje de frecuencia, a un nivel de potencia dado por el eje de potencia, y durante un determinado período dado por el eje de tiempo. Sin embargo, existen porciones del espectro de frecuencia que no son utilizadas durante determinado intervalo de tiempo, dichos espacios son denominados oportunidades espectrales, que pueden ser aprovechados por los SU (Ozger y Akan, 2016).




Figura 2.1. Concepto de oportunidades espectrales.

Fuente: adaptada de Akyildiz *et al.* (2009).

2.1.1 Características de la radio cognitiva

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

2.1.1.1 Capacidad cognitiva

Tecnología capaz de capturar la información de su entorno de radiofrecuencia para identificar los segmentos del espectro que no están siendo utilizados,

seleccionar el mejor espectro posible y definir los parámetros de operación más adecuados con el objetivo de evitar la interferencia con otros usuarios (Pedraza *et al.*, 2016).

2.1.1.2 Reconfigurabilidad

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

2.1.2 Gestión de 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 2.2). El modelo se caracteriza por cuatro funciones principales: detección, decisión, movilidad y compartición de espectro. En la etapa de detección los SU monitorean de manera continua el espectro para poder determinar las oportunidades espectrales; luego, con la función decisión de espectro, los SU deben seleccionar la oportunidad espectral más adecuada de acuerdo con sus requerimientos de QoS. En la tercera función, movilidad de espectro, el SU puede tener que realizar el cambio de su frecuencia actual para continuar su comunicación en otro canal, debido a causas tales como: llegada de un PU, no disponibilidad del canal; interferencia al PU, degradación de la calidad del canal, variación del tráfico y movimiento del SU. Por último, en la función de 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).

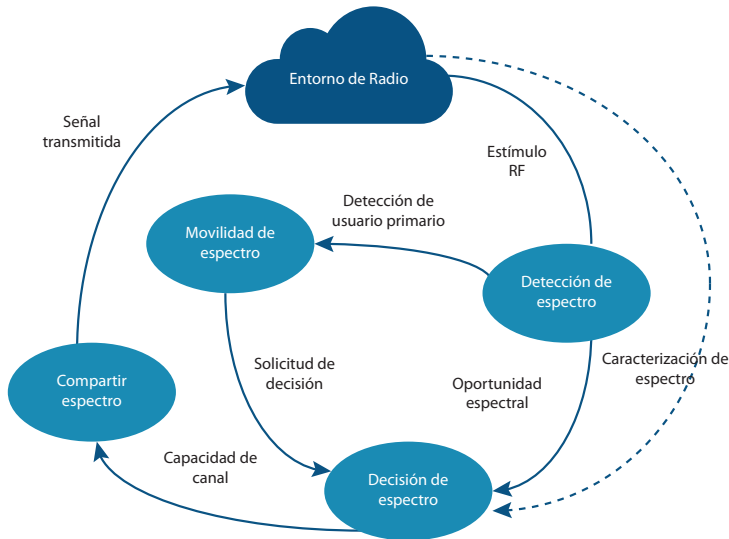


Figura 2.2. Ciclo cognitivo.

Fuente: adaptada de Akyildiz *et al.* (2009).

2.1.2.1 Monitorización de espectro

La detección del espectro es la función encargada de identificar oportunidades espectrales. Los SU monitorean el espectro capturando información que permita determinar disponibilidad de canales. Actualmente existen varias técnicas para monitorizar el espectro, las cuales se clasifican como se muestra en la figura 2.3, siendo detección de energía la más básica de ellas (Páez *et al.*, 2017).

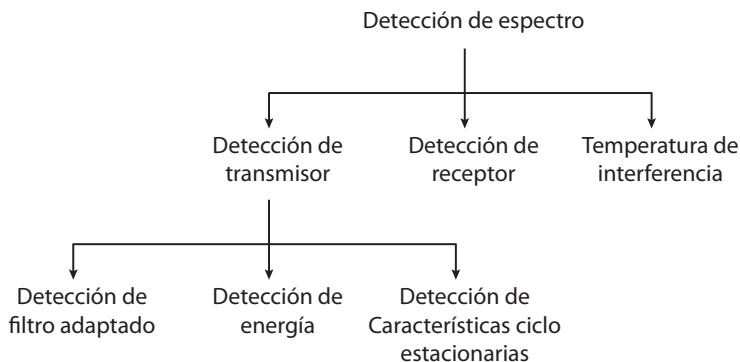


Figura 2.3. Clasificación de las técnicas de detección de espectro.

Fuente: adaptada de Akyildiz *et al.* (2009).

2.1.2.2 Decisión de espectro

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

2.1.2.3 Compartición de espectro

Debido a que varios SU pueden intentar acceder al espectro, la función de compartición proporciona la capacidad de distribuir 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 clasifican en función de la arquitectura —centralizada, descentralizada y distribuida—; de acuerdo con el comportamiento del acceso al medio —cooperativo o no cooperativo— y por la forma como se accede al medio —superposición o subyacente— (Lertsinsruttavee y Malouch, 2016; Pedraza *et al.*, 2016).

2.1.2.4 Movilidad de espectro

La movilidad espectral da lugar al concepto de *handoff* espectral, mediante el cual, el SU cambia de una oportunidad espectral a otra. Durante el movimiento es inevitable que la comunicación se rompa temporalmente, por tanto, 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, determinando cuando y donde realizar un *handoff* espectral mediante un conjunto de reglas (Hernández *et al.*, 2016a; López *et al.*, 2015; Oyewobi y Hancke, 2017; Páez *et al.*, 2017)

2.1.3 Arquitectura de la radio cognitiva

El proceso de toma de decisiones en la CRN se clasifica según su arquitectura, de acuerdo con la figura 2.4.




Figura 2.4. Arquitectura de una CRN.

Fuente: adaptado de Masonta *et al.* (2013) y Pedraza *et al.* (2016).

2.1.3.1 Centralizada

En las arquitecturas centralizadas — figura 2.5a — existe un coordinador llamado entidad central o estación base que se encarga de acomodar, asignar y tomar las decisiones de los canales y además, almacena y procesa la información entregada por los PU y SU (Ahmed *et al.*, 2016). Su vulnerabilidad radica en 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 evite interferencias. En caso de que la selección de canal no sea suficiente para eludirlos, se implementa la adaptación de potencia. Las evaluaciones de las alternativas anteriores revelan que el CCC mejora el rendimiento entre 35 % y 160 % a través de la frecuencia como de la adaptación de potencia (Akyildiz *et al.*, 2006; Tsiropoulos *et al.*, 2016).

2.1.3.2 Distribuida

Las redes distribuidas forman una malla (figura 2.5c) donde 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 donde no es viable la implementación

de infraestructura (Brik *et al.*, 2005; Cao y Zheng, 2005; Krishnamurthy *et al.*, 2005; Pedraza *et al.*, 2016; Salgado *et al.*, 2016b). La desventaja de este modelo es su baja seguridad. Los protocolos distribuidos que no requieren infraestructura son ampliamente utilizados en redes de radio cognitiva *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 —es decir, una estación base compite con su interferente estación base (BS) de acuerdo con los requisitos de QoS de los usuarios para asignar una porción del espectro. De forma similar al protocolo CCC, los canales de control y datos se separan— (Akyildiz *et al.*, 2006; Tsiropoulos *et al.*, 2016).

2.1.3.3 Descentralizada

Las redes descentralizadas son arquitecturas formadas por un conjunto de redes centralizadas conectadas por enlaces adicionales que crean una malla. Cuentan con una infraestructura de implementación sencilla; tienen buenos niveles de seguridad, ausencia de sobrecarga de comunicación, menor retardo, baja complejidad, entre otras (Darak *et al.*, 2014). Su estructura incorpora atributos de redes centralizadas y distribuidas. El enfoque descentralizado es una opción eficiente para redes de gran tamaño, además, es la mejor alternativa para redes de seguridad pública y servicios de redes sociales (Darak *et al.*, 2017). La figura 2.5b presenta la jerarquía de una red descentralizada.




Figura 2.5. Arquitectura de una red. a. Centralizada; b. Descentralizada; c. Distribuida.

Fuente: adaptado de Baran (1964) y Pankratev *et al.* (2019).

2.1.4 Aplicaciones de la radio cognitiva

Los resultados de esta investigación pueden impactar el campo de la información y las comunicaciones en la región, no solo Bogotá D.C. sino Colombia y el mundo entero. Un ejemplo claro son las redes *Mesh*, las cuales han emergido como una tecnología con relación beneficio-costo muy buena; 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. Con las ventajas de la CR es posible habilitar el acceso a un mayor segmento del espectro; por otro lado, una red *backbone mesh* puede incrementar el área de cobertura basada en puntos de acceso cognitivos (Akyildiz *et al.*, 2006).

Un desastre natural podría deshabilitar temporalmente o incluso destruir la infraestructura de comunicaciones, por lo que sería necesario establecer redes de emergencia que requieren una gran cantidad de espectro para poder manejar el volumen de tráfico de video, voz y datos. 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 sus ventajas (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 su frecuencia, BW, modulación, codificación, adaptándose al ambiente de radio variable del campo de batalla (Akyildiz *et al.*, 2006).

En suma, las características de reconfigurabilidad dinámica de cada uno de los parámetros de operación en una CRN puede garantizar integridad de información, interoperabilidad, fiabilidad, flexibilidad; redundancia, escalabilidad, seguridad, eficiencia y acceso en todo tiempo y espacio, beneficiando significativamente el manejo de la información y las comunicaciones en Colombia.

2.1.5 Desafíos y futuras investigaciones en radio cognitiva

La radio cognitiva abarca aspectos que van desde la monitorización del espectro hasta las decisiones de movilidad en este, teniendo en cuenta esquemas de acceso al medio y tipo de redes en las cuales interactúa.

2.1.5.1 Monitorización del espectro

El proceso de monitorización no puede realizarse al mismo tiempo en que se envía información entre SU, por consiguiente, si hay que monitorear los usuarios deben detener las transmisiones, afectando la eficiencia del espectro. Con base en esto, sería deseable desarrollar algoritmos de monitorización que reduzcan su tiempo mientras mejoran la precisión en el proceso de detección de oportunidades espectrales.

2.1.5.2 Espectro compartido

En trabajos realizados en CR se hacen suposiciones como 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 de manera fácil. Sin embargo, esta suposición no siempre es cierta para algunas CRN (Lertsinsrubtavee y Malouch, 2016).

2.1.5.3 Procesos de aprendizaje

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

2.1.5.4 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 adecuan al estándar. Por ejemplo, los esquemas MAC distribuidos para CRAHN no están del todo cubiertas.

2.2 Decisión espectral

Después de realizar la detección del espectro los SU deben decidir cuál es la mejor oportunidad espectral. Este proceso debe satisfacer los requerimientos

de QoS e 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 parámetros de QoS tales como: latencia, *throughput*, confiabilidad, señalización, interferencia, eficiencia energética, ancho de banda, SINR y tasa de error (Hernández *et al.*, 2016a; López *et al.*, 2015; Oyewobi y Hancke, 2017; Páez *et al.*, 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, permitiendo a los SU generar una secuencia de acciones que conducirá 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 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: (1) caracterización del espectro, (2) selección del espectro y (3) reconfiguración. Como se muestra en la figura 2.6, 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. A partir de la decisión tomada el SU reconfigura sus parámetros de transmisión y continúa el envío de datos (López, 2017; Masonta *et al.*, 2013).

A continuación presentamos la descripción de las funciones: caracterización del espectro, decisión de espectro (selección de espectro) y reconfiguración.

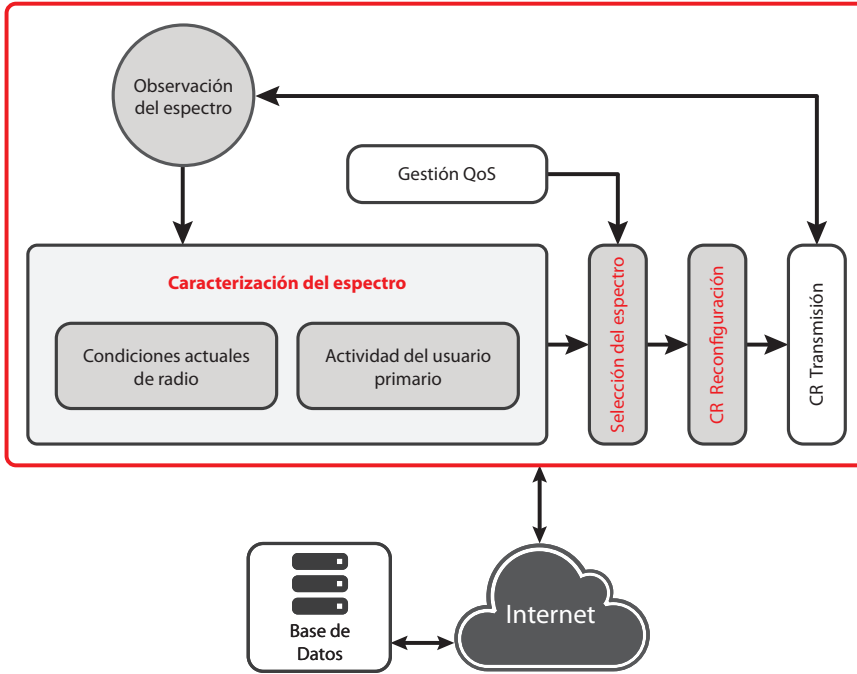


Figura 2.6. Marco de decisión del espectro.

Fuente: López (2017).

2.2.1 Caracterización del espectro

Para determinar la banda espectral más adecuada, en primer lugar, y 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, interferencia y número de usuarios actuales. Adicionalmente, para realizar un correcto proceso de toma de decisiones los SU deben observar la disponibilidad de espectro heterogéneo que varía con el tiempo y el espacio. La disponibilidad heterogénea hace referencia a la disponibilidad de los huecos espectrales que fluctúan con el tiempo y la ubicación. En general, la caracterización del espectro debe incluir tanto las condiciones actuales del entorno de radio frecuencia como el modelo de 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, tasa de error del canal, ubicación del abonado y pérdida de trayecto.

La caracterización del espectro determina y describe el comportamiento de los canales permitiendo distinguir unos de otros, de acuerdo con su tráfico, ocupación y configuración. Al seleccionar un canal es importante tener en cuenta que dentro de sus características de transmisión existen parámetros que influyen en su comportamiento. 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. Algunas características son (Masonta *et al.*, 2013):

- Identificar el canal.
- Capacidad del canal.
- Retardo de conmutación de espectro.
- Interferencia del canal.
- Canal de tiempo.
- Tasa de error del canal.
- Posición del abonado.

2.2.1.1 Identificar el 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, donde 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 *et al.*, 2011).

2.2.1.2 Capacidad del canal

Cada banda del espectro en un sistema de multiplexación por división de frecuencia ortogonal tiene un ancho de banda diferente, el cual está compuesto por varias subportadoras que estiman una capacidad normalizada del canal. Las investigaciones se han enfocado en estimar la capacidad de BW

mediante el estudio de otros parámetros como el nivel de interferencia, tasa de errores y propagación (Lee y Akyildiz, 2011).

Se ha demostrado que el método tradicional de estimación de 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, haciendo que el SU requiera analizar recursos cuando el BW del PU sea menor que el requerido por el SU. Para el modelo propuesto, el BW no es utilizado.

2.2.1.3 Retardo de conmutación de espectro

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

El desafío radica en reducir el retardo de detección del canal; el tiempo que tarda el SU en configurar sus parámetros de transmisión y disminuir el tiempo que gasta el SU en acceder al nuevo canal, con el fin de mejorar el rendimiento de retardo en CRN.

2.2.1.4 Interferencia del canal

La interferencia es la mayor consecuencia generada en el proceso de interacción entre usuarios en una red. Al acceder al espectro, un SU puede afectar la señal alterando los servicios de PU, por 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 específica, donde es importante que el SU no transmita mientras haya presencia de un PU.

2.2.1.5 Tiempo de retención del canal

Esta característica 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 SU permitiendo 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 tiempos en que el canal permanece libre, luego se definen bloques de tiempo que serán recursos libres que pueden ser utilizados por los SU con bloques de similar tamaño, para finalmente, acceder al canal que más se ajuste con las mediciones realizadas, reduciendo interferencias en la interacción (Akyildiz *et al.*, 2006).

2.2.1.6 Tasa de error de canal

Este factor está directamente relacionado con el nivel de interferencia, 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 (Höyhty *et al.*, 2008).

2.2.1.7 Localización del abonado

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

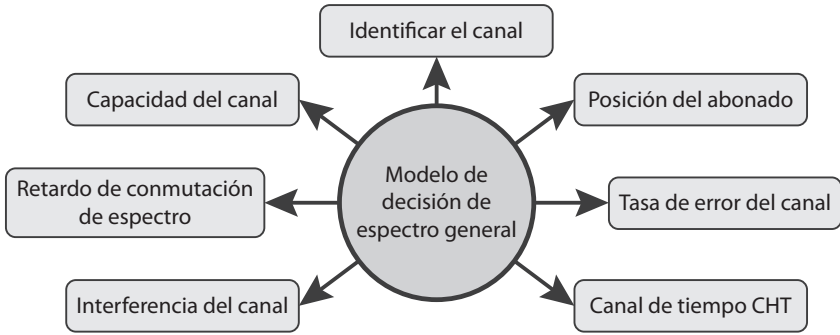


Figura 2.7. Caracterización del ambiente de radio.

Fuente: adaptada de Masonta *et al.* (2013).

La figura 2.7 sintetiza los componentes que debe tener en cuenta un modelo de decisión de espectro para cumplir con el objetivo de acceder al espectro oportunamente. Aunque diseñar un modelo que evalúe todas las características puede ser robusto, complejo y computacionalmente poco eficaz, si es misión del ingeniero idear un modelo que utilice las características principales y necesarias, y que también reduzca su tiempo de ejecución.

2.2.2 Selección – decisión del espectro

La decisión del espectro o proceso de toma de decisiones determina cual es el mejor canal de frecuencia entre los disponibles, según los requisitos de QoS 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; Páez *et al.*, 2017; Pedraza *et al.*, 2016; Ramzan *et al.*, 2017).

2.2.3 Reconfiguración CR

En las redes inalámbricas tradicionales los terminales de radio están configurados estáticamente para operar sobre canales de frecuencia predefinidos con parámetros y características predefinidas del transceptor. Las CR 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, 2017).

2.2.4 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 analizará el enfoque con infraestructura frente al enfoque *ad hoc*; el enfoque centralizado frente al distribuido, el enfoque de asignación multicanal frente al de asignación única, inclusión o no del PU, inclusión o no del SU, CCC dedicado o dinámico, y segmentación o agrupamiento.

2.2.4.1 Infraestructura vs *ad hoc*

De acuerdo con la arquitectura de la red, las CRN pueden clasificarse en redes basadas en infraestructura o CRAHN (Ahmed *et al.*, 2016; Akyildiz *et al.*, 2006). Las CRN basadas en infraestructura tienen una entidad de red central similar a una estación base en redes celulares o un punto de acceso en las redes inalámbricas de área local. Por otro lado, las CRAHN no tienen ninguna infraestructura, por tanto, un SU se comunica con otro SU a través de una conexión *ad hoc*, tanto en bandas espectrales 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 con el fin de maximizar los parámetros de comunicación, como el *throughput*, el BW, SINR, el balanceo de carga, entre otros, 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 en observaciones locales únicamente, lo cual les impide realizar un uso eficiente de los recursos de la red entera. Para compensar el caso anterior, los SU pueden hacer uso de esquemas de colaboración, en los cuales cada SU intercambia su información de observación del espectro local, permitiéndoles tener un conocimiento aproximado de la red completa (Akyildiz *et al.*, 2009).

2.2.4.2 Centralizado vs distribuido

Si las CRN cuentan con infraestructura, pueden operar tanto con un enfoque centralizado como distribuido. En el primero existe una entidad encargada de coordinar las funciones necesarias para la decisión y asignación del canal de frecuencia durante una decisión espectral conocida como estación base central que 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 estación base central 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 a la proporcionada por los SU actualiza dinámicamente la base de datos central. La estación base central procesa periódicamente esta información y calcula valores estimados de algunos parámetros de interés del espectro como la AP, la SINR, el ETA y BW de los canales, entre otros, los cuales permiten tomar decisiones más acertadas para la asignación espectral. Lo anterior libera a los SU de la carga computacional requerida para ejecutar un algoritmo robusto de asignación espectral.

La principal ventaja en el enfoque centralizado es la observación y conocimiento global de la red lo cual permite maximizar el *throughput*, minimizar la interferencia entre los SU, 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 estación base central y los SU. Además, si la estación base central llegara a fallar se perdería el control sobre la asignación espectral creando desequilibrio y un potencial caos en el sistema. (Tragos *et al.*, 2013).

En el enfoque distribuido no existe una estación base central responsable de coordinar la asignación espectral a los SU. Por tanto, los SU toman decisiones por ellos mismos o de forma colaborativa con otros SU vecinos, a través de intercambio de información y medidas dentro de un rango determinado (i.e. 2-3 saltos). Lo anterior hace que el enfoque distribuido sea

más flexible y eficiente que el centralizado ya que puede adaptarse rápidamente a los posibles cambios o variaciones del ambiente de radio o de la red; solamente los SU en el área afectada tendrán que hacer modificaciones e intercambiar información. Otra ventaja significativa del enfoque distribuido es la baja información de señalización requerida ya que solo los nodos vecinos intercambian información. Entre las desventajas del enfoque distribuido destaca que las decisiones tomadas no son óptimas debido a que los nodos solo tienen información de sus vecinos y no de la red completa, adicionando el hecho de que es posible que la información intercambiada no sea suficiente (Tragos *et al.*, 2013). También, la falta de un soporte centralizado impide obtener información completa de la topología de la red provocando colisiones entre SU e interferencia al PU (Giupponi y Pérez-Neira, 2008). En conclusión, en lo que respecta a la asignación espectral, 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*, el cual se encarga de combinar la información completa y generar un vector de asignación espectral final. Todos los *cluster head* 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 enrutador principal decide que canal de frecuencia asignar y transmite esta información a todos los demás *cluster head* de la red. Este enfoque es más robusto contra fallas; hace un uso más eficiente del ancho de banda 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 *cluster* y no de la red completa. (Alsarhan y Agarwal, 2009; Chen *et al.*, 2007; Tragos *et al.*, 2013).

2.2.4.3 Canal único 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 anterior implica que los canales son contiguos en el espectro.

El caso de la asignación multicanal consiste en la agrupación de varios canales disponibles que no son adyacentes, para formar un solo canal. Este enfoque permite aumentar el BW del SU aprovechando las oportunidades espectrales con baja capacidad de canal. Una de las técnicas que permite el acceso simultáneo a varios canales de frecuencia es la Multiplexación por División de Frecuencia Ortogonal Discontinua (Chen *et al.*, 2008). Lo anterior permite 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 puede 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 encuentran 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 12MHz. Esto significa que, si dos canales están separados más de 12MHz, no pueden unirse en un solo canal. Por tanto, los algoritmos de asignación espectral 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 oportunidad espectral a otros SU, por tanto, el algoritmo de asignación espectral debería manejar alguna métrica de justicia para estos casos. (Tragos *et al.*, 2013).

2.2.4.4 Incluir modelos de PU y SU vs no incluirlos

De acuerdo con algunos trabajos (Akter *et al.*, 2008; Chen y Hee-Seok, 2016; Csurgai-Horvath y Bito, 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 SU es relevante para lograr un buen desempeño en las CRN. Un buen modelo de actividad del PU y SU permite asignar inteligentemente cada canal de frecuencia disponible, optimizando el uso del espectro, maximizando los parámetros de comunicación —como la tasa de datos, el BW, la SINR y el balanceo de carga, entre otros—, eliminando o minimizando 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 diseñó.

Una estrategia de *handoff* espectral 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 de PU puede evitar o minimizar esta interferencia, a través de una estrategia de *handoff* espectral 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 puede 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; en (Akter *et al.*, 2008) se propone un modelo de predicción para el SU, ya que, en muchas oportunidades, múltiples SU compiten por el mismo recurso de espectro, degradando la QoS. A través de la implementación de un filtro Kalman se logró realizar una significativa estimación del número de SU en el futuro instantáneo.

2.2.4.5 CCC dedicado vs CCC dinámico

El CCC es un requerimiento común en la asignación espectral de CRN, el cual permite la coordinación entre SU para la concesión del canal. El CCC es un canal predefinido para el intercambio de información de señalización, control y espectro entre los SU, el cual 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 para la asignación del canal de frecuencia o dinámico.

En la literatura son más los trabajos de investigación que defienden la necesidad o existencia de un CCC dedicado (Ding *et al.*, 2010; Kim *et al.*, 2010; Ma *et al.*, 2007). El enfoque con CCC dedicado se divide 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 del CCC son el mismo su utilización se comparte por períodos fijos y no es necesario un transreceptor adicional, ni se requiere cambiar la frecuencia para recibir o transmitir los mensajes. Sin embargo, cuando sea necesario realizar un *handoff* espectral, 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).

Cuando el canal de datos del SU y el CCC son independientes el CCC no se ve afectado por la realización de un *handoff* espectral; sin embargo, el costo de tener dos canales implica la necesidad de un transreceptor 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 —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). 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, la selección dinámica de un CCC puede incrementar el nivel de retardo en la transmisión del SU (Tragos *et al.*, 2013).

2.2.5 Criterios de decisión espectral

En la asignación espectral existen múltiples criterios que ayudan a tomar decisiones inteligentes. Sin embargo, cuantos y cuales criterios utilizar, depende del objetivo en cada toma de decisiones. En aras de imparcialidad, se analizaron todas las variables que intervienen durante la toma de decisiones y que pueden afectar el desempeño de la red. Esto se logró a partir del análisis de cada una de las investigaciones consultadas alrededor del tema de decisión espectral en CRN (Ahmed *et al.*, 2014; Masonta *et al.*, 2013; Tragos *et al.*, 2013).

Estos criterios proporcionan información necesaria para alimentar los algoritmos de toma de decisiones con base en los criterios de evaluación para

la asignación espectral a los SU en las CRN. Estos criterios varían de acuerdo con los objetivos de cada esquema de *handoff* espectral.

Calidad de Servicio (QoS)

La QoS es uno de los criterios más relevantes en los algoritmos de toma de decisión para la asignación espectral de los SU en las CRN. Permite diferenciar entre aplicaciones sensitivas y no al retardo; en otras palabras, las clasifica de acuerdo con el tipo de servicio: tiempo real (RT) y mejor esfuerzo (BE). Con esta información se puede tomar la decisión más adecuada en términos de las oportunidades espectrales.

Aplicaciones que no son sensibles al retardo pueden ser asignadas a oportunidades espectrales con nivel de disponibilidad intermedio. Mientras que aplicaciones sensibles al retardo pueden ser asignadas a oportunidades espectrales 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 SRN, los cuales también afectan la QoS de la red. Esta última a veces se trabaja como SINR.

BER

Es el número de bits recibidos que han sido alterados debido al ruido y la interferencia, divididos por el número total de bits transmitidos durante un período 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). El nivel de BER está relacionado con el nivel de SNR, esto causa que la energía por bit transmitido sea una métrica importante en la estimación del error (Höyhty *et al.*, 2008). A mayor SNR menor BER, sin embargo, 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 mínimo nivel de

SNR que garantice cierto nivel de BER que no perjudique la comunicación (Tragos *et al.*, 2013).

Calidad del enlace de comunicación

En CRN puede variar dinámicamente en el tiempo y 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. 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, sin embargo, la primera está más inclinada a proveer conectividad y la segunda, QoS de la red (Ahmed *et al.*, 2014).

AP del canal

La disponibilidad de canal estima la probabilidad de que un canal de frecuencia esté disponible. Algunos trabajos lo expresan como ocupación de canal, en cuyo caso se busca estimar la probabilidad de ocupación de un canal de frecuencia. Es un criterio muy relevante en la asignación espectral ya que puede determinar las posibilidades de que una oportunidad espectral 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 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 período de tiempo de actualización. Lo anterior permite lograr una mejor eficiencia de energía, al no tener que correr el algoritmo de estimación del criterio de disponibilidad de canal continuamente (Ahmed *et al.*, 2016).

ETA del canal

El tiempo estimado de disponibilidad es un criterio que busca determinar el valor promedio que un canal de frecuencia permanece disponible para un SU o PU. A diferencia del criterio de disponibilidad de canal, donde se determina la probabilidad de encontrar cierto canal libre, el criterio de tiempo estimado de disponibilidad estima el tiempo medio durante el cual el canal

permanece libre, una vez está disponible. Estos dos criterios no son sustitutos sino complementarios, ya que dos canales pueden tener la misma AP, pero con distribuciones de tiempo de disponibilidad distintas. Seleccionar un canal con un tiempo estimado de disponibilidad alto, garantiza un menor número de *handoff* espectral. Los autores en (Pla *et al.*, 2010) proponen un modelo Markoviano para determinar la duración de las oportunidades espectrales. Una vez se ha modelado el tiempo ocioso del PU, se aplican técnicas de matriz analítica para determinar la duración de las oportunidades espectrales para ser ocupadas por los SU. La principal desventaja de esta técnica radica en su complejidad.

Patrón de tráfico del PU y SU

No hay ninguna garantía de que el canal de frecuencia seleccionado esté disponible durante toda la comunicación, por ello 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 puede estimar la AP y la ETA (Ahmed *et al.*, 2016; Akyildiz *et al.*, 2009; Christian *et al.*, 2012; Wu *et al.*, 2016).

Los autores en (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 aplicar a diferentes aplicaciones como voz, video y 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 (Sriram y Whitt, 1986) el patrón de tráfico se modela como un proceso de dos estados *ON-OFF*; nacimiento y muerte, con sus respectivas tasas. Otros modelan la actividad del PU a partir del tiempo entre arribos; longitud y 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). Los autores en (Willkomm *et al.*, 2008) utilizan medidas reales de una red celular para modelar características de uso del espectro por parte del PU. El análisis realizado muestra que el modelo de llegadas exponencialmente

distribuidas es adecuado para capturar el tiempo de actividad del PU en llamadas no inalámbricas. Mientras que para 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. Los autores en (Hernández *et al.*, 2009) validan el uso de series de tiempo —modelos Autorregresivo (AR); Media móvil (MA) y Autorregresivo integrado de media móvil (ARIMA)— para el modelamiento y predicción de tráfico en redes Wi-Fi, obteniendo un alto nivel de precisión en el pronóstico de rango corto. En (Li y Zekavat, 2008) se presenta un trabajo sobre la predicción del patrón de tráfico para CRN.

Los autores en (Wei *et al.*, 2006) almacenan información de interés para una CRN —pasada y presente— en un repositorio, incluyendo la información de localización y tráfico del SU y PU. 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 maquina, los SU deberían ser hábiles para recordar las lecciones aprendidas en el pasado y actuar rápidamente en el futuro (Marinho y Monteiro, 2012). Idealmente el SU debería conocer el patrón de tráfico del PU, observar el cambio y seleccionar la estrategia de *handoff* más adecuada (Akyildiz *et al.*, 2009; Christian *et al.*, 2012). Las estrategias de *handoff* espectral 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 ser un buen dato de información para estimar el nivel de tráfico y congestión de la red, a partir de las estadísticas de la historia de información pasada (Hernández *et al.*, 2009, 2013; Issariyakul *et al.*, 2009; Wei *et al.*, 2006; Zhang *et al.*, 2016). Una base de datos de estadísticas pasadas y recientes permite 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).

Geo-localización

De acuerdo con la naturaleza de las redes inalámbricas, la disponibilidad de espectro no solamente cambia 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 PU es una ventaja en la toma de decisiones para la asignación espectral. Esta información puede mejorar las estrategias para evitar interferencias al PU y reducir la tasa de *handoff* espectral, 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 oportunidades espectrales y la caracterización del ambiente de radiofrecuencia.

Capacidad del canal o BW disponible

Muchos trabajos se enfocan en parámetros como tasa de datos, retardo, nivel de interferencia, BER o tasa de *handoff* espectral, los cuales son relevantes para la eficiencia espectral. Sin embargo, la capacidad de canal es otra variable de interés en la asignación espectral, ya que algunas aplicaciones requieren un mínimo BW para mantener sus parámetros de BW (Kumar *et al.*, 2016). En los sistemas de multiplexación por división de frecuencia ortogonal cada banda espectral tiene un diferente BW que consiste de varias subportadoras (Masonta *et al.*, 2013).

Fuerza de la señal recibida (RSS)

También conocida como Indicador de fuerza de la señal recibida (RSSI) y Fuerza relativa de la señal recibida (RRSS), es un factor tradicional e importante para tomar decisiones de *handoff* espectral. RSS provee información acerca del nivel de potencia que está siendo recibido por la antena, el cual decrementa cuando el usuario se aleja del actual punto de acceso 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. El valor del

costo monetario dependerá principalmente del recurso de BW y del tiempo durante el cual se utilizó. Si dos redes proveen la misma QoS entonces la red con el costo más bajo será la preferida por los SU (Ahmed *et al.*, 2014). Debido a lo anterior, el valor del costo monetario es una variable de información de interés para el algoritmo de asignación espectral.

Preferencias de usuario

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

Seguridad de la red

La seguridad es uno de los temas más relevantes en la convergencia de redes debido a que cada red tiene sus propias opciones de seguridad. El proceso de *handoff* espectral requiere proveer seguridad y privacidad contra intercepciones ilegales o ataques de denegación de servicio (Ahmed *et al.*, 2014).

2.3 Técnicas y algoritmos para la asignación espectral

La asignación espectral —y por ende la decisión espectral— es un aspecto clave en las CRN para reducir 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 *handoff* espectral, degradando el desempeño de todo el conjunto (Christian *et al.*, 2012; Hernández, Salgado *et al.*, 2015; Hernández-Guillén *et al.*, 2012).

Esta sección tiene por objetivo presentar una revisión sobre los algoritmos de asignación espectral en CRN, describiendo los algoritmos más relevantes y su clasificación de acuerdo con la literatura actual. El desarrollo de esta revisión se realizó 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 los algoritmos de asignación espectral en CRN. Los principales resultados determinan la importancia de una asignación espectral 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 múltiples canales de frecuencia. Como conclusión es importante diseñar algoritmos adaptativos que permitan hacer un uso eficiente de las porciones disponibles del espectro licenciado.

Una vez que todas las oportunidades espectrales se detectan y caracterizan se debe seleccionar la oportunidad espectral más cercana a los requerimientos para la transmisión, teniendo en cuenta los requisitos de QoS y las características del espectro. Por tanto, se deben conocer los requisitos de QoS del usuario. 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. En (Zheng y Cao, 2005) se 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. En (Kanodia *et al.*, 2004) se propone un protocolo de saltos de canal de frecuencia oportunista para la búsqueda de un canal de mejor calidad, basada en la SNR.

La figura 2.8 propone una clasificación de algoritmos para la selección de oportunidades espectrales. Esta clasificación agrupa los algoritmos de asignación espectral en seis clases: (1) toma de decisiones multicriterio (MCDM), (2) algoritmos inteligentes, (3) técnicas de aprendizaje, (4) funciones de decisión, (5) contexto, y (6) estadísticos. A continuación, se describen los algoritmos más relevantes dentro de cada clase de la clasificación propuesta.

2.3.1 Algoritmo de asignación aleatoria

Es la forma más básica para la asignación espectral y la que peor desempeño provee, por esta razón no se encuentra en la clasificación propuesta de la figura 2.8. Sin embargo, se ha convertido en el algoritmo más utilizado para contrastar los resultados obtenidos por otros de asignación espectral propuestos en la literatura actual al seleccionar de forma completamente aleatoria las oportunidades espectrales, por lo cual es utilizado como punto de referencia y comparación para la evaluación de algoritmos propuestos.

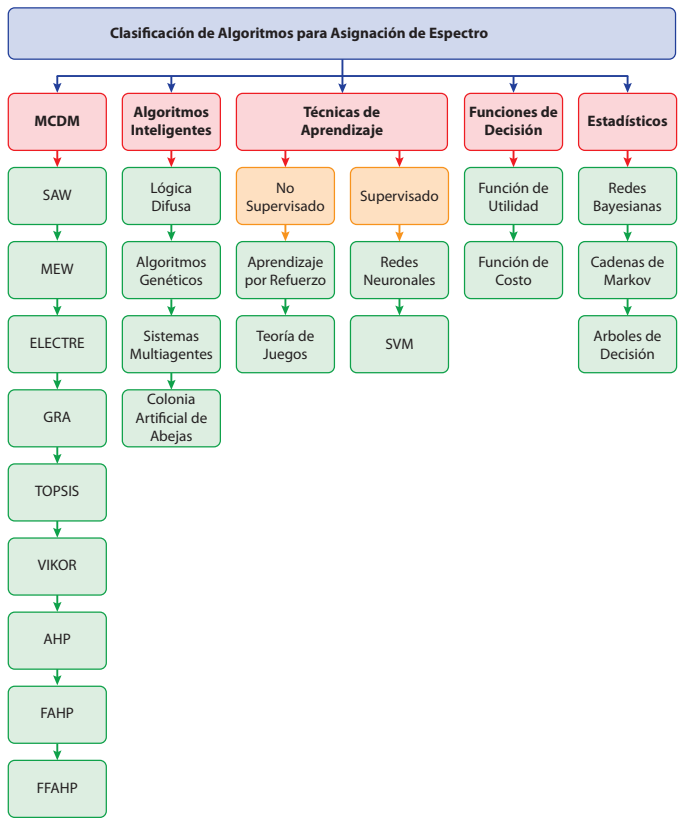


Figura 2.8. Clasificación de los algoritmos para la asignación de espectro.

Fuente: elaboración propia.

2.3.2 Algoritmos MCDM

El problema de asignación espectral tiene múltiples variables a analizar para seleccionar una sola oportunidad espectral, por tanto, los algoritmos basados

en MCDM son ampliamente usados en este tipo de problemas, donde la relación entre los criterios de decisión es medida a través de pesos 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).

2.3.2.1 Simple Additive Weighting–SAW

Este algoritmo desarrolla una matriz de decisión conformada por criterios y alternativas (oportunidades espectrales). Para cada intersección de la matriz el algoritmo asigna un peso de acuerdo con los criterios del diseñador. Esto permite establecer una calificación para cada una de las oportunidades espectrales evaluadas, y obtener así un *ranking* de todas las alternativas. La oportunidad espectral con mayor puntaje será la seleccionada (Hernández *et al.*, 2015a; Ramírez y Ramos, 2010).

La alternativa A_i está definida por la ecuación (2.1) (Ramírez y Ramos, 2013).

$$u_i = \sum_{j=1}^M \omega_j r_{i,j} \quad \forall i \in 1, \dots, N \quad (2.1)$$

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 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 y Ramos, 2013; Ramírez y Ramos, 2010).

En Hernández *et al.*, (2015c) se utiliza SAW para seleccionar la mejor oportunidad espectral en una banda de frecuencia GSM, evaluando la cantidad de *handoff* realizados y comparando los resultados con otros dos algoritmos de asignación espectral.

2.3.2.2 Multiplicative Exponent Weighting–MEW

MEW es otro algoritmo MCDM, muy similar a SAW. La principal diferencia es que en MEW en lugar de suma hay multiplicación. Fue propuesto

para asignación espectral en (Stevens y Wong, 2006). En MEW la calificación de las oportunidades espectrales es determinada por el producto de los pesos de los criterios de decisión. El puntaje S_i de la oportunidad espectral i es determinada por la ecuación (2.2) (Hernández *et al.*, 2015a; Hernández *et al.*, 2015c; Hübner, 2007; Ramírez y Ramos, 2013; Ramírez y Ramos, 2010; Stevens *et al.*, 2012; Stevens y Wong, 2006).

$$S_i = \prod_{j \in N} x_{ij}^{w_j} \quad (2.2)$$

Donde X_{ij} denota el criterio j de la oportunidad espectral i , W_j denota el peso del criterio j , y $\sum_{j=1}^N w_j = 1$.

Es necesario tener en cuenta que en (2.2) W_j es una potencia positiva para métrica de beneficio y negativa para una métrica de costo. Debido a que la normalización de parámetros no es requerida sino opcional, el puntaje de la oportunidad espectral asignado por MEW no tiene una cota superior (Yoon y Hwang, 1995).

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

2.3.2.3 Elimination and Choice Expressing the Reality – ELECTRE

comparaciones entre parejas de alternativas utilizando cada uno de los criterios por separado para establecer relaciones (Valenta *et al.*, 2010). Se propuso, inicialmente, para la asignación espectral en Christian *et al.* (2012). En general, ELECTRE utiliza un vector de criterios de referencia para ajustar los valores iniciales antes de compararlos. El valor de cada uno de estos en la matriz de decisión se compara con el correspondiente valor de criterio de referencia X_j^{ref} . La diferencia entre ambos se calcula de acuerdo con la ecuación (2.3) (Stevens *et al.*, 2012).

$$r_{ij} = |x_{ij} - x_j^{ref}| \quad (2.3)$$

Con el objetivo de comparar las alternativas espectrales se introduce el concepto 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 *et al.*, 2012).

2.3.2.4 Grey Relational Analysis – GRA

“El objetivo de este algoritmo 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” (Hernández, Giral, y Páez, 2015; Hernández, Giral, y Santa, 2015; Hübner, 2007; Páez *et al.*, 2015; Ramírez y Ramos, 2013; Ramírez y Ramos, 2010; Stevens *et al.*, 2012; Stevens 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” como lo describe la ecuación (2.4) (Páez *et al.*, 2015).

$$\gamma(x_0(i), x_j(i)) = \frac{\Delta_{min} + \zeta \Delta_{max}}{\Delta_{0,j}(i) + \zeta \Delta_{max}} \quad (2.4)$$

Donde,

$$\Delta_{0,j} = |x_0(i) - x_j(i)|$$

$$\Delta_{min} = \min_{j \in N} \left\{ \min_{i \in M} \{|x_0(i) - x_j(i)|\} \right\}$$

$$\Delta_{max} = \max_{j \in N} \left\{ \max_{i \in M} \{|x_0(i) - x_j(i)|\} \right\}$$

Donde el coeficiente que pertenece $[0,1]$ compensa el efecto de 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 (2.5), donde $\Gamma(x_o, x_i)$ representa el grado relacional de Grey para las j -ésimas alternativas.

$$\Gamma(x_o, x_j) = \sum_{i=1}^M \omega_i \gamma(x_o(i), x_j(i)) \quad (2.5)$$

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

En Páez *et al.* (2015) se utiliza GRA para seleccionar la oportunidad espectral 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 asignación espectral.

2.3.2.5 Technique for Order Preference by Similarity to Ideal Solution—TOPSIS

El desarrollo de este algoritmo se basa en la determinación de dos componentes: la solución ideal del sistema y la solución que no puede ser aceptada en ninguna situación. Aquí es necesario comparar los resultados obtenidos para determinar qué solución es la más cercana posible a la ideal, y cual 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, Giral, y Páez, 2015; Ramírez y Ramos, 2010).

El procedimiento del algoritmo TOPSIS está descrito en Hernández, Giral, y Páez (2015), Ramírez y Ramos (2013) y Ramírez y Ramos (2010). Inicialmente, se construye la matriz de decisión X y se normaliza usando el método de raíz cuadrada —ecuación (2.6)—.

$$\tilde{X} = \begin{pmatrix} \tilde{x}_{11} & \cdots & \tilde{x}_{1M} \\ \vdots & \ddots & \vdots \\ \tilde{x}_{N1} & \cdots & \tilde{x}_{NM} \end{pmatrix} = \begin{pmatrix} \omega_1 \tilde{x}_{11} & \cdots & \omega_M \tilde{x}_{1M} \\ \vdots & \ddots & \vdots \\ \omega_1 \tilde{x}_{N1} & \cdots & \omega_M \tilde{x}_{NM} \end{pmatrix} \quad (2.6)$$

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 (2.7) y (2.8).

$$A^+ = \left\{ \left(\max_{ij} \chi_{ij} | j \in X^+ \right), \left(\min_{ij} \chi_{ij} | j \in X^- \right) \right\} = \{ \chi_1^+, \dots, \chi_M^+ \} \quad (2.7)$$

$$A^- = \left\{ \left(\min_{ij} \chi_{ij} | j \in X^+ \right), \left(\max_{ij} \chi_{ij} | j \in X^- \right) \right\} = \{ \chi_1^-, \dots, \chi_M^- \} \quad (2.8)$$

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 (2.9) y (2.10).

$$D_i^+ = \sqrt{\sum_{j=1}^M (\chi_{ij} - \chi_j^+)^2} \quad i = 1, \dots, N \quad (2.9)$$

$$D_i^- = \sqrt{\sum_{j=1}^M (\chi_{ij} - \chi_j^-)^2} \quad i = 1, \dots, N \quad (2.10)$$

Finalmente, las alternativas son organizadas en orden descendente de acuerdo con el índice de preferencia dado por la ecuación (2.11).

$$C_i^+ = \frac{D_i^-}{D_i^+ + D_i^-}, \quad i = 1, \dots, N. \quad (2.11)$$

En Hernández *et al.* (2015f) se utiliza TOPSIS para seleccionar la mejor oportunidad espectral evaluando el nivel de interferencia por canal adyacente y el número promedio de *handoff* realizados. Los resultados son comparados con otro algoritmo y sus respectivas versiones, al combinarlos, con tres algoritmos de predicción basados en series de tiempo.

2.3.2.6 Multi-Criteria Optimization and Compromise Solution—VIKOR

“El método VIKOR 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, Vásquez, *et al.*, 2015; Páez *et al.*, 2015; Tanino *et al.*, 2003). VIKOR fue desarrollado para lograr la optimización de sistemas complejos con múltiples criterios, 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 asignación espectral (Gallardo-Medina *et al.*, 2009).

El algoritmo VIKOR sigue los pasos descritos en Hernández *et al.* (2015a), Páez *et al.* (2015), Ramírez y Ramos (2010) y Stevens *et al.* (2012).

Para cada parámetro $j = 1, 2, 3, \dots, N$, se determina el mejor y peor valor, dados por las ecuaciones (2.12) y (2.13).

$$F_j^+ = \left\{ \left(\max_{i \in M} x_{ij} | j \in N_b \right), \left(\min_{i \in M} x_{ij} | j \in N_c \right) \right\} \quad (2.12)$$

$$F_j^- = \left\{ \left(\min_{i \in M} x_{ij} | j \in N_b \right), \left(\max_{i \in M} x_{ij} | j \in N_c \right) \right\} \quad (2.13)$$

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 (2.14) y (2.15).

$$S_i = \sum_{j \in N} w_j \frac{(F_j^+ - x_{ij})}{(F_j^+ - F_j^-)} \quad (2.14)$$

$$R_i = \max_{j \in N} \left[w_j \frac{(F_j^+ - x_{ij})}{(F_j^+ - F_j^-)} \right] \quad (2.15)$$

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 (2.16).

$$Q_i = \gamma \left(\frac{S_i - S^+}{S^- - S^+} \right) + (1 - \gamma) \left(\frac{R_i - R^+}{R^- - R^+} \right) \quad (2.16)$$

Dónde, $S^+ = \min_{i \in M} S_i$, $S^- = \max_{i \in M} S_i$, $S^+ = \min_{i \in M} S_i$, $S^- = \max_{i \in M} S_i$, $R^+ = \min_{i \in M} R_i$, $R^- = \max_{i \in M} R_i$,
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 oportunidades espectrales candidatas. Finalmente, la oportunidad espectral seleccionada está dada por el Q óptimo, como lo describe la ecuación (2.17).

$$A_{\text{VIK}}^* = \arg \min_{i \in M} Q_i^* \quad (2.17)$$

En (Páez *et al.*, 2015) se utiliza VIKOR para seleccionar la mejor oportunidad espectral 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 asignación espectral.

2.3.2.7 Analytical Hierarchical Process—AHP

AHP se basa en comparaciones sobre la importancia entre los criterios de decisión escogidos para la selección de una alternativa, siendo más una medida relativa 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 oportunidad espectral. Los criterios son los factores que afectan la preferencia de una alternativa. Las alternativas son todas las oportunidades espectrales, de las cuales hay que escoger solo una.

El segundo paso es la construcción de la jerarquía de acuerdo con la definición del problema. 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 —ver ecuación (2.18)—.

$$A = [a_{ij}]_{n \times n} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix} \quad (2.18)$$

Donde $i = j = 1, 2, \dots, n$, corresponden al número de criterios.

El cuarto paso procede a calcular los pesos normalizados para cada criterio, como lo describe la ecuación (2.19) (Hernández *et al.*, 2015a).

$$r = [r_1, r_2, \dots, r_n] \text{ con } r_i = \frac{v_i}{\sum_{j=1}^n v_j} \quad (2.19)$$

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, el quinto paso evalúa la validez del algoritmo AHP a través del índice de consistencia, como se muestra en la ecuación (2.20) (Miranda, 2001). De acuerdo con Saaty (1990) si el índice de consistencia es menor que 0,1 el desarrollo del algoritmo es satisfactorio.

$$CI = \frac{\sqrt{\frac{\sum_{i=1}^n \sum_{j>1}^n (\ln a_{ij} - \ln \frac{v_i}{v_j})^2}{(n-1) \times (n-2)}}}{2} \quad (2.20)$$

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

En Hernández, Giral y Páez (2015) se utiliza AHP para seleccionar la mejor oportunidad espectral en la banda de frecuencia GSM, calculando el desempeño del algoritmo con base en cinco métricas de evaluación y comparando los resultados con otros cinco algoritmos de asignación espectral.

2.3.2.8 Algoritmo multivariable difuso-FAHP

El algoritmo AHP 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 *et al.*, 2011; Song y Jamalipour, 2005; Stevens *et al.*, 2012; Stevens *et al.*, 2008). El algoritmo AHP se basa en juicios subjetivos, a través de comparaciones de la importancia entre criterios usados para la selección de una alternativa, como consecuencia es más una medida relativa que un valor absoluto (Saaty, 1990).

Sin embargo, el método AHP propuesto en Saaty (1990) tiene algunas limitaciones como: (1) trabajar con una escala de juicios muy desbalanceada, (2) no manejar información con incertidumbre y ambigüedad asociada a la asignación de un número a cada evaluación, (3) el ranking de AHP es bastante impreciso, (4) la subjetividad del juicio, selección y preferencia de quienes toman las decisiones tiene gran influencia en los resultados. Estas limitaciones se pueden corregir a través de la integración de la lógica difusa en el algoritmo AHP, mejorando el manejo de subjetividad e incertidumbre en la información y en las evaluaciones de criterios, obteniendo de esta forma el algoritmo 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 con la lógica difusa, 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, subcriterios y alternativas. El objetivo es la selección de la mejor oportunidad espectral en una CRN. Los criterios y subcriterios son los factores que afectan la preferencia de una alternativa. Las alternativas son todas las oportunidades espectrales 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 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 respondiendo 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 criterios de decisión para el algoritmo FAHP fueron propuestos inicialmente a partir de todos los parámetros reportados en la literatura actual sobre *handoff* espectral para CRN, y finalmente seleccionados con una modificación del método Delphi, propuesto en (Hernández *et al.*, 2015). La contribución al método Delphi es la definición de experto por sí misma, definida 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 siguientes, se consideraron dos entradas, la decisión de un Consejo de Administradores de Red compuesto por nueve expertos seleccionados aleatoriamente, y el *ranking* del impacto de las variables que influyen en el proceso de *handoff* espectral, reportadas en la literatura.

La segunda ronda del método Delphi implementado consideró 13 variables seleccionadas durante la primera ronda del proceso y el *ranking* del impacto de las variables actualizado. El Consejo de Administradores de Red determinó cuáles de las 13 variables eran significativas, si debía adicionarse nuevas variables, o si había que modificar o descartar variables seleccionadas inicialmente, lo cual se combinó con las estadísticas del *ranking* del impacto de las variables y se actualizó. En caso de desacuerdo entre miembros del Consejo de Administradores de Red, se desarrolla un análisis global combinado con las estadísticas del *ranking* del impacto de las variables, luego un segundo conjunto de variables es propuesto para la tercera ronda, con el mismo procedimiento. Este proceso se repite iterativamente hasta alcanzar consenso general por parte del Consejo de Administradores de Red combinado con las estadísticas del *ranking* del impacto de las variables. 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 *ranking* del impacto de las variables. 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 Consejo de Administradores de Red y las estadísticas del *ranking* del impacto de las variables. Estas son, clase de servicio del SU (RT y BE); AP, ETA, SINR y BW. El próximo paso

fue organizar los criterios de decisión en criterios y subcriterios para el objetivo de seleccionar la mejor oportunidad espectral para el SU. Se consideró que la variable clase de servicio es más general que las otras variables, por lo que se decidió seleccionarla como criterio, clasificándola como alta sensibilidad al retardo y baja sensibilidad al retardo, y considerando las otras cuatro variables seleccionadas como subcriterios de la clase de servicio. En esta investigación el criterio clase de servicio es determinado por la aplicación del SU. Se considera que el objetivo es el mismo tanto para alta como baja sensibilidad al retardo (seleccionar la mejor oportunidad espectral), sin embargo, la importancia (ponderación) de cada subcriterio es diferente, y corresponde al enfoque de la sensibilidad al retardo de las aplicaciones.

Los cuatro subcriterios fueron medidos y calculados a partir de datos experimentales de ocupación espectral, capturados en la banda GSM y Wi-Fi.

Estructura jerárquica

La estructura jerárquica del algoritmo FAHP se construyó con base en el objetivo, los criterios, subcriterios y las alternativas seleccionadas. Dicha estructura se puede observar en la figura 2.9.

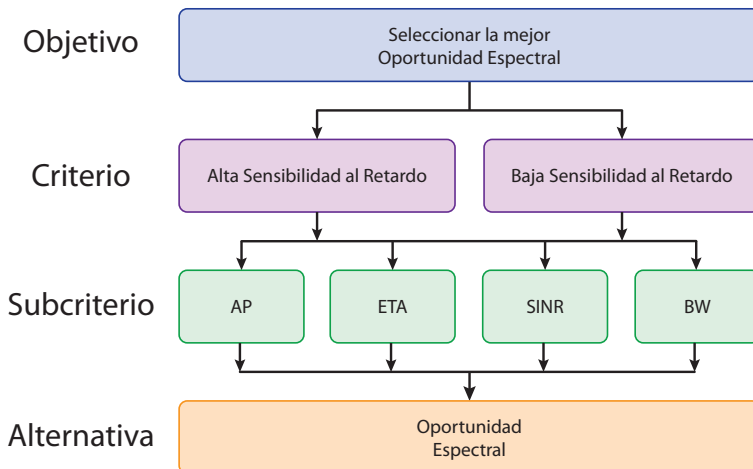


Figura 2.9. Estructura propuesta para el algoritmo FAHP.

Fuente: elaboración propia.

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: alta y baja sensibilidad al retardo (cada uno con los mismos cuatro subcriterios), los cuales son mutuamente excluyentes, no tiene sentido realizar una matriz de juicios para este nivel. En el caso de las alternativas, debido a que las oportunidades espectrales modifican sus características (subcriterios) dinámicamente en el tiempo, tampoco tendría sentido realizar una matriz de juicios a este nivel, por tal razón se decidió que el algoritmo FAHP evaluara dinámicamente el conjunto de alternativas.

De acuerdo con Büyüközkan *et al.* (2004) “las personas encargadas de la toma de decisiones usualmente encuentran que 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, dado la naturaleza difusa de los procesos de comparación humana”, por ello se decidió trabajar con una escala de Números Difusos Triangulares (TFN), presentados en la tabla 2.1. La escala de importancia difusa se obtuvo de la conversión de la escala de importancia fundamental de nueve niveles a números difusos presentada en (Büyüközkan *et al.*, 2004).

Tabla 2.1. 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: 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), Zadeh (1965).




Figura 2.10. TFN para la escala de importancia de FAHP.

Fuente: elaboración propia.

Una matriz de juicios de n criterios o subcriterios esta descrita por la ecuación (2.21).

$$A = [a_{ij}]_{n \times n} = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nn} \end{bmatrix} \quad (2.21)$$

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 de que contienen los TFN representan las comparaciones por parejas entre subcriterios (Mehbodniya *et al.*, 2012), como lo describe la ecuación (2.22).

$$\tilde{A}(\tilde{a}_{ij})_{n \times n} = \begin{bmatrix} (0.5, 1, 1.5) & (l_{12}, m_{12}, u_{12}) & \dots & (l_{1n}, m_{1n}, u_{1n}) \\ (l_{21}, m_{21}, u_{21}) & (0.5, 1, 1.5) & \dots & (l_{2n}, m_{2n}, u_{2n}) \\ \vdots & \vdots & \ddots & \vdots \\ (l_{n1}, m_{n1}, u_{n1}) & (l_{n2}, m_{n2}, u_{n2}) & \dots & (0.5, 1, 1.5) \end{bmatrix} \quad (2.22)$$

$$\text{Donde } (\tilde{a}_{ij}) = [\tilde{a}_{ij}]^{-1} = (l_{ij}, m_{ij}, u_{ij})^{-1} = \left(\frac{1}{u_{ij}}, \frac{1}{m_{ij}}, \frac{1}{l_{ij}} \right)$$

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 2.1 y la figura 2.10, y 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 de los resultados de la primera ronda del método Delphi modificado. Los resultados de la primera ronda fueron usados en la segunda ronda tanto para el enfoque de alta sensibilidad como el de baja sensibilidad al retardo. El proceso de decisión se repite hasta que los resultados convergen, los cuales se presentan en las matrices de juicio para los subcriterios con el enfoque de alta sensibilidad al retardo (ver tabla 2.2) y la matriz de juicios para los subcriterios con el enfoque de baja sensibilidad al retardo (ver tabla 2.3).

Tabla 2.2. Matriz de juicios para los subcriterios de alta sensibilidad al retardo.

Subcriterios	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 2.3. Matriz de juicios para los subcriterios de baja sensibilidad al retardo.

Subcriterios	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 de alta y baja sensibilidad al retardo, tienen diferentes enfoques. Para el primero, los subcriterios con más alta prioridad son los que

reducen el retardo, como AP y ETA. Para el segundo, 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 (2.23):

$$\tilde{S}_i = \sum_{j=1}^n \tilde{a}_{ij} \left[\sum_{i=1}^n \sum_{j=1}^n \tilde{a}_{ij} \right]^{-1} \quad (2.23)$$

Dónde:

$$\sum_{j=1}^n \tilde{a}_{ij} = \left(\sum_{j=1}^n l_{ij}, \sum_{j=1}^n m_{ij}, \sum_{j=1}^n u_{ij} \right)$$

La matriz inversa de la ecuación (2.23) se calcula a partir de la ecuación (2.24):

$$\left[\sum_{i=1}^n \sum_{j=1}^n \tilde{a}_{ij} \right]^{-1} = \left(\frac{1}{\sum_{i=1}^n \sum_{j=1}^n u_{ij}}, \frac{1}{\sum_{i=1}^n \sum_{j=1}^n m_{ij}}, \frac{1}{\sum_{i=1}^n \sum_{j=1}^n l_{ij}} \right) \quad (2.24)$$

El grado de posibilidad de que un número difuso convexo sea más grande que k números difusos convexos, está dado por la ecuación (2.25):

$$V(\tilde{S} \geq \tilde{S}_i) = V[(\tilde{S} \geq \tilde{S}_1) \wedge (\tilde{S} \geq \tilde{S}_2) \dots (\tilde{S} \geq \tilde{S}_k)] = \min\{V(\tilde{S} \geq \tilde{S}_i)\} \quad (2.25)$$

Donde el grado de posibilidad de que y está dado por las ecuaciones (2.26) y (2.27), respectivamente.

$$V(\tilde{S}_1 \geq \tilde{S}_2) = \begin{cases} 1 & m_1 \geq m_2 \\ 0 & l_2 \geq u_1 \\ \frac{l_2 - u_1}{(m_1 - u_1) - (m_2 - l_2)}, & \text{otherwise} \end{cases} \quad (2.26)$$

$$V(\tilde{S}_2 \geq \tilde{S}_1) = \left\{ \begin{array}{ll} 1 & m_2 \geq m_1 \\ 0 & l_1 \geq u_2 \\ \frac{l_2 - u_1}{(m_2 - u_2) - (m_1 - l_1)}, & otherwise \end{array} \right\} \quad (2.27)$$

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 (2.28):

$$W = (d_1, d_2, \dots, d_n)^T = \left(\frac{d'_1}{\sum_{i=1}^n d'_i}, \frac{d'_2}{\sum_{i=1}^n d'_i}, \dots, \frac{d'_n}{\sum_{i=1}^n d'_i} \right) \quad (2.28)$$

A partir del procedimiento anterior, los resultados del vector de pesos, correspondientes al criterio de alta sensibilidad al retardo se observan en la tabla 2.4, mientras que los de baja sensibilidad se muestran en la tabla 2.5.

Tabla 2.4. Pesos normalizados de los subcriterios de alta sensibilidad al retardo.

Subcriterio alta sensibilidad	AP	ETA	SINR	BW
Pesos normalizados	0,3593	0,2966	0,1970	0,1471

Fuente: elaboración propia.

Tabla 2.5. Pesos normalizados de los subcriterios de baja sensibilidad al retardo.

Subcriterio baja sensibilidad	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 alta o baja sensibilidad al retardo.

Los pesos descritos en la tabla 2.4 y tabla 2.5 se utilizan para configurar cada uno de los cuatro algoritmos de decisión espectral a evaluar comparativamente.

2.3.2.9 Algoritmo multivariable difuso realimentado – FFAHP

En el algoritmo FFAHP, el puntaje de cada oportunidad espectral es calculado a partir de los pesos obtenidos con FAHP, usando la ecuación (2.29) para el enfoque de alta sensibilidad al retardo y la ecuación (2.30) para el enfoque de baja sensibilidad al retardo. La oportunidad espectral con el puntaje más alto es la oportunidad espectral objetivo; la de segundo puntaje es la de respaldo y las siguientes — de mayor a menor puntaje— son las oportunidades espectrales candidatas.

$$Score_i_ASR = AP \times 0,3593 + ETA \times 0,2966 + SINR \times 0,1970 + BW \times 0,1471 \quad (2.29)$$

$$Score_j_BSR = AP \times 0,1607 + ETA \times 0,1523 + SINR \times 0,3949 + BW \times 0,2921 \quad (2.30)$$

El objetivo del algoritmo FFAHP es incrementar la precisión en la selección de oportunidad espectral. Para lograr esto, FFAHP realimenta la información de las evaluaciones de las oportunidades espectrales realizadas anteriormente. La selección de la oportunidad espectral se realiza con base en la evaluación de la información actual del espectro y 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 resolución de BW, 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 criterios de decisión: AP, ETA, SINR y BW, y los normaliza sobre una base de 100. El algoritmo FAHP recibe los valores actualizados de cada criterio de decisión y procede a evaluar cada oportunidad espectral. Si la aplicación es de alta sensibilidad al retardo se utiliza la ecuación (2.29), y si es una aplicación de baja sensibilidad al retardo se utiliza la ecuación (2.30), donde $Score_i$ es el puntaje asignado a la oportunidad espectral i para la aplicación RT y $Score_j$ es el puntaje asignado a la oportunidad espectral j para la aplicación BE. El rango del puntaje de evaluación puede estar entre 0 y 100, siendo 100 el mejor puntaje posible. La figura 2.11 ilustra el diseño del algoritmo FFAHP.

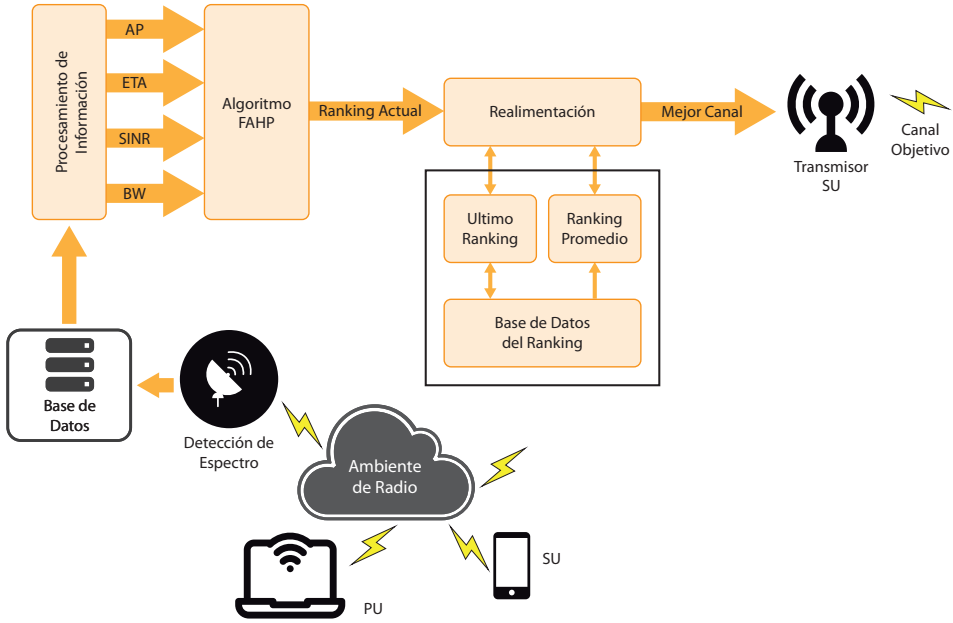


Figura 2.11. Esquema del algoritmo FFAHP propuesto.

Fuente: elaboración propia.

Esta parte del proceso tiene un *ranking* de cada una de las oportunidades espectrales con base, únicamente, en la información actual de los criterios de decisión. Sin embargo, la oportunidad espectral 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 oportunidad espectral y las pondera con el valor de la última evaluación reciente (LS) y el promedio de las evaluaciones (AS) realizadas en la última hora. Esta ponderación da como resultado el *ranking* definitivo de las oportunidades espectrales. El procedimiento anterior se describe en la ecuación (2.31).

$$Score_{Final} = \alpha \times PS + \beta \times LS + (1 - \alpha - \beta) \times AS \quad (2.31)$$

Donde α y $\beta \in [0,1]$, y $Score_final$ es el valor de la evaluación final de la oportunidad espectral i o j .

La oportunidad espectral 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 oportunidad espectral seleccionada finalmente se encuentra ocupada, el algoritmo FFAHP sobrescribe el valor de LS en cero para la respectiva oportunidad espectral.

Para determinar los valores de α y β , se realizó un análisis experimental autorregresivo con diferentes combinaciones de α y β , para un conjunto de datos predeterminado. Se tomaron los valores de α y β para los cuales la precisión en la selección de la oportunidad espectral fue más alta. Dichos valores corresponden a $\alpha=0.60$ y $\beta=0.35$, con 87% de precisión experimental.

2.3.3 Algoritmos inteligentes

La inteligencia artificial tiene como objetivo hacer que las máquinas realicen tareas de manera similar a un experto. La máquina inteligente percibirá la toma de decisiones y de esta manera maximizará su propia utilidad (Woods, 1986). De tal manera, ésta tendrá que prever desafíos principales como deducción, razonamiento, representación de las problemáticas para, finalmente, dar solución a problemas como fuentes 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: detección de la frecuencia disponible de radio, calidad del canal de comunicación, reconocimiento, predicción y anticipación en la toma de decisiones y por último, no menos importante, decisión sobre asignación de recursos para ajuste de errores de transmisión y recepción de datos (Abbas *et al.*, 2015).

2.3.3.1 Lógica difusa

La lógica difusa está basada en la teoría de conjuntos difusos, 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 por el contrario es uno, el elemento pertenece completamente al conjunto, y si el valor es una cantidad intermedia, el elemento tiene

cierto grado de pertenencia al conjunto (Patil y Kant, 2014). Los TFN son ampliamente usados como funciones de membresía debido a su eficiencia computacional.

Los TFN pueden ser denotados como parámetros l , m y u que representan el límite más bajo, el valor modal y el límite más alto, respectivamente, como se observa en la figura 2.12 y en la ecuación (2.32).




Figura 2.12. Número difuso triangular.

Fuente: adaptada de Cho y Lee (2013).

$$\mu_A(x) = \begin{cases} 0, & x < l, \\ (x-l)/(m-l), & l \leq x \leq m, \\ (u-x)/(u-m), & m < x \leq u, \\ 0, & x > u, \end{cases} \quad (2.32)$$

La lógica difusa es una herramienta particularmente apropiada para tomar decisiones en situaciones donde las entradas disponibles son, en general, inciertas e imprecisas o cualitativamente interpretadas. La lógica difusa 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 tal 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).

La lógica difusa proporciona al sistema razonamiento aproximado mediante conjuntos de reglas, teniendo la capacidad de obtener condiciones de incertidumbre mediante la predicción de consecuencias, además de la capacidad de adaptarse a nuevas situaciones (Abbas *et al.*, 2015; Dadios, 2012; Gavrilovska *et al.*, 2013).

Diferentes investigaciones (Abbas *et al.*, 2015; Hernández *et al.*, 2015; Matinmikko *et al.*, 2013) han aplicado la teoría de lógica difusa en la CR para resolver problemas en función de la asignación del BW, estudiando de antemano la interferencia y la administración de la energía, los anteriores como métodos de evaluación en la correcta asignación espectral. No obstante, diferentes resultados de 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 como 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, determina la latencia para el acceso a SU (Abbas *et al.*, 2015).

2.3.3.2 Algoritmos genéticos

Su principal campo de acción se encuentra inmerso en la optimización y búsqueda de soluciones, inspirado en la evolución genética y la selección natural de las especies por naturaleza (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. Así pues, es común encontrar definiciones de los cromosomas y funciones de aptitud como descriptores de un algoritmo genético en donde los primeros son representaciones abstractas

de las soluciones candidatas y las segundas están estrechamente relacionadas con el objetivo del algoritmo para procesos de optimización (He *et al.*, 2010).

La ventaja de utilizar algoritmos genéticos para solucionar el problema de optimización de la asignación espectral 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 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 (Tragos *et al.*, 2013).

2.3.3.3 Sistemas multiagente

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

En (Trigui *et al.*, 2012) se introdujo un concepto novedoso para direccionar el “espectro de transición” en CR, permitiendo a los terminales cambiar a una banda espectral que ofrezca mejores condiciones mediante una negociación usando sistemas multiagente. En Mir *et al.* (2011) usaron sistemas multiagente para compartir dinámicamente el espectro en CR. De acuerdo con las necesidades de SU, los agentes SU cooperan y se comunican con los agentes PU para compartir el espectro.

2.3.3.4 Colonia artificial de abejas

La colonia artificial de abejas está compuesta por tres grupos: abejas “empleadas”, “exploradoras” y “observadoras”. El objetivo es determinar las ubicaciones de las mejores fuentes de alimento. Para ello, las “abejas empleadas” buscarán las fuentes de alimento, y si la cantidad de néctar de la nueva fuente es mayor que una anterior, memorizarán las nuevas posiciones, olvidándose de la anterior. Las “abejas empleadas” son iguales al número

de fuentes de alimento; las “observadoras” comparten información de estas fuentes y las “exploradoras” buscan nuevas, abandonando la propia (Ahmed *et al.*, 2016; Tragos *et al.*, 2013).

En Cheng y Jiang (2011) el problema de asignación espectral se resuelve utilizando el algoritmo de colonia artificial de abejas. La ubicación de una abeja o espectador representa una posible asignación de canal y la cantidad de néctar es la utilidad que se maximiza.

2.3.4 Técnicas de aprendizaje

El objetivo principal del aprendizaje autónomo es el autoaprendizaje computacional, en donde las técnicas de análisis pueden ser programadas de forma autónoma a través de la inducción del conocimiento, en 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).

2.3.4.1 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 explorar características del entorno y tomar acciones, por sí mismas, sin tener ningún conocimiento previo (Jayaweera y Christodoulou, 2011). Sin embargo, si la CR tiene información previa sobre el medio ambiente, puede aprovechar este conocimiento mediante uso de técnicas de aprendizaje supervisado (Bkassiny *et al.*, 2013).

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. Por 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. La recompensa retardada 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, 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, optimizando el desempeño en la toma de decisiones para la administración del espectro electromagnético.

Teoría de juegos

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 redes de comunicación de datos para modelar y analizar encaminamiento y asignación de recursos en entornos competitivos (Bkassiny *et al.*, 2013).

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

2.3.4.2 Supervisado

El aprendizaje supervisado se usa cuando los datos de entrenamiento están etiquetados, es decir, se conoce información *a priori* acerca del ambiente. Algoritmos de entrenamiento tales como árboles de decisión, redes neuronales, SVM y razonamiento basado en casos, funcionan bien para este caso. Difieren entre ellos en sus fortalezas y limitaciones, desafíos y aplicaciones referentes a la CR (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 inter-neuronas, conocidas como pesos sinápticos, se utilizan para almacenar el conocimiento adquirido. Algunas de las capacidades y ventajas de las redes neuronales incluyen el modelado de comportamientos no lineales y la capacidad de adaptación ante cambios pequeños. Su principal desventaja es la necesidad de realizar un entrenamiento bajo diferentes condiciones del entorno (Bkassiny *et al.*, 2013).

En (Taj y Akil, 2011) se presenta una metodología para predecir el comportamiento del espectro. La actividad del PU es modelada a través de una serie de tiempo caótica multivariable, la cual se convierte en una entrada a la red neuronal. Esta última predice la evolución de la serie de tiempo para decidir si el SU puede ocupar una oportunidad espectral determinada (Bkassiny *et al.*, 2013).

Máquina de soporte vectorial

La SVM es un conjunto de algoritmos que tiene la capacidad de aprender bajo la supervisión de un agente de *software*. Su principal modo de operación está en función de la regresión y clasificación en el aprendizaje. Esta técnica es utilizada para llegar a márgenes de clasificación en un conjunto de datos, por tanto, el principal objetivo de la SVM consiste en establecer un modelo de predicción en donde una entrada incierta puede 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 existen varios trabajos (Petrova *et al.*, 2010; Xu y Lu, 2006) sobre la aplicación de la SVM en la CR.

2.3.5 Funciones de decisión

En redes heterogéneas con facilidad de acceso ubicuo los procesos de decisión y selección se hacen más complejos debido a que las diferentes tecnologías, por lo general, ofrecen diversas características. De acuerdo con lo anterior, la asignación espectral llega a ser un problema con múltiples criterios y 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).

2.3.5.1 Función de utilidad

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

2.3.5.2 Función de costos

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

2.3.6 Algoritmos estadísticos

Existen otro tipo de técnicas que también se han utilizado para la asignación espectral en CRN, las cuales están basadas fundamentalmente en conceptos de estadística y probabilidad, tales como las redes bayesianas, cadenas de Markov y árboles de decisión.

2.3.6.1 Redes bayesianas

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

En Jiang *et al.* (2014) usan un enfoque cooperativo para estimar el estado del canal usando aprendizaje bayesiano para resolver problemas de detección multicanal.

2.3.6.2 Cadenas de Markov

Los modelos de Markov son usados para modelar procesos aleatorios que cambian de un estado a otro en el tiempo. Son procesos aleatorios donde el estado futuro depende del estado presente y dichos estados son visibles al observador, en contraste con los modelos ocultos de Markov, donde 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 las estructuras sucesivas determinan el éxito del proceso. Puede asignarse un solo paso o ser extendido a las probabilidades asociadas con cada una de las transiciones dependientes en múltiples eventos que lo preceden (Abbas *et al.*, 2015).

En Yifei *et al.* (2013) usaron toma de decisiones de Markov para el acceso dinámico al espectro en CRN. Utilizaron modelos ocultos de Markov en un canal inalámbrico y predijeron el estado del canal. Las decisiones estuvieron basadas en: sensibilidad espectral, selección de canal, modulación, esquemas de codificación y potencia transmitida. En Pham *et al.* (2014) también los utilizan en el *handoff* espectral para que el SU estudie el comportamiento del PU, pueda predecir su futuro comportamiento y asegurar la transmisión.

2.3.6.3 Árboles de decisión

El árbol de decisión es un modelo que predice el valor de una “clase objetivo” basado en la diversidad de variables de entrada. En este cada nodo tiene un criterio; cada rama representa el resultado de una prueba y cada hoja representa o contiene información de la etiqueta de una 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).

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

La tabla 2.6 resume el análisis comparativo de las diferentes técnicas para la asignación espectral en CRN, en términos de fortalezas y limitaciones.

Tabla 2.6. Análisis comparativo de las técnicas de asignación espectral.

Algoritmo	Fortalezas	Limitaciones
MCDM	Simplicidad. Fácil implementación. Respuesta rápida.	No hay una metodología analítica para estudiar su convergencia.
Lógica difusa	Decisiones rápidas basadas en reglas predefinidas. Técnicas de aprendizaje 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	Tiene optimización multi-objetivo. Se configura dinámicamente dado los cambios del entorno.	Requiere conocimiento previo del sistema. Proceso lento para encontrar una solución óptima.
Sistemas multiagente	Adecuados para problemas con múltiples jugadores. Aprendizaje y cooperación.	La complejidad y el costo computacional pueden llegar a ser altos.
Colonia artificial de abejas	Búsqueda de soluciones en paralelo.	Requiere de conocimiento <i>a priori</i> del sistema y función de aptitud.

Algoritmo	Fortalezas	Limitaciones
Aprendizaje por refuerzo	Aprendizaje autónomo usando retroalimentación y autoadaptación progresiva en tiempo real.	Necesita reglas de derivación por lo que la exactitud está basada en dichas reglas.
Teoría de juegos	Reduce la complejidad de la adaptación. Soluciones por medio de múltiples agentes. Enfoque cooperativo y no cooperativo.	Requiere conocimiento previo de diferentes parámetros del sistema y que los datos de entrenamiento estén etiquetados.
Redes neuronales	Habilidad para adaptarse a los cambios menores. Excelente para clasificación. Puede identificar nuevos patrones.	El entrenamiento puede ser lento dependiendo del tamaño de la red. Poca capacidad para generalizar. Puede sufrir de sobre entrenamiento. Datos previos.
SVM	Capacidad de generalizar. Robustez contra el ruido de entrada y casos diferentes. Mejor desempeño con poco entrenamiento en comparación con las redes neuronales.	Requiere que los datos de entrenamiento estén etiquetados. Hay que tener previo conocimiento del funcionamiento del sistema. Se vuelve complejo a medida que el problema es más grande.
Funciones de utilidad y costo	Permite encontrar óptimos con múltiples parámetros y restricciones.	Requiere que todos los parámetros estén modelados con una función analítica.
Redes bayesianas	Se basa en modelos probabilísticos.	Requiere conocimiento <i>a priori</i> del sistema. Presenta complejidad computacional.
Modelos de Markov	Se basa en modelos estadísticos y es fácilmente escalable. Puede predecir basado en la experiencia.	Requiere conocimiento previo del sistema. Presenta complejidad computacional.
Árboles de decisión	Simplicidad. Toma de decisiones mediante las configuraciones de sus ramas.	Requiere conocimiento previo del sistema. Puede sufrir sobre entrenamiento y requiere que los datos de entrenamiento estén etiquetados.

Fuente: Bkassiny *et al.* (2013), He *et al.* (2010), Tragos *et al.* (2013), Yifei *et al.* (2013).

2.3.8 Desafíos de investigación en la asignación espectral

Existen varias cuestiones de investigación abiertas que necesitan ser estudiadas para el desarrollo de la asignación espectral. Mencionamos algunas (Akyildiz *et al.*, 2006):

2.3.8.1 Modelo de decisión multivariado

La SNR no es suficiente para caracterizar las bandas espectrales en las CRN. Además de la SNR, muchos parámetros de caracterización del espectro afectan la calidad. Por tanto, la manera de combinar estos parámetros para el modelo de decisión del espectro sigue siendo una cuestión abierta.

2.3.8.2 Algoritmos adaptativos

Para desarrollar soluciones eficientes en la asignación espectral 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 se centran en un escenario y red estáticos; en tratar de encontrar una solución óptima de acuerdo con algunos criterios (Tragos *et al.*, 2013).

2.3.8.3 Selección multicanal

En las CRN se pueden utilizar simultáneamente múltiples bandas de espectro para la transmisión. Por otra parte, las CRN no requieren que las múltiples bandas seleccionadas sean contiguas. De este modo, un SU puede enviar paquetes a través de bandas de espectro no contiguas. Esta transmisión sobre múltiples bandas muestra menos degradación de calidad durante el *handoff* espectral en comparación con la transmisión convencional sobre una sola banda del espectro (Akyildiz y Li, 2006). Por ejemplo, si un PU aparece en una banda de espectro en particular, el SU tiene que desalojar solo esa banda; en el resto de bandas de espectro mantendrá la comunicación, por lo cual la degradación de la QoS puede ser mitigada (Dadallage *et al.*, 2016).

Adicionalmente, la transmisión en múltiples bandas de espectro permite menor consumo de energía en cada una. Como resultado, se consiguen 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. 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.

2.3.8.4 Selección cooperativa de espectro

El enfoque cooperativo tiene más ventajas que el no cooperativo. En la primera forma el SU vecino comparte su información de detección con el objetivo de aprovechar la diversidad espacial; el desafío allí es combinar la información de los usuarios cooperativos mientras se realiza la transmisión (Masonta *et al.*, 2013).

2.3.8.5 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 el desafío consiste en seleccionar las bandas de frecuencia apropiadas para satisfacer los requerimientos de QoS de cada SU (Masonta *et al.*, 2013).

2.4 Multiusuario

Debido a la movilidad de los nodos y la dinámica de variación del canal la precisión de las decisiones de los usuarios es limitada y sigue siendo un desafío para utilizar plenamente los escasos recursos de espectro (Jiang *et al.*, 2014a). La mayoría de los enfoques suponen que la utilidad de un SU es independiente de las decisiones tomadas por otros SU, sin embargo, tal suposición no es cierta, especialmente cuando se consideran escenarios en los que las SU comparten o compiten por ciertos recursos (Masonta *et al.*, 2013). La comunicación inalámbrica entre múltiples usuarios es uno de los principales retos para el despliegue de sistemas de próxima generación.

Para poder recopilar información global y ampliar el conocimiento limitado del usuario sobre el verdadero estado del sistema (señales y decisiones tomadas por otros nodos), los usuarios de una CR deben tener la capacidad de reconocer los cambios del entorno circundante. La información aprendida permitirá elaborar una descripción del estado desconocido del sistema y mejorar la precisión de las decisiones y, por tanto, la eficiencia de la red (Wang *et al.*, 2017).

Al tomar la decisión de acceso al canal cada SU no solo debe considerar la calidad del mismo sino, también, tener en cuenta las decisiones de acceso

del canal de otros SU; cuanto más SU acceden al mismo canal menor es el rendimiento que puede alcanzar cada uno debido a la interferencia entre ellos. Este fenómeno se conoce como externalidad negativa de la red (Jiang *et al.*, 2014b; Zhang *et al.*, 2012) o influencia negativa de los comportamientos de otros usuarios en la recompensa de un usuario, debido a que cada uno tiende a evitar tomar la misma decisión de otro para maximizar su propia utilidad.

Consideremos una CRN multiusuario con PU y pares de SU, como se muestra en la figura 2.13. Cada transmisor SU y su receptor SU correspondiente están dentro del rango de transmisión del otro. Por tanto, la existencia de comunicación entre dos SU depende de actividades que varían en el tiempo del PU. Como se ilustra, varios SU pueden acceder al mismo canal y un SU puede tener más de un canal para seleccionar (Hu *et al.*, 2016).




Figura 2.13. Escenario multiusuario.

Fuente: elaboración propia.

2.5 Estructuras colaborativas

El principal desafío de las redes CR es garantizar los requisitos de QoS sin causar degradación inaceptable de rendimiento de los PU. Son múltiples las técnicas disponibles para el análisis de las CR, sin embargo, actualmente, los

algoritmos cooperativos están tomando un fuerte impulso en aplicaciones de estructuras cognitivas. La CR y las estrategias colaborativas han brindado nuevos modelos para el uso eficiente de los recursos de radio (Hernández *et al.*, 2020).

Las estructuras cooperativas son metodologías que utiliza múltiples rutas en el entorno de radio para evitar el desvanecimiento de la señal, maximizando el rendimiento de los SU sin comprometer los requerimientos del PU (Ghanem *et al.*, 2017; Huang *et al.*, 2014).

A diferencia de los sistemas clásicos, el nodo cooperativo actúa como fuente de información y retransmisión; es una estructura bidireccional de información que permite ahorrar energía al combinar las señales recibidas de diferentes rutas espaciales y ranuras de tiempo consecutivas. Los sistemas CR cooperativos pueden aumentar la velocidad de transmisión y mejorar significativamente los parámetros de QoS, latencia, *throughput*, confiabilidad, señalización, interferencia PU, eficiencia energética, BW, SINR, y tasa de error (Hernández *et al.*, 2017; Hernández *et al.*, 2016a; Kumar *et al.*, 2016; Lertsinsrubtavee y Malouch, 2016; López *et al.*, 2015; Oyewobi y Hancke, 2017; Páez *et al.*, 2017).

En el contexto de CRN, las estrategias colaborativas permiten que los usuarios se comuniquen entre ellos para intercambiar mediciones de interferencia observadas localmente. El objetivo es aprovechar la diversidad espacial. Para lograrlo, el usuario no licenciado comparte su información de detección con los usuarios vecinos (Salgado *et al.*, 2016b; Thakur *et al.*, 2017).

Existen dos escenarios básicos: 1) transmisión cooperativa entre SU, que tiene como objetivo aumentar el rendimiento de las oportunidades espectrales; 2) transmisión cooperativa entre PU y SU, que tiene como objetivo aumentar las oportunidades de espectro de SU.

Otro tipo de clasificación es la manera como se comparte la información: centralizada, distribuida y retransmisión asistida (Akyildiz *et al.*, 2011).

La figura 2.14a muestra la cooperación de manera centralizada. Existe una unidad central (UC) encargada de coordinar el proceso. La UC selecciona la oportunidad espectral e informa a todos los SU que cooperan para que realicen individualmente la detección local y los resultados se envían a través

del canal de control. Finalmente, la UC analiza la información recibida, determina la presencia de PU y difunde la decisión a los SU que cooperan.

La figura 2.14b muestra la cooperación de manera distribuida. Después de la detección local los SU comparten resultados entre ellos. Cada SU envía, combina sus datos con los datos de detección recibidos y decide si el PU está presente o no.

La figura 2.14c ilustra la cooperación de manera asistida. SU1 y SU4 tienen un canal de informe débil y pueden sufrir pérdida de información. SU2 y SU3 tienen un canal de informe sólido, lo que les permite servir como retransmisores para ayudar a enviar los resultados de detección de SU1 y SU4 a la UC. Esta figura muestra una estructura centralizada, sin embargo, la detección cooperativa asistida puede implementar esquemas distribuidos.

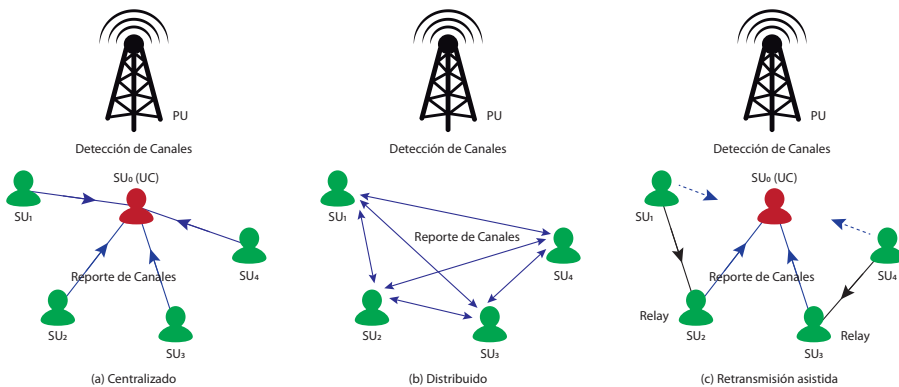


Figura 2.14. Clasificación de estrategias colaborativas.
a. Centralizado; b. Distribuido; c. Retransmisión asistida.

Fuente: elaboración propia.

2.6 Trabajos relacionados

Con respecto a investigaciones previas, no se identificaron proyectos que relacionen todos los enfoques descritos en el presente trabajo: toma de decisiones, modelos multiusuario, modelos colaborativos y DCRN. Sin embargo, se encuentran investigaciones relevantes de enfoques independientes o combinaciones de dos de ellos.

En el área de DCRN, se describen tres publicaciones que tienen relación con la presente investigación. Estas publicaciones están enfocadas en el

análisis de la QoS, el esquema de aprendizaje y acceso al espectro dinámico, utilizando estrategias como teoría de colas, cadenas de Markov, filtros digitales, entre otras. En general, los modelos descritos caracterizan las redes utilizando aproximaciones basadas en funciones probabilísticas e implementan la red descentralizada dividiendo en N canales el espectro disponible; derivando medidas de desempeño para respaldar características de QoS, política de toma de decisiones y limitaciones de *hardware*.

Los resultados obtenidos en cada uno de los trabajos permiten identificar que las estrategias seleccionadas para el ajuste de los respectivos modelos cuentan con buenos rendimientos. Xenakis *et al.* (2014) destaca la posibilidad de extender la estructura al uso compartido del espectro para redes descentralizadas, Darak *et al.* (2015) exalta la posibilidad de extender el modelo a escenarios desafiantes de CRN multiusuario y Amjad *et al.* (2016) resuelve el problema de compartir el espectro mediante la adopción de un enfoque basado en teoría de juegos. Sin embargo, las investigaciones cuentan con una característica en común: no presentan evidencia de su desempeño bajo comportamientos del PU cercanos a la realidad; desde el modelo de la red hasta el análisis de los nodos utilizan comportamientos basados en procesos aleatorios. Aunque el modelo matemático es detallado, se basa en estimaciones de posible tráfico que pueden afectar el desempeño del modelo si se implementa en escenarios más prácticos (realistas). Existen otras variables adicionales al comportamiento del PU que también pueden afectar el desempeño en aplicaciones prácticas y que los trabajos mencionados no contemplan. Ninguno aborda la consecuencia de los comportamientos de otros usuarios en la recompensa de un usuario. Aunque Darak *et al.* (2015) propone análisis multiusuario, no se evidencia de qué manera se pueden abordar los fenómenos asociados a interferencias y como las decisiones de un SU afectan otros usuarios.

A continuación describimos las tres publicaciones citadas para el área de DCRN.

El artículo “Multi-parameter performance analysis for decentralized cognitive radio networks” de Xenakis *et al.* (2014) realiza un análisis del impacto de la actividad del PU y SU, el desvanecimiento de canales y las colas de longitud finita, en el rendimiento de las DCRN. Analiza también la teoría de

colas y deriva 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 variables en el rendimiento del sistema y ponen de relieve las principales ventajas y desventajas del rendimiento en las DCRN.

El artículo “Low complexity and efficient dynamic spectrum learning and tunable bandwidth access for heterogeneous decentralized Cognitive Radio Networks” de Darak *et al.* (2015) propone un esquema de aprendizaje y acceso al espectro dinámico de baja complejidad y eficiencia para DCRN y heterogéneas de próxima generación. 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 demás existentes.

El artículo “Coexistence in heterogeneous spectrum through distributed correlated equilibrium in cognitive radio networks” de Amjad *et al.* (2016) analiza múltiples técnicas de cadenas de Markov para estudiar fenómenos de desigualdad en escenarios heterogéneos de CRN coexistentes. Propone una solución descentralizada que no limite la capacidad de *hardware* de un dispositivo de CR e introduce una capa MAC 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*.

En el área de toma de decisiones y arquitecturas descentralizadas hay dos publicaciones que trabajan en conjunto los dos enfoques y tienen relación con la presente investigación. Darak *et al.* (2017) diseña una política de toma de decisiones que permite, desde un punto de vista energético, implementar redes inalámbricas descentralizadas eficientes. Hasegawa *et al.* (2014) analiza la toma de decisiones en redes cognitivas heterogéneas como un problema de flujo de costos mínimo solucionado a través de una red neuronal. Para la caracterización y posterior análisis de efectividad utiliza métricas exclusivas para los modelos realizados que pueden presentar un alto grado de dificultad al momento de extrapolar estas mediciones o indicadores a otro tipo de estrategias que analicen casos equivalentes. Para el proceso de toma de decisiones, los autores no amplían las discusiones sobre

otras posibles métricas de desempeño, ni incluyen propuestas que permitan expandir los indicadores a escenarios multiusuario. Al igual que los trabajos citados previamente, los modelos utilizados para la caracterización de la red descentralizada utilizan tráficos estocásticos, lo que no permite evidenciar validaciones cercanas a la realidad.

A continuación, se describen dos publicaciones que trabajan en conjunto los enfoques de toma de decisiones y arquitecturas descentralizadas.

Darak *et al.* (2017) en su artículo “Decision making policy for RF energy harvesting enabled cognitive radios in decentralized wireless networks” propone una nueva política de toma de decisiones para DCRN basada en acceso oportunista al espectro con capacidades de recolección de energía por radiofrecuencia que 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 de 10-35 % en el rendimiento de la DCRN y una reducción de 40-90 % en el número de conmutaciones de subbandas en comparación con las políticas de toma de decisiones existentes.

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

En el área de toma de decisiones y CRN, describimos seis publicaciones que trabajan en conjunto los dos enfoques y que tienen relación con la presente investigación. En general, para el proceso de toma de decisiones, los trabajos analizados utilizan como estrategias: modelos probabilísticos, de optimización y técnicas de *machine learning*. Tripathi *et al.* (2019) implementa lógica difusa, Kaur y Sharma (2018a) optimización por enjambres de partículas, López (2017) redes neuronales, sistemas neurodifusos y SVM. Li *et al.* (2016) técnicas evolutivas y modelos bioinspirados; Martins y Andrade (2018) redes neurales, cadenas de Markov y árboles predictores y Joda y

Zorzi (2015) utiliza técnicas heurísticas. Cada una de estas propuestas argumenta la selección del modelo implementado en función de los resultados obtenidos en investigaciones previas.

Durante los últimos años se ha propuesto en la literatura un considerable número de técnicas, sin embargo, y como se identifica en los documentos que se citan a continuación, no hay ningún algoritmo que sea mejor para un problema general si un algoritmo supera a otros en alguna función; habrá alguna tarea en la que otros algoritmos serán mejores. Una buena estrategia para mejorar el rendimiento consiste en proponer algoritmos basados en estructuras híbridas, esto permite caracterizar las ventajas y desventajas de dos o más estrategias para luego combinarlas, de tal forma que el algoritmo global sea mejor que los individuales. Aunque los resultados obtenidos son buenos, los autores no evalúan el efecto en la carga computacional. Una característica relevante para este tipo de problemas es que los algoritmos para toma de decisiones no solo deben entregar buenos resultados y resolver tareas complejas: deben diseñarse para que sean eficientes; el objetivo final es poder evaluar el desempeño en escenarios reales.

Adicionalmente, las estrategias utilizadas tienen buenos esquemas de decisión, lo cual se puede identificar en el análisis cuantitativo presentado en cada una de las respectivas investigaciones; sin embargo, desde la estructura del proceso de toma de decisiones, no cuentan con un módulo de intercambio de información, por tanto, no es posible identificar el efecto de las decisiones de un usuario sobre los demás. Joda y Zorzi (2015) consideran esta característica como trabajo futuro, resaltando la importancia de implementar escenarios multiusuarios.

A continuación, describimos seis publicaciones que trabajan en conjunto los enfoques de toma de decisiones y CRN.

El artículo “Analysis and Comparison of Different Fuzzy Inference Systems Used in Decision Making for Secondary Users in Cognitive Radio Network” de Tripathi *et al.* (2019) implementa 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 *Sugeno Fuzzy Inference System* y *Mamdani Fuzzy Inference System*. El trabajo concluye con

una lista de ventajas y desventajas para cada una de las técnicas donde se obtiene una correlación mayor al 0,95 entre Mamdani y Sugeno, por tanto, la selección entre estrategias depende de los requisitos de aplicación. Desde una perspectiva computacional, Sugeno presenta una mayor eficiencia que Mamdani para más de 100 reglas.

El artículo “PSO based Multiobjective Optimization for parameter adaptation in CR based IoTs” de Kaur *et al.* (2018b) estudia 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. Los resultados son comparados con un algoritmo genético con codificación real. Para aplicaciones de *email*, voz y video el promedio de *fitness* para enjambres de partículas es de 0,8614; 0,7327 y 0,8597 respectivamente, comparado con el 0,8121; 0,5975 y 0,7183 obtenido para el algoritmo genético con codificación real. Se demuestra que el módulo de decisión cognitiva basado en enjambres de partículas supera la implementación basada en el algoritmo genético con codificación real en todos los escenarios, en términos de valor de la función *fitness* y los valores óptimos de métricas de decisión.

En su tesis de doctorado “Implementación de un modelo predictor para la toma de decisiones en redes inalámbricas de radio cognitiva” López (2017) desarrolla metodologías para mejorar la selección y asignación de canales a través de técnicas que aumentan la precisión en estimación de presencia/ausencia de usuarios en canales licenciados. Utiliza los modelos LSTM, ANFIS-GRID-FCM y SVM para predecir el comportamiento de los PU; implementa una red neuronal perceptrón multicapa para gestionar anticipadamente las solicitudes de los SU en la base central, y SVM y ANFIS para generar esquemas de selección de canales eficientes. Los resultados muestran disminución en el tiempo de selección y asignación de canales.

El artículo “Optimization spectrum decision parameters in CR using autonomously search algorithm” de Li *et al.* (2016) introduce el concepto de bioinspiración y su aplicación en la toma de decisiones. Se propone un algoritmo de búsqueda autónomo basado en la evolución de la población, reproducción, selección y mutación. La estrategia propuesta es comparada

con un algoritmo de optimización por enjambres de partículas y un algoritmo genérico. Los resultados experimentales muestran que el algoritmo de búsqueda autónomo satisface la demanda de comunicación y tiene un buen rendimiento. 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.

El artículo “Analysis of machine learning algorithms for spectrum decision in cognitive radios” de Martins y Andrade (2018) presenta un análisis de algoritmos de *machine learning* para desarrollo de CRN en *hardware* real. Se implementan en dos escenarios distintos tres métodos para la decisión del espectro: redes neuronales artificiales, bosques aleatorios y modelos ocultos de Markov. Los resultados muestran que el modelo oculto de Markov obtuvo la mejor tasa media de entrega en los dos escenarios evaluados —fue 4 % mejor que la red neuronal artificial y 16 % mejor que el bosque aleatorio en el patrón de tráfico alto; en el patrón medio fue 5,9 % mejor que la red neuronal artificial y 9,7 % mejor que el bosque aleatorio. En el patrón bajo fue 5,7 % mejor que la red neuronal artificial y 3 % mejor que el bosque aleatorio—.

El artículo “Decentralized Heuristic Access Policy Design for Two Cognitive Secondary Users under a Primary Type-I HARQ Process” de Joda y Zorzi (2015) propone políticas de acceso heurístico descentralizadas para dos SU cognitivos. Debido a la falta de unidad central, el problema se modela como un proceso de decisión descentralizado parcialmente observable de Markov. Por la complejidad del modelo se diseñan políticas de acceso que aprovechan la redundancia introducida por el protocolo Híbrido-ARQ de Tipo I. Los resultados muestran que las políticas heurísticas diseñadas aumentan el rendimiento, la flexibilidad y robustez, frente a los cambios de canal. Como trabajo futuro, los autores resaltan la importancia de implementar escenarios multiusuarios.

En el área de toma de decisiones y estructuras multiusuario mencionamos dos publicaciones que trabajan en conjunto los dos enfoques y que tienen relación con la presente investigación. Los trabajos analizados utilizan técnicas heurísticas, metaheurísticas, estrategias probabilísticas basadas en cadenas de Markov y teoría de juegos. Ambos documentos utilizan modelos

de sistemas multiagente para establecer o analizar objetivos comunes de los usuarios a través de técnicas de cooperación. Rizk *et al.* (2018) presenta la revisión de los últimos cinco años en aplicaciones de sistemas inteligentes dentro de los cuales se incluye la CR, y Roy *et al.* (2017) estudia el conflicto entre dos niveles de SU utilizando teoría de juegos. Una característica general de los documentos es que no analizan las consecuencias de las decisiones tomadas, lo que indica que las estrategias de cooperación parten del supuesto de que la utilidad de un SU es independiente de las decisiones tomadas por otros SU, lo cual, no es la estrategia más viable si se consideran escenarios en los que los SU comparten o compiten por ciertos recursos. Para el caso particular de Roy *et al.* (2017) se limita a dos SU y un PU, con una arquitectura de tipo centralizada y tráfico emulado por Qualnet. Si bien un tráfico real no implica validaciones totalmente reales —ya que existen otras variables exógenas que pueden afectar el desempeño del modelo como el consumo de energía—, el hecho de utilizar tráfico real (capturado en campañas de medición) para las pruebas y validaciones garantiza un acercamiento a escenarios más prácticos en la realidad.

A continuación, se describen dos publicaciones que trabajan en conjunto los enfoques de toma de decisiones y estructuras multiusuario.

Rizk *et al.* (2018) en su artículo “Decision Making in Multiagent Systems: A Survey” realiza una revisión de los modelos cooperativos más relevantes para la toma de decisiones en sistemas multiagente. Presenta modelos basados en procesos de decisión de Markov, teoría de juegos, teoría de grafos e inteligencia de enjambres. Las diferentes técnicas son analizadas según su criterio de optimalidad y 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 avances y retos para los próximos años, la necesidad de incluir en el proceso de toma de decisiones 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” utiliza la teoría de juegos para estudiar el conflicto y la cooperación entre dos niveles de SU. El análisis comparativo muestra que la probabilidad de bloqueo, caída y saturación de canales se reduce en 81 %, 79 %, 84 %, respectivamente y la probabilidad de aceptación aumenta en 91 %.

En el área de toma de decisiones y escenarios colaborativos se identificaron dos trabajos. Giral *et al.* (2020b) proponen un modelo colaborativo a través de un nodo de información bidireccional con cinco niveles de colaboración. El proceso de toma de decisiones se realiza por medio de técnicas multicriterio implementando datos reales. Como métrica de desempeño se utiliza el número de *handoff* fallidos. De acuerdo con los resultados obtenidos se establece que el nivel de colaboración que conduce a resultados eficientes está entre 20 % y 50 %. Ye *et al.* (2017) analizan el costo de la interferencia para los modelos de decisión de interferencia cognitiva colaborativa. Se propone un algoritmo de búsqueda tabú-colonia de abejas artificial para el proceso de toma de decisiones. Para verificar la solidez y capacidad del algoritmo propuesto se analiza el número de iteraciones en función del nivel de interferencia. Los resultados muestran que la solución propuesta presenta una mayor probabilidad de identificar el punto óptimo.

En el área de escenarios multiusuarios y escenarios colaborativos se identificaron dos trabajos. Khedkar y Patil (2019) proponen una técnica de toma de decisiones *intra-coalition* e *inter-coalition* para una CRN multiusuario. Para la asignación del espectro la estrategia utilizada es *Pareto optimal coalitions*, donde se utilizan métricas convencionales de toma de decisiones como *OR/AND/máximo*, *voting/half voting rules*. Los resultados muestran una carga de trabajo reducida y un aumento en la velocidad del proceso de decisión. Rizk *et al.* (2018) realizan una revisión de los modelos colaborativos más relevantes para la toma de decisiones en sistemas multiagentes (MAS), presentan modelos basados en procesos de decisión de Markov, teoría de juegos, teoría de grafos e inteligencia de enjambres. Las diferentes técnicas son analizadas según su criterio de optimalidad y su aplicación.

De acuerdo con los antecedentes, la tabla 2.7 presenta el análisis de los enfoques: toma de decisiones, modelos multiusuario y DCRN en función de las estrategias implementadas y las limitaciones identificadas.

Tabla 2.7. Análisis de los enfoques de acuerdo con las estrategias implementadas y las limitaciones.

Enfoques	Estrategias implementadas	Limitaciones
DCRN	<ul style="list-style-type: none"> *Teoría de colas *Cadenas de Markov *Filtros digitales 	<ul style="list-style-type: none"> *Estructura de la DCRN utilizando aproximaciones basadas en funciones probabilísticas. *No se presenta evidencia de su desempeño bajo comportamientos reales del PU.
Toma de decisiones y CRN	<ul style="list-style-type: none"> *Modelos probabilísticos: cadenas de Markov *Técnicas optimización: técnicas heurísticas, técnicas evolutivas y modelos bioinspirados *Técnicas de <i>machine learning</i>: lógica difusa, redes neuronales, árboles predictores 	<ul style="list-style-type: none"> *Estructura de la DCRN utilizando aproximaciones basadas en funciones probabilísticas. *No se evalúa el efecto en la carga computacional. *No se presenta evidencia de su desempeño bajo comportamientos reales del PU. *No es posible identificar el efecto de las decisiones de un usuario sobre los demás.
Toma de decisiones y DCRN	<ul style="list-style-type: none"> *Propuestas de políticas de toma de decisiones *Optimización a través de redes neuronales 	<ul style="list-style-type: none"> *Estructura de la DCRN utilizando aproximaciones basadas en funciones probabilísticas. *Métricas exclusivas para los modelos propuestos. *No se presenta evidencia de su desempeño bajo comportamientos reales del PU.
Toma de decisiones y estructuras multiusuario	<ul style="list-style-type: none"> *Técnicas heurísticas *Técnicas metaheurísticas *Estrategias probabilísticas: cadenas de Markov, teoría de juegos *Sistemas multiagente 	<ul style="list-style-type: none"> *Estructura de la DCRN utilizando aproximaciones basadas en funciones probabilísticas. *No es posible identificar el efecto de las decisiones de un usuario sobre los demás. *Las estrategias de cooperación parten del supuesto de que la utilidad de un SU es independiente de las decisiones tomadas por otros SU.
Toma de decisiones y escenarios colaborativos	<ul style="list-style-type: none"> *Técnicas multicriterio *Nodo bidireccional *Algoritmo de búsqueda tá-bú-colonia de abejas artificial 	<ul style="list-style-type: none"> *No es posible identificar el efecto de las decisiones.

Enfoques	Estrategias implementadas	Limitaciones
Escenarios multiusuarios y escenarios colaborativos	<ul style="list-style-type: none">*Sistemas multiagentes*Cadenas de Markov*Teoría de juegos*Teoría de grafos*Inteligencia de enjambres	<ul style="list-style-type: none">*Métricas exclusivas para los modelos propuestos.*No se presenta evidencia de su desempeño bajo comportamientos reales del PU.*No es posible identificar el efecto de las decisiones de un usuario sobre los demás.

Fuente: elaboración propia.

En conclusión, se evidencia que aún no hay estudios que relacionen en conjunto los cuatro enfoques: (1) decisión de espectro, (2) ambiente multiusuario, (3) ambiente colaborativo y (4) arquitectura descentralizada y, además, los oriente hacia las redes de radio cognitiva, lo cual se convierte en el principal aporte de este trabajo de investigación. Adicionalmente, el hecho de trabajar con datos de ocupación espectral reales obtenidos a partir de una campaña de medición le da al trabajo un mayor valor agregado y diferenciador con respecto a las publicaciones descritas anteriormente, dado que en ellas se trabaja con datos espectrales generados aleatoriamente.

3. Metodología

Debido a que la información de ocupación espectral tiene un papel relevante en esta investigación, enunciamos primero la metodología que se llevó a cabo para capturar, organizar y procesar los datos experimentales de ocupación espectral. Luego, presentamos el módulo colaborativo. Posteriormente, hay una descripción del módulo de selección de oportunidades espectrales junto con los resultados obtenidos para, finalmente, exponer 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.

3.1 Selección de *software* y equipos

Para desarrollar la presente investigación se utilizaron los siguientes recursos:

- Un sistema de monitorización del espectro (descrito en la tabla 3.1) para realizar el proceso de captura de datos de potencia espectral en las bandas GSM y Wi-Fi, dentro de los cuales se destaca el analizador de espectro MS2721B Anritsu.
- Múltiples bases de datos electrónicas para realizar la consulta y construcción de la revisión literaria sobre *handoff* espectral para CRN.
- El *software* Matlab para desarrollar el simulador y los correspondientes algoritmos de decisión espectral.
- Un computador de escritorio — cuyas características están descritas en la tabla 3.2— para realizar el procesamiento de la información, el diseño del

modelo propuesto, el desarrollo de la experimentación, el análisis de los resultados y la documentación de esta investigación.

Tabla 3.1. 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 3.2. Especificaciones del equipo de cómputo.

Característica	Valor de referencia
Procesador	AMD FX 9590 de 8 núcleos y 4.71 GHz
Memoria RAM	DDR 3 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.

3.2 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 tipos de redes diferentes: GSM y Wi-Fi. La razón de escoger la banda GSM está basada en la alta demanda de telefonía celular y la baja QoS (Pedraza *et al.*, 2016). En el caso de la banda Wi-Fi, la razón obedece al interés de analizar el desempeño de los algoritmos en un ambiente más estocástico y la viabilidad de la posible utilización de esta banda por parte de SU de telefonía móvil (Cárdenas *et al.*, 2016).

3.3 Captura y procesamiento de datos de ocupación espectral

Esta sección describe el procedimiento realizado para obtener la información de ocupación espectral, la cantidad de información almacenada y su posterior procesamiento para servir de insumo a la herramienta de simulación. El análisis se presenta para la red GSM; en el caso de Wi-Fi se sigue una metodología similar.

La figura 3.1 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 y la configuración de los parámetros técnicos del analizador de espectro para la banda GSM se exponen en la tabla 3.3.

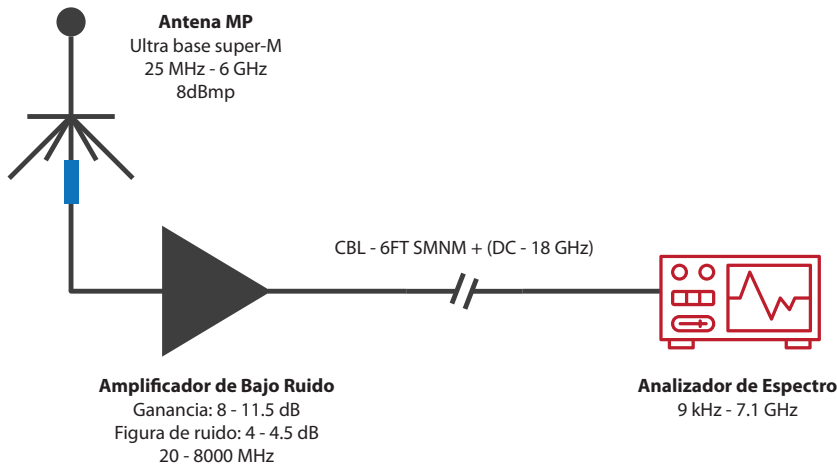


Figura 3.1. Configuración experimental para medir la ocupación espectral.
Fuente: elaboración propia.

Tabla 3.3. Configuración de los parámetros técnicos del analizador de espectro para GSM.

Parámetro	Valor
Banda de frecuencia	824 MHz a 874 MHz
Sistema de comunicación	Móvil
Tecnología de comunicación	GSM
Técnica de detección	Detección de energía

Parámetro	Valor
Tiempo de captura	1 mes
Tiempo de barrido	290 ms
Resolución de BW	100 kHz
Span	50 MHz
Puntos por Span	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 y el Span, con el fin de garantizar una adecuada medida en función del piso de ruido y el BW 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. La campaña de medición se realizó durante un mes en total, 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 el capítulo tres de Pedraza *et al.* (2016).

El valor del Span corresponde al rango de frecuencia que está siendo analizado, en este caso 50 MHz (874 MHz – 824 MHz), y Puntos Por Span determina el número de canales de frecuencia (división uniforme de una porción de espectro) para los cuales el analizador de espectro midió el correspondiente nivel de potencia durante cada barrido. De acuerdo con lo anterior, en cada barrido, el analizador de espectro entrega la información del valor de potencia medido en dBm correspondiente a 500 canales de frecuencia (potenciales oportunidades espectrales), con un BW de 100 kHz (50MHz / 500) cada uno.

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

A partir de la información anterior se construyó una matriz de potencia de $8.937.216 \times 500$, la cual 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 (cada instante de tiempo 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.

3.4 Nivel de tráfico

Se realizó un análisis previo a la matriz de potencias para GSM basado en la AP. El resultado obtenido se muestra en la figura 3.2. De este análisis resalta la determinación de un rango de frecuencia en donde la disponibilidad de la matriz de potencia es alta. Para que el análisis de los modelos sea equitativo se requiere realizar ajustes previos a este rango de frecuencias.

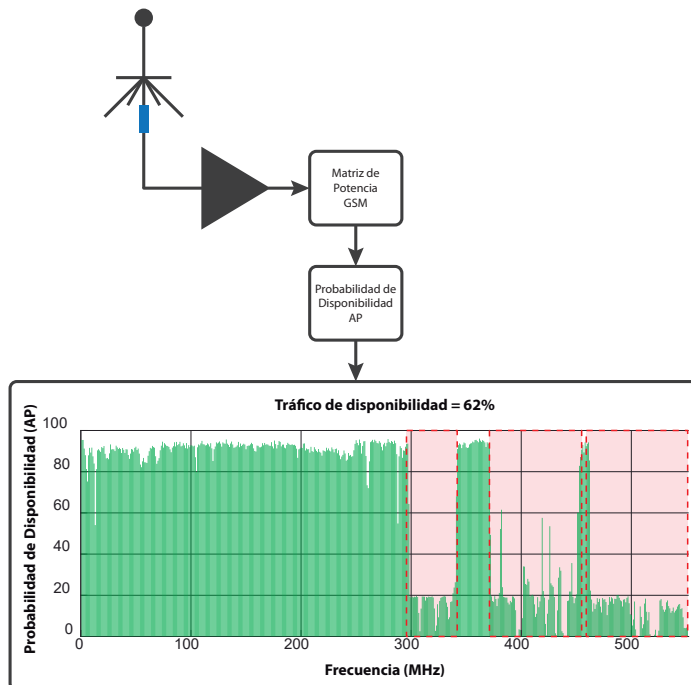


Figura 3.2. Probabilidad de disponibilidad matriz de potencia.

Fuente: elaboración propia.

Para realizar el ajuste al rango de frecuencia se implementa una estrategia que involucra todos los canales de la matriz de potencia; consiste en generar un conjunto de matrices para diferentes niveles de AP.

La metodología —descrita en la figura 3.3— toma la matriz de potencia medida. A través del nivel de *threshold* se obtiene la matriz de disponibilidad; a esta se le determina la AP actual y se compara con la AP objetivo. A partir de esta comparación se establece el ajuste que se debe realizar a la matriz de disponibilidad. El ajuste consiste en cambiar 0 por 1 si se requiere aumentar la AP actual o, 1 por 0 si se requiere disminuir la AP actual. Los cambios se realizan según un criterio de porcentaje para no afectar el ETA. El proceso previamente descrito es realizado en el bloque “Matriz de tráfico objetivo”, donde se analizan las múltiples matrices obtenidas. De acuerdo con los resultados obtenidos se seleccionan los niveles de tráfico para la base de datos.

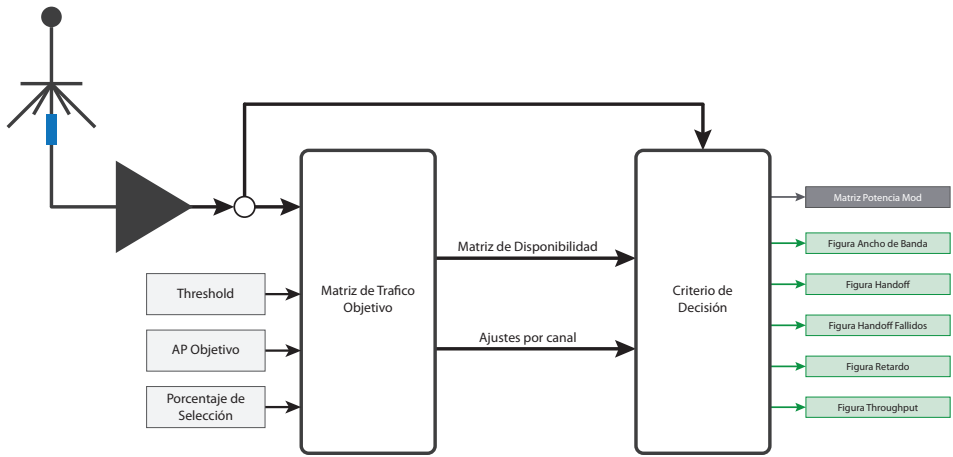


Figura 3.3. Metodología para AP objetivo.

Fuente: elaboración propia.

3.4.1 Matriz de tráfico objetivo

Este bloque es el encargado de realizar todo el proceso de ajuste según los requerimientos de AP objetivo y criterio de porcentaje. El primer paso consiste en tomar la matriz de potencia medida y convertirla en disponibilidad —como se muestra en la figura 3.4 este proceso se realiza a través del nivel de *threshold*—; posteriormente se analiza el AP actual, calculando la AP por canal y a través de los datos obtenidos, la AP global.




Figura 3.4. Probabilidad de disponibilidad actual.

Fuente: elaboración propia.

Se compara la información —la AP actual con la AP objetivo— y se determina si se requiere aumentar la cantidad o disminuir la disponibilidad por canal. En el Algoritmo 1 se toman los criterios actuales, se comparan con los objetivos y se determina el factor que se debe agregar a cada canal —aditivo o sustractivo, depende si se quiere aumentar el nivel de tráfico o disminuir—. Para analizar los múltiples escenarios, se analizan nueve casos de AP objetivo: 10 %, 20 %, 30 %, 40 %, 50 %, 60 %, 70 %, 80 % y 90 %.

Algoritmo 1. Ajuste según criterios de AP objetivo.

Probabilidad de Disponibilidad Objetivo
Variables de entrada: Traffic_goal, Available
<pre>AP_Old = mean(Available); Mean_AP = mean(AP_Old); if Traffic_goal < Mean_PD Y = -(Traffic_goal*length(AP_Old)-sum(AP_Old)) / length(AP_Old); AP_Goal = AP_Old-Y; else Y = (Traffic_goal*length(AP_Old)-sum(AP_Old)) / length(AP_Old); AP_Goal = AP_Old + Y; end</pre>

Fuente: elaboración propia.

De acuerdo con el factor que se debe agregar a cada canal se determina si se debe incrementar o reducir la cantidad de ceros —0 por 1 si se requiere aumentar la AP actual del canal o, 1 por 0 si se requiere disminuir el AP actual del canal—. Estos cambios se plantearon en dos escenarios; el primero, a través de cambios aleatorios, es decir, se toma la ubicación de los elementos a cambiar y de forma aleatoria se modifican hasta obtener la AP de interés. El problema de estos cambios aleatorios es que el criterio del ETA presentaba fuertes variaciones, por tanto, no fue viable su implementación. El segundo escenario incluye el ETA para realizar los cambios —se toman los conjuntos de 1 o 0 según el caso, y de forma porcentual se realizan las modificaciones—.

En la figura 3.5 se describe la metodología utilizada: la columna representa instantes de tiempo y la fila el canal de interés. Para el caso particular donde se requiere aumentar el tráfico del canal, se toma el conjunto de columnas (tiempo) disponibles consecutivas y se realizan cambios de acuerdo con el tamaño y al criterio de porcentaje de selección; como el tamaño de columnas consecutivas es de 10, si se requiere realizar un cambio en el 10 %, se toma 1 canal y se modifica su estado; si se requiere realizar un cambio en el 40 %, se toman 4 columnas y se modifica su estado. Esto significa que los cambios

son proporcionales al tamaño del conjunto de columnas consecutivos. El proceso se realiza hasta cumplir con la AP objetivo. Los cambios se realizan desde los mayores conjuntos de columnas consecutivas hasta los menores.

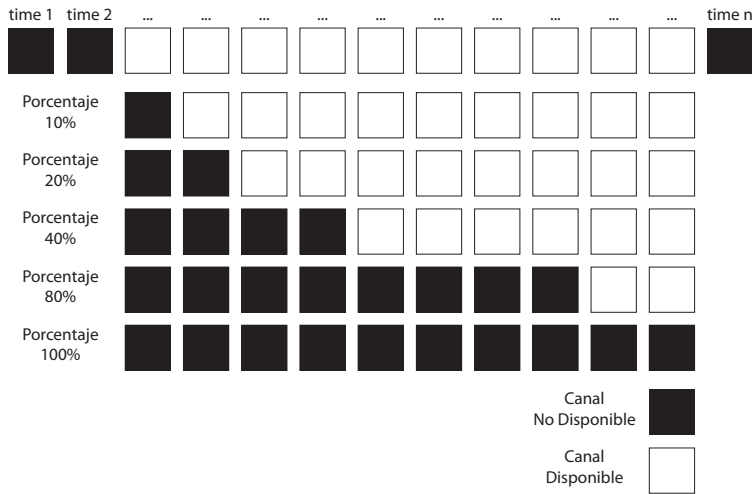


Figura 3.5. Modificaciones porcentuales bajo criterios de ETA.

Fuente: elaboración propia.

Según la metodología (figura 3.3) el porcentaje de selección es un parámetro de entrada del modelo. Para la presente investigación se tomaron diferentes porcentajes de selección: 10%, 20%, 30%, 40%, 50%, 60%, 70%, 80% y 90%. Luego se combinaron con nueve casos de AP objetivo: 10%, 20%, 30%, 40%, 50%, 60%, 70%, 80% y 90%. Para cada caso de AP objetivo se analizaron nueve porcentajes de selección, por tanto, se obtuvieron 81 matrices de disponibilidad.

3.4.2 Criterio de decisión

Para las 81 matrices de disponibilidad, se analizó el AAD, AAFH, AAH, AAT y ABW; se compararon los resultados, semejanzas y diferencias; finalmente, se seleccionó la AP objetivo de 40% con porcentaje de selección de 50% para tráfico alto y AP objetivo de 80% con porcentaje de selección de 50%. La figura 3.6 presenta el comportamiento de la AP para las matrices seleccionadas; la gráfica de color verde es el comportamiento original.

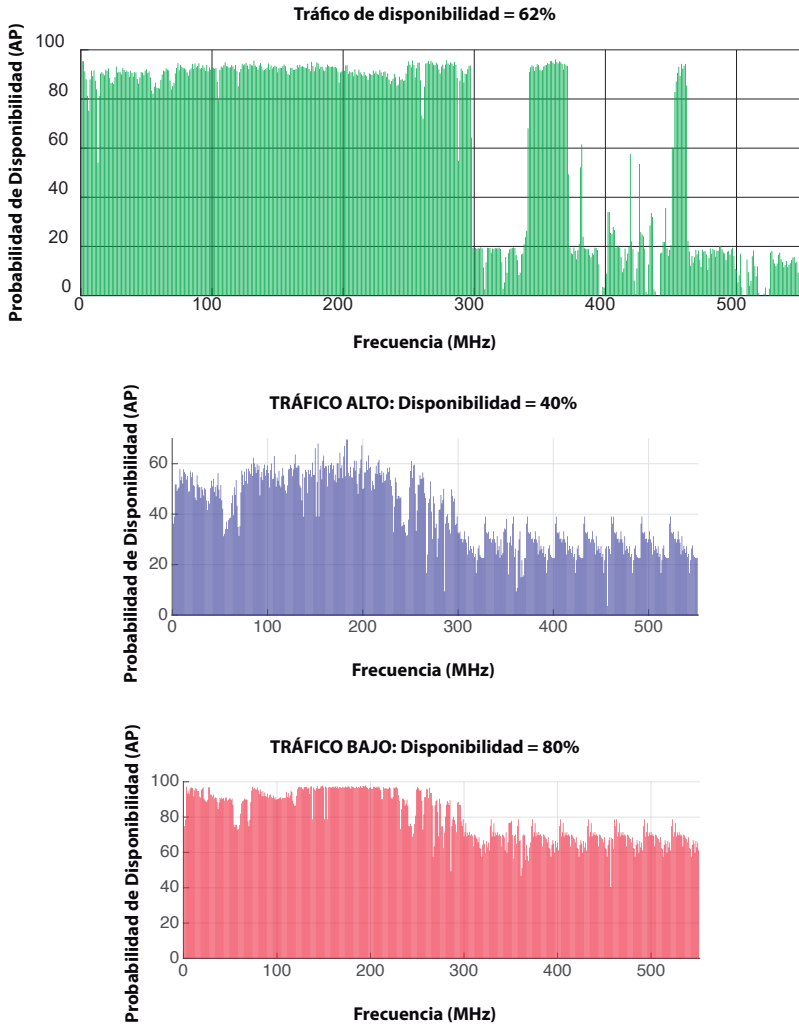


Figura 3.6. Probabilidad de disponibilidad para tráfico alto y bajo GSM.

Fuente: elaboración propia.

3.4.3 Base de datos de ocupación espectral

Para implementar las estrategias de toma de decisiones es necesario generar un grupo de datos que pueda entrenar los modelos y otro grupo de datos que los valide. Por tanto, se requieren dos bases de datos: una para entrenamiento y otra para evaluación. Adicionalmente, cada base de datos se clasifica de

acuerdo con el tipo de matriz (Potencia y Disponibilidad) y a los niveles de tráfico (HT y LT). Las tablas 3.4 y 3.5 describen la estructura de la base de datos generada para la matriz de potencia y disponibilidad.

La matriz de disponibilidad se obtiene a través del nivel de Umbral (-95 dBm); este nivel se selecciona teniendo en cuenta la búsqueda de equilibrio entre la probabilidad de detección y la probabilidad de falsa alarma (Digham *et al.*, 2007; Lehtomaki *et al.*, 2005).

Tabla 3.4. Estructura de la base de datos para la matriz de potencia.

Matriz de Potencia	Nivel de Tráfico	Filas	Columnas
Evaluación	HT	1800	500
	LT		
Entrenamiento	HT	10,800	500
	LT		

Fuente: elaboración propia.

Tabla 3.5. Estructura de la base de datos para la matriz de disponibilidad.

Matriz de Disponibilidad	Nivel de Tráfico	Filas	Columnas
Evaluación	HT	1800	500
	LT		
Entrenamiento	HT	10,800	500
	LT		

Fuente: elaboración propia.

3.5 Modelo propuesto

La figura 3.7 presenta el modelo de asignación espectral multiusuario para redes de radio cognitiva descentralizadas donde se tiene un ambiente de radio que intercambia información de los SU de forma permanente con el módulo colaborativo. El módulo colaborativo es la estructura de comunicación entre los módulos propuestos y el ambiente de radio de forma permanente, este módulo se comunica con la base de datos para almacenar y actualiza la información sobre las solicitudes y requerimientos de los SU.

mejor oportunidad espectral. Como se mencionó en los capítulos primero y segundo, la mayor parte de trabajos de investigación en radio cognitiva se fundamentan en una red centralizada donde toda la información está organizada en un solo lugar y acceder a ella resulta más fácil y beneficioso para la toma de decisiones. Sin embargo, aunque la observación y conocimiento global de la red presenta ventajas, para sistemas a gran escala y aplicaciones en redes de seguridad pública no es la mejor opción: el aumento en los costos de medición, la complejidad del sistema, la cantidad de información que se debe controlar, sumado al desequilibrio y potencial caos si la estación base llega a fallar (vulnerabilidad), la convierte en una arquitectura no factible para todas las estructuras de CRN (Pankratev *et al.*, 2019).

Las redes distribuidas —por ejemplo, MANET— se caracterizan por su alta movilidad, autonomía, adaptación e independencia. Sus aplicaciones se encuentran en escenarios que involucran redes VANET (Bujari *et al.*, 2018), vehículos aéreos no tripulados (Bujari *et al.*, 2018), vigilancia urbana y misiones de búsqueda o rescate (Dhamodharavadhani, 2015). Sin embargo, la falta de infraestructura, topología dinámica, 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 retardo es alto (Kongsiriwattana y Gardner-Stephen, 2017) y el BW es bajo al igual que su rendimiento por las frecuentes fallas de enlace (Dhamodharavadhani, 2015; Goswami, 2017). La anterior problemática puede ser solucionada si se distribuye la responsabilidad de la información en diferentes puntos de control, criterio base de las DCRN. Ahora, debido a que en las DCRN no se centraliza la información y 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, el cual segmenta la matriz de entrenamiento de acuerdo con un número establecido de usuarios. Adicionalmente, caracteriza niveles de colaboración a través del porcentaje de información que se comparte. A continuación, se realiza la descripción de la metodología utilizada para el módulo colaborativo.

3.5.1.1 Estructura del módulo implementado

La figura 3.8 presenta el diagrama de bloques del módulo colaborativo. Los bloques donde convergen las señales de entrada y salida corresponden a la metodología que segmenta la matriz de potencia de acuerdo con los niveles de colaboración. La idea general del módulo es dividir la matriz de potencia (base de datos) en submatrices y caracterizar los niveles de colaboración de acuerdo con la cantidad de usuarios que serán parte del análisis del proceso de decisión espectral. Cada submatriz representa un usuario, por tanto, el total de submatrices corresponde al número total de usuarios. La cantidad de información a compartir se selecciona de acuerdo con los niveles de colaboración que son caracterizados por el tipo de segmentación, el método de división y el porcentaje de selección. La descripción de cada una de las variables de entrada y su respectivo ajuste se presenta en la tabla 3.6.

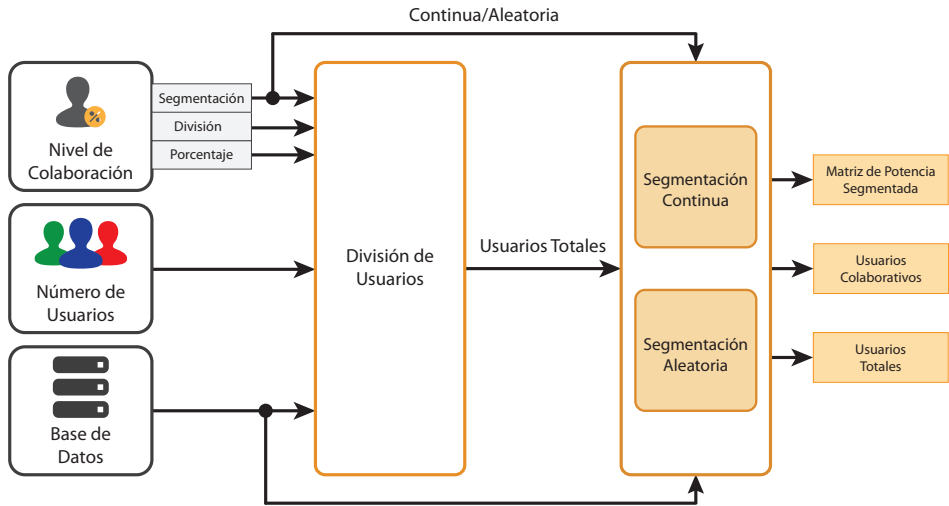


Figura 3.8. Diagrama general del módulo colaborativo.

Fuente: elaboración propia.

Tabla 3.6. Descripción de las variables de entrada para el módulo colaborativo.

Variable	Ajuste		Descripción
Nivel de colaboración	Segmentación	Aleatoria	La selección de usuarios para la simulación, de acuerdo con el ajuste del porcentaje, se realiza de forma aleatoria.
		Continua	La selección de usuarios para la simulación, de acuerdo con el ajuste del porcentaje, se realiza en orden, por filas o por columnas.
	División	Fila	<p><i>* Si el número de usuarios es mayor o igual a 10:</i> Se dividen las filas de la matriz de potencia en 10 partes iguales y las columnas se dividen en m partes hasta completar el número de usuarios (Usuarios Totales = $10(m)$)</p> <p><i>* Si el número de usuarios es menor a 2:</i> Se dividen las filas de la matriz de potencia en 2 partes iguales y las columnas se dividen en m partes hasta completar el número de usuarios (Usuarios Totales = $2(m)$).</p>
		Columna	<p><i>* Si el número de usuarios es mayor o igual a 10:</i> Se dividen las columnas de la matriz de potencia en 10 partes iguales y las filas se dividen en m partes hasta completar el número de usuarios (Usuarios Totales = $10(m)$)</p> <p><i>* Si el número de usuarios es menor a 2:</i> Se dividen las columnas de la matriz de potencia en 2 partes iguales y las filas se dividen en m partes hasta completar el número de usuarios (Usuarios Totales = $2(m)$).</p>
	Porcentaje	10%–100 %	Porcentaje de usuarios que participaran en el entrenamiento.
Número de usuarios	1-1000		Número de usuarios (submatrices) que segmentan la matriz de potencia.
Base de datos	Tipos de red (GSM o Wi-Fi)		Matriz de tráfico.

Fuente: elaboración propia.

Una descripción particular omitiendo el tipo de segmentación y el método de división se presenta en la figura 3.9. Se toma la información de entrada (Base de datos) y se divide en n submatrices (Número de usuarios = n). Después de la división en submatrices se selecciona la cantidad de información a

compartir en el entrenamiento según el nivel de colaboración (Porcentaje). De acuerdo con la figura 3.9, para un número de usuarios igual a cuatro ($n = 4$), un nivel de colaboración de 25 % (Porcentaje = 25 %) corresponde a un entrenamiento basado en la información de un solo usuario (Usuarios colaborativos = 1); un nivel de colaboración de 50 % (Porcentaje = 50 %) corresponde a un entrenamiento basado en la información de dos usuarios (Usuarios colaborativos = 2), un nivel de colaboración de 75 % (Porcentaje = 75 %) corresponde a un entrenamiento basado en la información de tres usuarios (Usuarios colaborativos = 3), si el nivel es de 100 % (Porcentaje = 100 %) el entrenamiento utiliza toda la información disponible (Usuarios colaborativos = 100).

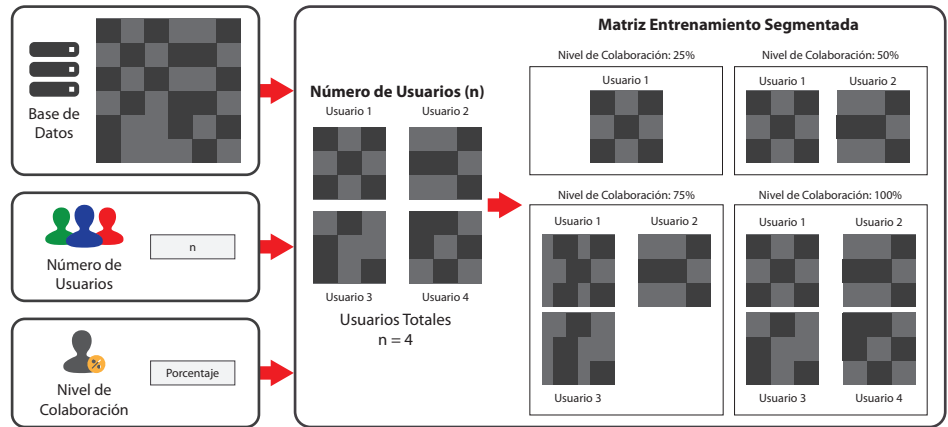


Figura 3.9. Operación particular del modelo colaborativo.

Fuente: elaboración propia.

Para una mejor comprensión de la estrategia, a continuación, se presentan dos ejemplos. En contraste con el caso descrito en la figura 3.9, estos dos escenarios son más específicos ya que involucran todos los ajustes del modelo colaborativo. La figura 3.10 corresponde a la base de datos de entrada de los dos escenarios, representa una matriz de disponibilidad binaria con 36 datos, obtenida a través de una matriz de potencia con un umbral de decisión. Cada columna representa un canal y cada fila representa el tiempo, donde un valor de “1” representa un canal disponible y “0” representa un canal no disponible.

Time	Channels					
	1	1	0	1	0	0
	1	1	1	1	1	1
	0	1	0	0	0	1
	0	1	0	1	0	0
	1	0	0	1	1	0
	1	1	1	0	1	1

Figura 3.10. Base de datos de entrada para los dos escenarios.**Fuente:** elaboración propia.

Los criterios de cada uno de los escenarios se presentan en la tabla 3.7 y tabla 3.8. Para los dos casos, la matriz de disponibilidad es segmentada en seis usuarios (equivalente a seis submatrices), el porcentaje es un valor seleccionado aleatoriamente, 50 % para el primer escenario y 67 % para el segundo escenario. Como se describió previamente, este parámetro indica el porcentaje de usuarios que serán parte del entrenamiento, equivalente a un nivel de colaboración de 50 % (caso 1) y 67 % (caso 2), por tanto, si 6 es el total de usuarios (100 %), 50 % corresponde a un entrenamiento basado en la información de 3 de usuarios, y 67 % corresponde a un entrenamiento basado en la información de 4 usuarios. Este porcentaje, es un parámetro ajustable que puede variar entre 10 % y 100 % según el caso de estudio a analizar. El modelo colaborativo está programado para adaptarse a cualquier parámetro de entrada. Si el nivel de colaboración ajusta un entrenamiento basado en la información de un número de usuarios decimal, el modelo toma el entero más cercano. Las variaciones en el modelo por las variables División y Segmentación se describen en el análisis individual de cada uno de los casos de estudio.

Tabla 3.7. Ajuste modelo colaborativo para el primer escenario.

Base de datos	Matriz de disponibilidad figura 3.10	
Número de usuarios	6	
Nivel de colaboración	Segmentación	Fila
	División	Aleatoria
	Porcentaje	50 %

Fuente: elaboración propia.

Tabla 3.8. Ajuste modelo colaborativo para el segundo escenario.

Base de datos	Matriz de disponibilidad figura 3.10	
Número de usuarios	6	
Nivel de colaboración	Segmentación	Continua
	División	Columna
	Porcentaje	67 %

Fuente: elaboración propia.

Primer escenario: Según la información presentada en la tabla 3.7, el primer escenario segmenta la matriz de disponibilidad en seis usuarios con división por filas. Como el número de usuarios es inferior a diez y la segmentación es por fila, el módulo toma la matriz de disponibilidad y la divide en dos columnas (para usuarios mayores a diez, consulte la tabla 3.6). El módulo determina que para segmentar la matriz de disponibilidad en seis submatrices con una división de dos columnas, el número de filas debe ser tres. La figura 3.11 presenta la matriz de disponibilidad de acuerdo con el número de usuarios y la división.

De los seis usuarios, para el nivel de colaboración, solo 50 % serán parte de los usuarios colaborativos (Porcentaje = 50 %), lo que corresponde a tres usuarios (Usuarios colaborativos = 3). La selección de los tres usuarios se realiza de forma aleatoria. La figura 3.12 ilustra la matriz de entrenamiento de acuerdo con los ajustes descritos en la tabla 3.7.

	Channels						
Time	User 1			User 2			Row 1
	1	1	0	1	0	0	
	1	1	1	1	1	1	
	User 3			User 4			Row 2
	0	1	0	0	0	1	
	0	1	0	1	0	0	
	User 5			User 6			Row 3
	1	0	0	1	1	0	
	1	1	1	0	1	1	
	Column 1			Column 2			

Figura 3.11. Matriz de disponibilidad seccionado para 6 usuarios con división por fila.
Fuente: elaboración propia.

		Channels					
Time	User 1				Row 1		
	1	1	0				
	1	1	1				
				User 4	Row 2		
				0		0	1
				1		0	0
User 5				Row 3			
1	0	0					
1	1	1					
	Column 1		Column 2				

Figura 3.12. Matriz de entrenamiento para 3 usuarios, con 50 % de nivel de colaboración y selección aleatoria.
Fuente: elaboración propia.

Segundo escenario: Según la información presentada en la tabla 3.8, el segundo escenario segmenta la matriz de disponibilidad en seis usuarios con división por columna. Como el número de usuarios es inferior a diez y la segmentación es por columna, el módulo toma la matriz de disponibilidad y la divide en dos filas (para usuarios mayores a diez, consulte la tabla 3.6). El módulo determina que para segmentar la matriz de disponibilidad en seis submatrices con una división de dos filas, el número de columnas debe ser tres. La figura 3.13 presenta la matriz de disponibilidad de acuerdo con el número de usuarios y la división.

		Channels				
Time	User 1		User 2		User 3	
	1	1	0	1	0	0
	1	1	1	1	1	1
	0	1	0	0	0	1
	User 4		User 5		User 6	
	0	1	0	1	0	0
Row 2	1	0	0	1	1	0
	1	1	1	0	1	1
	Column 1		Column 2		Column 3	

Figura 3.13. Matriz de disponibilidad seccionado para 6 usuarios con división por columna.

Fuente: elaboración propia.

De los seis usuarios, para el nivel de colaboración, solo 67% serán parte de los usuarios colaborativos (Porcentaje = 50%), lo que corresponde a cuatro usuarios (Usuarios colaborativos = 4), la selección de los cuatro usuarios se realiza de forma continua. La figura 3.14 ilustra la matriz de entrenamiento de acuerdo con los ajustes descritos en la tabla 3.8.

		Channels				
Time	User 1		User 2		User 3	
	1	1	0	1	0	0
	1	1	1	1	1	1
	0	1	0	0	0	1
	User 4					
	0	1				
	1	0				
	1	1				
		Column 1	Column 2	Column 3		

Figura 3.14. Matriz entrenamiento para 4 SU, con 67% de colaboración y selección aleatoria.

Fuente: elaboración propia.

Finalmente, las variables de salida del módulo contienen la matriz segmentada con la información de los usuarios colaborativos seleccionados para el proceso de toma de decisiones. Adicionalmente, como variable de salida se incluye la matriz de potencia dividida por el total de usuarios.

3.5.2 Módulo multiusuario

En las CRN, los usuarios deben tomar decisiones inteligentes en función de la variación del espectro y de las acciones adoptadas por otros usuarios. A partir de esta dinámica, la probabilidad de que dos o más usuarios elijan el mismo canal es alta, especialmente cuando el número de usuarios es mayor que el número de canales disponibles: cuantos más seleccionen el mismo canal, menor será la utilidad y mayor el número de interferencias por el acceso simultáneo (Abbas *et al.*, 2015). Para modelar la red bajo parámetros de tráfico realistas es necesario analizar el acceso multiusuario.

Al tomar la decisión de acceso al canal cada SU no solo debe considerar la calidad del canal sino, también, tener en cuenta las decisiones de acceso al canal de otros SU; cuanto más acceden los SU al mismo canal menor es

el rendimiento que puede alcanzar cada SU debido a la interferencia entre ellos. Este fenómeno se conoce como externalidad negativa de la red (Jiang *et al.*, 2014b; Zhang *et al.*, 2012). La influencia negativa de los comportamientos de otros usuarios en la recompensa de un usuario se debe a que cada usuario tiende a evitar tomar la misma decisión de otro para maximizar su propia utilidad.

De acuerdo con lo relevante del proceso de toma de decisiones y la necesidad de incluir el efecto de las decisiones de los usuarios sobre la utilidad de los otros (para de esta manera poder obtener validaciones más útiles en la realidad), la presente investigación implementó y adaptó un módulo multiusuarios al modelo de decisión espectral propuesto, el cual permite incluir múltiples usuarios seriales, para diferentes tipos de aplicaciones, con niveles de prioridad y bandas de canales de diferentes tamaño. Adicionalmente, para incluir otras características asociadas al comportamiento real de la banda espectral, el módulo cuenta con la posibilidad de agregar usuarios aleatorios que serán parte de la simulación en instantes de tiempos distintos con los mismos requerimientos. A continuación, se realiza la descripción de la metodología utilizada para el módulo multiusuario.

3.5.2.1 Estructura del módulo implementado

La figura 3.15 presenta el diagrama de bloques del módulo multiusuario donde convergen las señales de entrada y salida correspondientes a la caracterización que se realiza de los diferentes usuarios. La idea general del módulo es analizar el comportamiento de los modelos de decisión espectral cuando se presenta acceso multiusuario. Para lograr este objetivo se generan múltiples usuarios con diferentes requerimientos.

El módulo permite manejar cuatro tipos de bandas (aplicaciones). Cada una de estas bandas tiene la posibilidad de solicitar prioridad y acceso a múltiples canales. Múltiples usuarios y sus respectivas características serán parte del modelo durante todo el tiempo de simulación. Esta metodología se denominó: “Modelo convencional”. El módulo cuenta con la posibilidad de incluir usuarios aleatorios, sin interés de análisis, que aparecen en tiempos aleatorios y que no estarán en todo el tiempo de simulación, sin embargo, con características similares a los usuarios que participan en todo el proceso.

Esta estructura se denominó: “Modelo real”. Para generar las métricas los múltiples usuarios se introducen en un algoritmo de búsqueda que analiza el comportamiento de los *handoff* espectral. La descripción de cada una de las variables de entrada y su respectivo ajuste se presentan en la tabla 3.9.

Tabla 3.9. Descripción de las variables de entrada para el módulo multiusuario.

Variable	Ajuste	Descripción
Bandas Multicanal	1–4	Número de aplicaciones seleccionados para la simulación.
Canales	1–10	Número de canales necesarios para cada aplicación seleccionado.
Porcentaje	25 % – 50 % – 75 % – 100 %	Porcentaje de usuarios que adquieren la característica de la aplicación y de la cantidad de canales.
Número de Usuarios Seriales	1–30	Número de SU que de forma simultánea acceden al espectro. Estos usuarios se caracterizan por intercambiar información entre ellos antes de iniciar el proceso de acceso oportunista.
Modo de Simulación	Modo Real	Se incluyen usuarios aleatorios.
	Modo Convencional	No se incluyen usuarios aleatorios.

Fuente: elaboración propia.

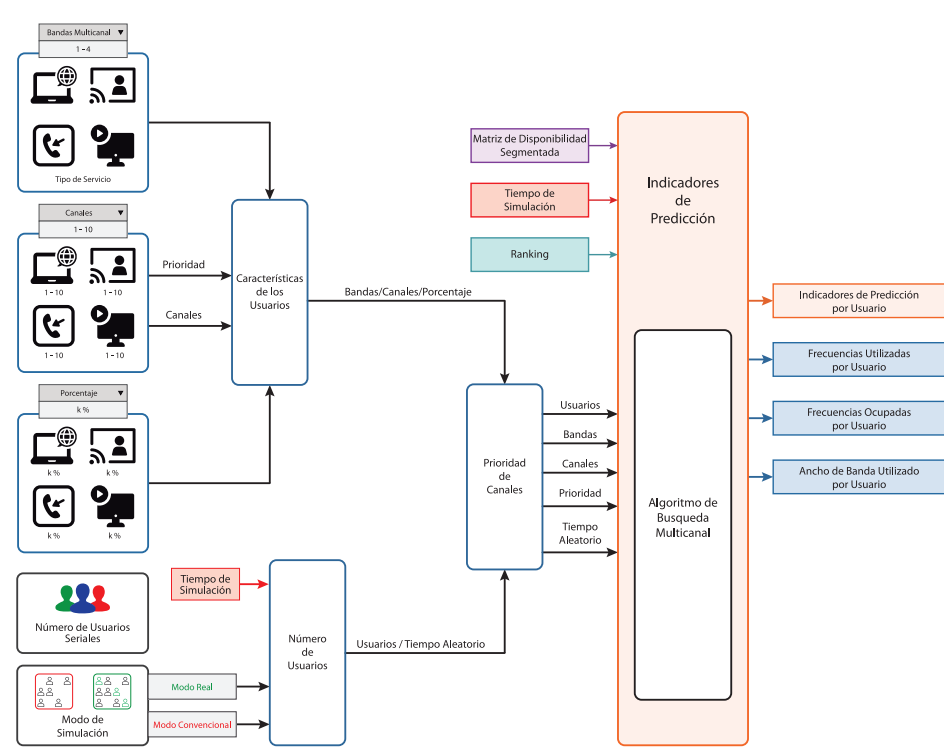


Figura 3.15. Diagrama general del módulo multiusuario.

Fuente: elaboración propia.

3.5.2.2 Características de los usuarios

Las características de los usuarios establecen la cantidad de bandas multicanales, el número de canales por banda, la prioridad y el porcentaje de usuarios que tendrán estas características. El objetivo es manejar diferentes escenarios de demanda de canales por usuario; las bandas multicanal representan el tipo de aplicación y el número de canales la demanda de BW o el requerimiento de acuerdo con el tipo de aplicación, la cual puede ser de un solo canal o de múltiples canales. La asignación de la prioridad se realiza según el orden de ajuste de la información. La figura 3.16 muestra la estructura de parametrización de la información.

Bandas Multicanal

Canales	<input type="text" value=""/>	Porcentaje	<input type="text" value=""/>	Prioridad: 1
Canales	<input type="text" value=""/>	Porcentaje	<input type="text" value=""/>	Prioridad: 2
Canales	<input type="text" value=""/>	Porcentaje	<input type="text" value=""/>	Prioridad: 3
Canales	<input type="text" value=""/>	Porcentaje	<input type="text" value=""/>	Prioridad: 4

Figura 3.16. Ajustes para características de los usuarios.

Fuente: elaboración propia.

Una descripción particular de las características de los usuarios se presenta en la figura 3.17. En este caso específico se seleccionaron tres bandas multi-canal (tres tipos de aplicaciones). La banda con la mayor prioridad requiere de tres canales de BW; la banda con la segunda prioridad requiere de dos canales de BW y la banda con la tercera prioridad requiere de cuatro canales de BW. De acuerdo con esta información 25% de los usuarios tendrá prioridad 1; 50% de los usuarios tendrá prioridad 2 y finalmente, 25% de los usuarios tendrá prioridad 3.

Bandas Multicanal












Canales	<input type="text" value="3"/>	Porcentaje	<input type="text" value="25"/>	Prioridad: 1				
Canales	<input type="text" value="2"/>	Porcentaje	<input type="text" value="50"/>	Prioridad: 2				
Canales	<input type="text" value="4"/>	Porcentaje	<input type="text" value="25"/>	Prioridad: 3				

Figura 3.17. Descripción particular para las características de los usuarios.

Fuente: elaboración propia.

3.5.2.3 Número de usuarios

El número de usuarios depende del modo simulación —convencional o real— como se muestra en la figura 3.18. Para establecer el total de usuarios se requiere un bloque de multiplexación; si se utiliza el modo convencional, la asignación de usuarios y tiempo aleatorio se deshabilita y por tanto el total de usuarios corresponde al número de usuarios. Si se utiliza el modo real, el bloque de usuarios y tiempo aleatorio se habilita y, por tanto, el total de usuarios aumenta con respecto al modo convencional. A continuación, se presenta la descripción de la metodología utilizada para los bloques de la figura 3.18.

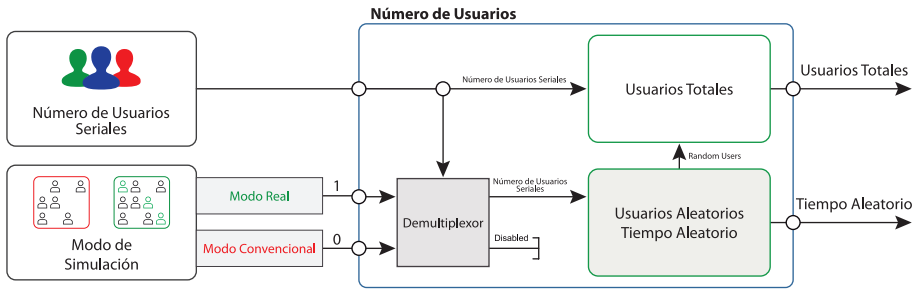


Figura 3.18. Usuarios totales en modo convencional y en modo real.

Fuente: elaboración propia.

Usuarios totales

Se cuantifican en función del modo ajustado —convencional o real—. El Algoritmo 2 presenta la estructura de programación implementada. No es posible que los dos modos estén habilitados de forma simultánea. La salida “Tiempo aleatorio” solo estará disponible para el modo real.

Algoritmo 2. Estructura para la asignación de usuarios totales.

Usuarios Totales
<pre> % Usuarios Totales Modo Real If Modo Real == 1 && Modo Convencional == 0 Usuarios Totales = Número de Usuarios Seriales + Usuarios Aleatorios Tiempo Aleatorio = Enable end % Usuarios Totales Modo Convencional If Modo Real == 0 && Modo Convencional == 1 Usuarios Totales = Número de Usuarios Seriales Tiempo Aleatorio = Disable end </pre>

Modo convencional

Este modo no genera usuarios aleatorios ni tiempo aleatorios. El total de usuarios, según describe el Algoritmo 2, corresponde al parámetro de usuarios que se ajusta a la entrada del modelo.

Modo real

Genera usuarios aleatorios, sin interés de análisis, que no estarán en todo el tiempo de simulación. Para el número de usuarios aleatorios se genera un número entero distribuido uniformemente entre uno y el valor máximo de usuarios que se ajusta a la entrada de modelo. Esto significa que el número de usuarios aleatorios nunca podrá ser superior a los usuarios convencionales. Si los usuarios aleatorios permanecen durante todo el tiempo de simulación, el modelo real tendría el mismo comportamiento del modelo convencional, por tanto, los usuarios aleatorios ingresan y salen en tiempos diferentes a los ajustados en el modelo convencional.

Por criterio de diseño, un usuario aleatorio solo podrá ingresar cuando se supere el 30% del tiempo de transmisión en minutos del SU, y podrá participar en el proceso de decisión espectral hasta alcanzar el 70%. Para establecer el tiempo de permanencia con los criterios previamente descritos, por usuario aleatorio, se genera un vector entero aleatorio ascendente de dos posiciones con un rango entre 30 y 70, equivalente a los porcentajes de tiempo

para ingreso y salida. La figura 3.19 presenta el diagrama de asignación de usuarios y tiempo aleatorio, este corresponde a la descripción específica del bloque “Usuarios Aleatorios Tiempo Aleatorio” de la figura 31.8. Como se muestra en la figura 3.19, para obtener el número de usuarios aleatorios y su tiempo de permanencia se requiere de las variables de entrada “Número de Usuarios Seriales (NSU)” y “Tiempo de simulación”, respectivamente. Además, se requieren tres constantes: valor mínimo de usuarios aleatorios —el cual corresponde a uno (1)— y límites de tiempo para ingreso (30%) y salida (70%) de los usuarios aleatorios. La distribución de probabilidad utilizada corresponde a una distribución uniforme (función *randperm* de Matlab).

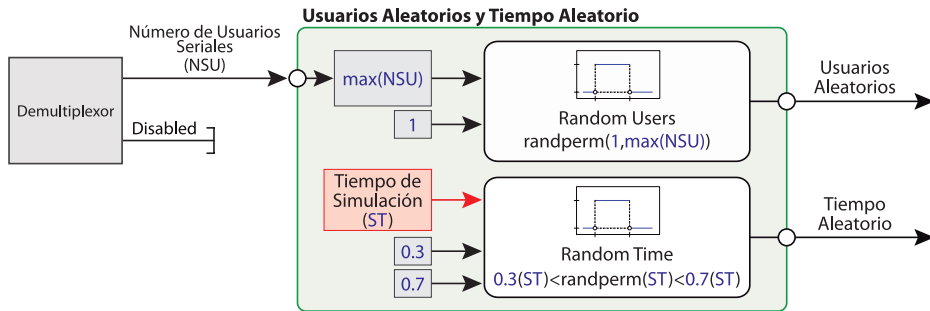


Figura 3.19. Asignación de usuarios y tiempo aleatorio.

Fuente: elaboración propia.

3.5.2.4 Prioridad de los canales

Como se describió en la sección 3.5.2.2, la asignación de prioridad se realiza de acuerdo con el orden de ajuste de la información. Esta incluye información asociada a la aplicación (banda) y a la cantidad de canales. Si se utiliza el modo convencional, el total de usuarios por cada prioridad está en función de la proporcionalidad —asignada en cada relación porcentual de las características del usuario—. El Algoritmo 3 presenta la estructura para prioridad de canales en modo convencional.

Algoritmo 3. Prioridad de canales en modo convencional.

Modo Convencional
<pre> % Usuarios Totales Modo Convencional if Modo Real == 0 && Modo Convencional == 1 Usuarios = Número de Usuarios Seriales Usuarios_Prioridad_1 = Porcentaje_Prioridad_1 * Usuarios Usuarios_Prioridad_2 = Porcentaje_Prioridad_2 * Usuarios Usuarios_Prioridad_3 = Porcentaje_Prioridad_3 * Usuarios Usuarios_Prioridad_4 = Porcentaje_Prioridad_4 * Usuarios Tiempo Aleatorio = Disable end </pre>

Para la prioridad de canales en modo real se requiere, primero, ubicar los usuarios aleatorios y a partir de este criterio realizar la asignación.

Ubicación de usuarios aleatorios

Es importante diferenciar el tiempo de permanencia y la ubicación de un usuario aleatorio en la estructura multiusuario. Por criterio de diseño, un usuario aleatorio solo podrá ingresar cuando se supere el 30% de tiempo de transmisión en minutos del SU, y permanecer hasta alcanzar el 70%. La ubicación solo se analiza cuando el usuario aleatorio ingresa. Como se muestra en la figura 3.20, un usuario aleatorio puede ubicarse al inicio, final y en una posición intermedia de los usuarios convencionales. La ubicación se realiza a través de una estructura aleatoria. Como se muestra en la figura 3.20 la prioridad de los usuarios convencionales no se ve afectada.




Figura 3.20. Ubicación de usuarios aleatorios.
Fuente: elaboración propia.

Asignación de prioridad

Cada usuario aleatorio debe adquirir una prioridad, la cual es asignada según la ubicación y el porcentaje de usuarios de cada prioridad. Para comprender esta asignación, la figura 3.21 presenta un ejemplo: se cuenta con tres usuarios convencionales y un usuario aleatorio; el usuario aleatorio fue ubicado entre los usuarios con prioridad 1 y prioridad 2 —como se describió previamente, la ubicación fue seleccionada de forma aleatoria—. Por las características asignadas, 25 % de los usuarios tendrán prioridad 1, 50 % tendrán prioridad 2 y 25 % tendrán prioridad 3; por tanto, solo un usuario tendrá prioridad 1 (se maneja el criterio del mayor entero ya que no es posible definir usuarios decimales), dos usuarios tendrán prioridad 2 y un usuario, prioridad 3. La selección de los usuarios se realiza en orden de ubicación, por ende, como describe la figura 3.21, el usuario aleatorio adquiere las características de los usuarios con prioridad 2.




Figura 3.21. Asignación de prioridad.

Fuente: elaboración propia.

3.5.2.5 Algoritmo de búsqueda multicanal

Es el encargado del análisis de movilidad espectral. Según el vector de posiciones el algoritmo *ranking* realiza saltos de columna en la matriz de disponibilidad hasta encontrar un canal disponible; al encontrarlo, realiza un cambio de fila (instante de tiempo) en la matriz de disponibilidad. Los saltos de columna, de fila; el tiempo y la disponibilidad son almacenados en un vector y retroalimentados, al finalizar la simulación, en una base de datos.

El proceso es equivalente para un usuario con un canal y para múltiples usuarios con múltiples canales. La diferencia más relevante se presenta en el cambio de fila (instante de tiempo), la cual, para múltiples usuarios, solo se realiza cuando todos los usuarios encuentran oportunidades espectrales o cuando los requerimientos de canales son superiores a la disponibilidad.

La figura 3.22 presenta dos escenarios de movilidad espectral para múltiples usuarios en modo convencional, o en modo real si la transmisión en minutos del SU es inferior a 30 % o superior a 70 %. Se cuenta con tres usuarios, para este caso particular. La prioridad 2 tiene un porcentaje de 50 % y la prioridad 1 y 3 de 25 %. Evidentemente, en números enteros, la asignación de usuarios para cada prioridad no es posible; el módulo se reconfigura y asigna a cada prioridad un porcentaje de 33 %, por tanto, cada prioridad tendrá un solo usuario. El objetivo del algoritmo de búsqueda es encontrar

las oportunidades espectrales (canales disponibles) de acuerdo con el vector *ranking*, donde, el valor más bajo en la posición corresponde a los canales con mayor AP.

En el primer escenario (figura 3.22) el usuario con prioridad 1 y requerimiento de 3 canales, encuentra oportunidades espectrales en las posiciones del vector *ranking* [1 2 3]. El usuario con prioridad 2 y con requerimiento de 2 canales, encuentra oportunidades espectrales en las posiciones del vector *ranking* [5 6] —no es posible ocupar la posición [4] ya que el canal se encuentra ocupado por un PU—; adicionalmente, el algoritmo no realiza la búsqueda en los canales [1 2 3] —previamente asignados a usuarios con prioridad 1—, el módulo se retroalimenta e informa que estos canales no están disponibles. Finalmente, el usuario con prioridad 3 y con requerimiento de 4 canales encuentra oportunidades espectrales en las posiciones del vector *ranking* [7 9 10 11] —no es posible ocupar la posición [4] ya que el canal se encuentra ocupado por un PU—. Como todos los usuarios encuentran oportunidades espectrales para todos los requerimientos de canales, el algoritmo realiza un salto de fila e inicia nuevamente la búsqueda.

En el segundo escenario (figura 3.22) los requerimientos de canales son superiores a la disponibilidad. Al finalizar la búsqueda, los usuarios con prioridad 3 y requerimiento de 4 canales encuentran solamente dos oportunidades espectrales de las 4 que requieren; para este caso particular, el módulo informa sobre el resultado, salta de fila e inicia nuevamente la búsqueda.

Los saltos de columna, de fila; el tiempo y la disponibilidad por usuario son almacenados en un vector y retroalimentados al finalizar la simulación en una base de datos.

La figura 3.23 presenta un escenario de movilidad espectral para múltiples usuarios en modo real. Se cuenta con tres usuarios convencionales y uno aleatorio que adquiere las características de la prioridad 2 (ejemplo descrito en la asignación de prioridades de la sección 3.5.2.4), para este caso particular, la prioridad 2 tiene un porcentaje de 50 % y, la prioridad 1 y 3 de 25 %, por tanto, la prioridad 2 tendrá dos usuarios y la prioridad 1 y 3 un solo usuario.

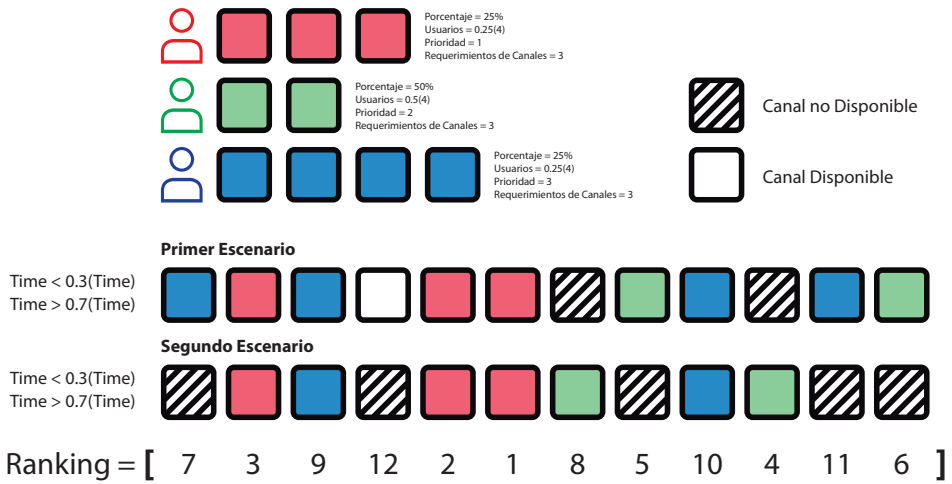


Figura 3.22. Movilidad espectral para múltiples usuarios en modo convencional.

Fuente: elaboración propia.

De acuerdo con el escenario descrito en la figura 3.23, el usuario con prioridad 1 y con requerimiento de 3 canales encuentra oportunidades espectrales en las posiciones del vector *ranking* [1 2 3]. Para la prioridad 2 hay dos usuarios con requerimiento de dos canales por usuario, el aleatorio encuentra oportunidades espectrales en las posiciones del vector *ranking* [4 6], y el convencional en las posiciones del vector *ranking* [7 8], no es posible ocupar la posición [5] ya que el canal se encuentra ocupado por un PU. Finalmente, el usuario con prioridad 3 y con requerimiento de cuatro canales, encuentra oportunidades espectrales para solo tres de los cuatro canales en las posiciones del vector *ranking* [9 10 11], el módulo informa sobre el resultado, salta de fila e inicia nuevamente la búsqueda.

Los saltos de columna y fila, el tiempo y la disponibilidad por usuario son almacenados en un vector y retroalimentados al finalizar la simulación en una base de datos.




Figura 3.23. Movilidad espectral para múltiples usuarios en modo real.

Fuente: elaboración propia.

3.5.3 Módulo predictivo

Una alternativa para reducir los niveles de interferencia entre PU y SU es predecir el comportamiento del PU o las oportunidades espectrales. Los algoritmos de predicción pronostican la llegada del PU, minimizando los niveles de interferencia al realizar el cambio de canal antes de su arribo. Estas estrategias son ampliamente utilizadas en aplicaciones con alta sensibilidad al retardo. Adicionalmente, reducen la degradación de la calidad del canal y mejoran el proceso de asignación de canales.

El propósito de este módulo es incluir estrategias y métricas para la predicción del comportamiento del usuario principal. La figura 3.24 presenta la estructura del módulo predictivo, que requiere información de los módulos colaborativo y multiusuario. Como modelos de predicción se utilizan las técnicas *Naive Bayes* y *Regresión logística*.

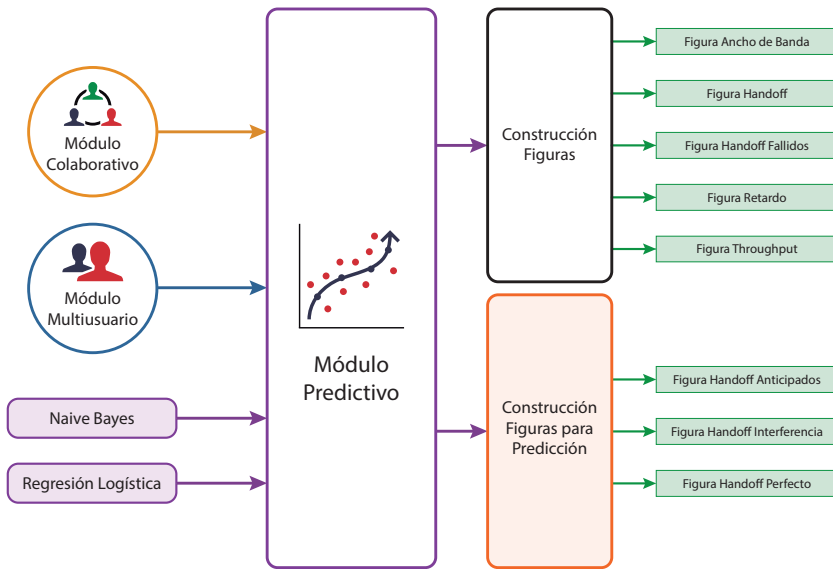


Figura 3.24. Estructura del módulo predictivo.

Fuente: elaboración propia.

A continuación, se presenta la descripción metodológica de los modelos Regresión logística y *Naive Bayes*.

Regresión logística

La regresión logística es un método estadístico que permite estimar la probabilidad de una variable cualitativa binaria en función de una variable cuantitativa. La principal ventaja es que puede utilizar diversas variables explicativas al mismo tiempo. Aunque parezca trivial, esta característica es importante debido al gran interés en conocer el impacto de estas variables sobre la variable de respuesta.

Una regresión logística modelará la probabilidad del resultado en función de las características individuales y está dada por la ecuación (3.1).

$$\log\left(\frac{\pi}{1-\pi}\right) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_m x_m \quad (3.1)$$

Donde π indica la probabilidad de un evento, β son los coeficientes de regresión asociados con el grupo de referencia y X_i las variables explicativas.

Para aplicaciones con una alta sensibilidad al retardo, el esquema genera una matriz de predicción de disponibilidad que requiere variables explicativas que estén asociadas y se puedan analizar de forma simultánea. Por tanto, se definieron como variables explicativas: AP, ETA, PSINR. De acuerdo con las variables definidas, la ecuación (3.1) se expresa en términos de la ecuación (3.2).

$$\log\left(\frac{\pi}{1-\pi}\right) = \beta_0 + \beta_1(\text{AP}) + \beta_2(\text{ETA}) + \beta_3(\text{PSINR}) \quad (3.2)$$

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. La figura 3.25 muestra el proceso de entrenamiento.




Figura 3.25. Proceso de entrenamiento de la regresión logística.

Fuente: elaboración propia.

Como se muestra en la figura 3.26, la estrategia propuesta contiene dos procesos: el primero, realiza el entrenamiento del modelo de predicción con las variables explicativas durante un período de tiempo establecido; el entrenamiento estima el costo y gradiente de la estrategia de regresión, los cuales permiten ajustar el predictor. El segundo proceso asigna la ocupación de cada canal de acuerdo con la predicción, generando una matriz de disponibilidad. Posteriormente, la información de la matriz de predicción es tomada por el algoritmo de búsqueda del modelo multiusuario para obtener las métricas de desempeño.

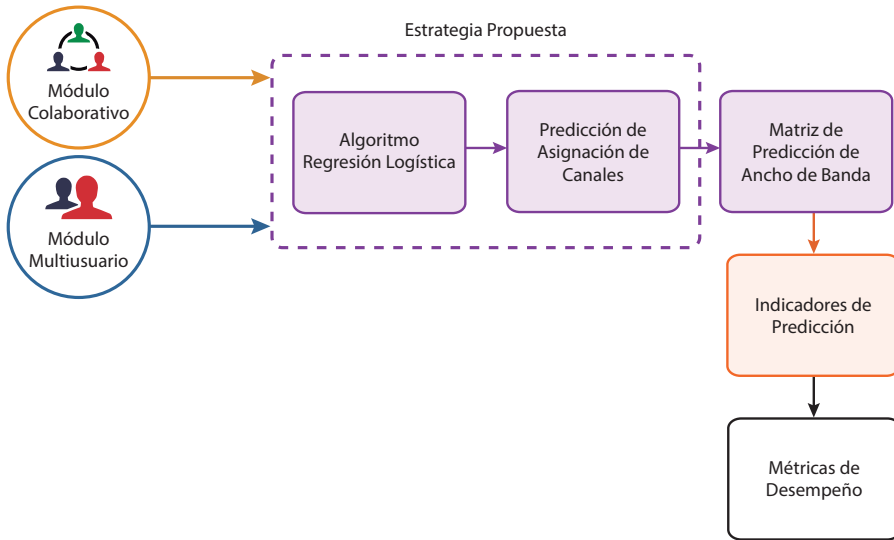


Figura 3.26. Regresión logística para la predicción de disponibilidad.

Fuente: elaboración propia.

Naive Bayes

Una de las principales consideraciones para la selección de modelos de predicción es el manejo de múltiples clases o características con y sin correlación. Un clasificador *Naive Bayes* supone que una característica en particular no se relaciona de ninguna manera con otra característica, en general. Las clases siempre se analizan de forma independiente. Adicionalmente, presenta desempeños eficientes al operar sobre grandes conjuntos de datos.

El teorema de Bayes permite determinar la probabilidad *posteriori* $P(c|x)$, $P(c)$, $P(x)$, $P(x|c)$ —ecuación (3.3)—.

$$P(c|x) = \frac{P(x|c)P(c)}{P(x)} \quad (3.3)$$

Donde:

$P(x|c)$ es la probabilidad del predictor dada la clase c (c , objetivo).

$P(c|x)$ es la probabilidad *a posteriori* de la clase c (c , objetivo) dado el predictor (x , atributos).

$P(c)$ es la probabilidad previa de la clase.

$P(x)$ es la probabilidad del predictor.

Considerando el teorema de *Naive Bayes* se puede afirmar que las variables independientes (o predictores en el caso específico) serían la AP y el ETA, mientras que la variable dependiente será la disponibilidad del canal.

Considerando las variables independientes AP y ETA, como se describió en párrafos anteriores, así como la variable o clase dependiente —en el caso específico la disponibilidad del canal es lo que se indicará como *occupied* o *available*— se obtienen las ecuaciones (3.4), (3.5) y (3.6).

$$posterior(occupied) = \frac{P(occupied) \cdot P(ETA|occupied) \cdot P(AP|occupied)}{evidence} \quad (3.4)$$

$$posterior(available) = \frac{P(available) \cdot P(ETA|available) \cdot P(AP|available)}{evidence} \quad (3.5)$$

$$evidence = k + t$$

$$k = P(occupied) \cdot P(ETA|occupied) \cdot P(AP|occupied) \quad (3.6)$$

$$t = P(available) \cdot P(ETA|available) \cdot P(AP|available)$$

La estrategia propuesta (figura 3.27) contiene dos procesos: el primero, realiza el entrenamiento del modelo de predicción utilizando las variables de AP y el tiempo promedio de disponibilidad. Durante un período de tiempo establecido en el proceso de entrenamiento, cada fila de datos se clasifica en una de las clases (ocupada, disponible). El segundo proceso asigna la ocupación de cada canal de acuerdo con la predicción, generando una matriz de disponibilidad donde los estados del canal están definidos por “1” (disponible) y “0” (ocupado). Posteriormente, la información de la matriz de predicción es tomada por el algoritmo de búsqueda del modelo multiusuario para obtener las métricas de desempeño.

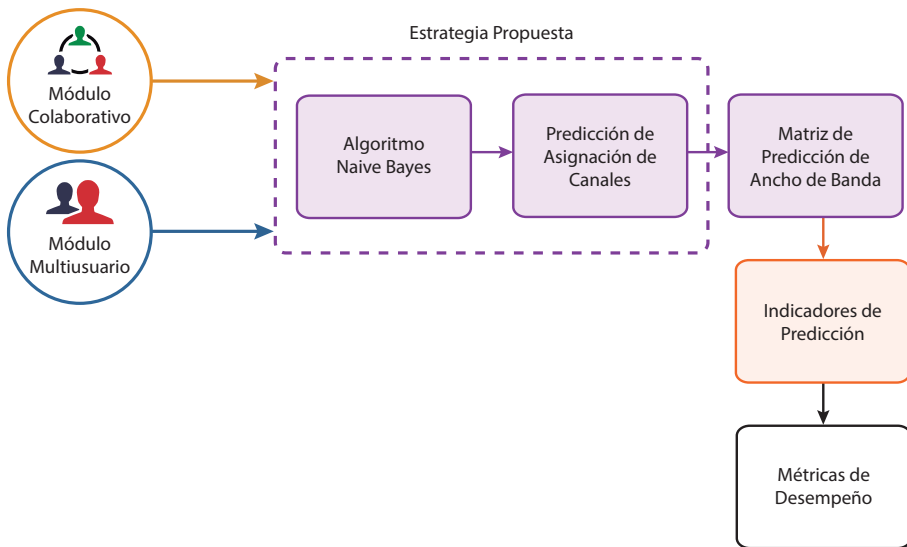


Figura 3.27. *Naive Bayes* para la predicción de disponibilidad.

Fuente: elaboración propia.

3.5.4 Deep Learning

El *Deep Learning* es un método que emula el aprendizaje humano. La mayoría de estos métodos utilizan arquitecturas de redes neuronales que, a diferencia de las estructuras tradicionales, contienen múltiples capas ocultas (redes profundas) para aprender diferentes características.

Los modelos *Deep Learning* utilizan grandes volúmenes de datos permitiendo extraer características directamente de estos —no es necesario realizar o implementar metodologías para sacarlos manualmente—. Durante el proceso de entrenamiento los algoritmos de aprendizaje identifican el conjunto correcto de características; lo hacen de forma automática, sin necesidad de procesar los datos.

El *Deep Learning* se realiza jerárquicamente. Las capas inferiores caracterizan estructuras básicas, mientras que las capas de nivel superior analizan estructuras más complejas. La red neuronal profunda más popular es la convolucional (CNN o ConvNet).

Las tres formas más comunes de aplicar una red profunda para la clasificación de objetos son entrenando desde cero, aprendizaje de transferencia y extracción de características.

Entrenando desde cero: Se reúne un conjunto de datos etiquetados muy grande y se diseña una arquitectura de red que aprenderá las características y el modelo desde cero.

Aprendizaje de transferencia: Proceso de ajustar el modelo de redes previamente entrenadas, como AlexNet o GoogLeNet. Esta estrategia solo requiere ajustar los datos de entrada y posteriormente entrega nuevas clases. Una característica adicional de este tipo de estructuras es la reducción en los tiempos de procesamiento.

Extracción de características: Las capas de las redes neuronales profundas aprenden ciertas características de las imágenes, las cuales se pueden extraer en cualquier momento. Estas características se pueden utilizar para el entrenamiento de clasificadores basados en estrategia de *machine learning* como SVM.

3.5.4.1 Estructura del modelo implementado

La metodología utilizando *Deep Learning* consiste en implementar el aprendizaje de transferencia para la extracción de características. El objetivo es utilizar una red neuronal convolucional para extraer de una de sus capas un conjunto acertado de características y, posteriormente, a través de estas características, entrenar una máquina de soporte vectorial que permita desarrollar un proceso de clasificación.

La figura 3.28 presenta las variables de entrada y salida descritas de forma general, adicional a la matriz entregada por el módulo colaborativo. Requiere de cuatro variables adicionales: el nivel de *threshold*, número de búsquedas para el nivel medio, tamaño de la segmentación para las figuras y tipo de división. Como salida el modelo entrega un vector de puntuaciones para cada canal.

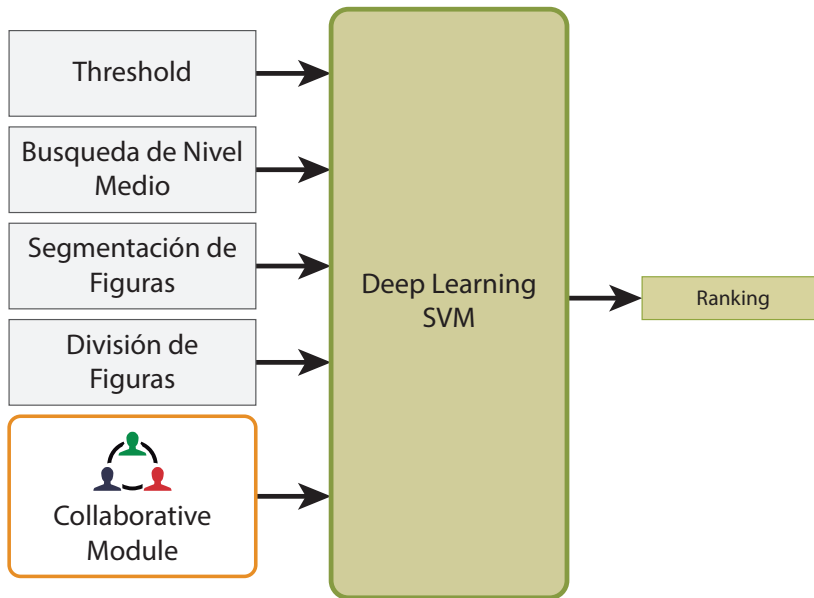


Figura 3.28. Variables de entrada y salida modelo de aprendizaje de transferencia para la extracción de características.

Fuente: elaboración propia.

Es importante resaltar que los datos se analizan directamente de la matriz de potencia; la evaluación de acuerdo con la matriz de disponibilidad se tendrá en cuenta solo para determinar los indicadores basados en QoS. La estrategia consiste en implementar un clasificador de tráfico. La tabla 3.10 presenta los niveles de tráfico a clasificar y su respectiva descripción.

Tabla 3.10. Descripción de los niveles de tráfico.

Nivel de tráfico	Descripción
Alto	Escenario con oportunidades espectrales limitadas, el número de PU es alto.
Bajo	Escenario con altas oportunidades espectrales, el número de PU es bajo, con tendencia a cero.
Medio	Escenario con oportunidades espectrales intermedias, el número de PU no es alto ni bajo, lo que permite que puedan interactuar en un mismo espacio SU y PU.

Fuente: elaboración propia.

Por el alto rendimiento que tienen las redes neuronales profundas en el reconocimiento de imágenes el modelo propuesto clasifica un conjunto de

imágenes asociadas a los niveles de potencia. Las imágenes son obtenidas a partir de la conversión a RGB de la base de datos. Para el entrenamiento de la red neuronal se utilizan figuras con múltiples variaciones.

La figura 3.29 presenta la estructura general del modelo desarrollado. Como se mencionó previamente, el objetivo es clasificar un conjunto de imágenes asociadas a los niveles de potencia. La primera tarea del modelo consiste en realizar la conversión de la matriz de potencia a figuras, posteriormente, estas figuras, mediante criterio de validación cruzada, son tomadas para entrenamiento y validación de la estrategia a implementar. Adicionalmente a las figuras obtenidas de la matriz de potencia se genera aleatoriamente un conjunto de figuras con otro tipo de comportamientos para asegurar un mejor proceso de entrenamiento. Las figuras tomadas para el entrenamiento son cargadas a la red AlexNet, y mediante el *toolbox* de *Deep Learning* de Matlab se calculan las activaciones de las capas de aprendizaje de la red profunda.

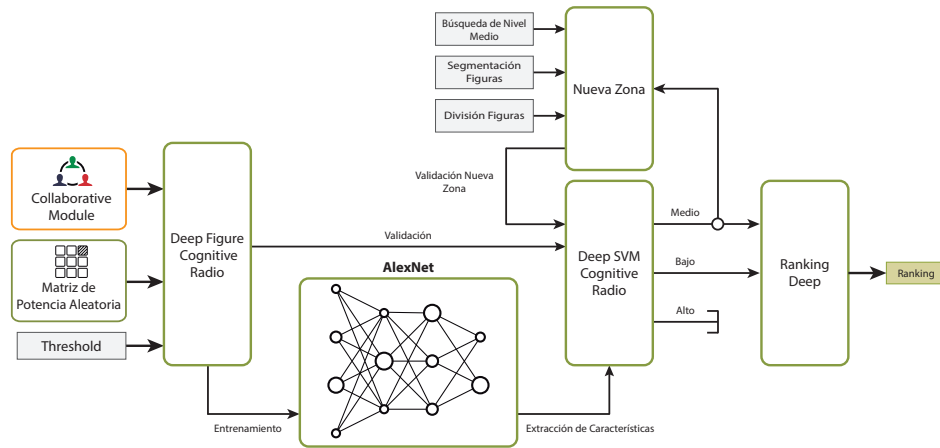


Figura 3.29. Diagrama de bloques general para el modelo basado en *Deep Learning*.

Fuente: elaboración propia.

Las características se extraen mediante las activaciones. Teniendo en cuenta la estructura jerárquica de las capas, se toma la capa de nivel superior fc7 de la red AlexNet; el criterio de selección se realiza debido a que las capas de nivel superior permiten analizar estructuras más complejas. Con la información de la capa se entrena una SVM; como técnica de clasificación para verificar el funcionamiento del clasificador se utilizan las figuras de prueba,

previamente obtenidas en la validación cruzada. Posteriormente, estas serán reemplazadas por la figura de la matriz de potencia entregada por el módulo colaborativo del simulador.

El clasificador identificará las figuras con tráfico alto, medio y bajo; las figuras con clasificación de tráfico alta serán almacenadas, sin analizar. En el proceso para determinar el *ranking* final, las figuras de tráfico medio tendrán un procesamiento adicional antes de ingresar al módulo de *ranking* —por la naturaleza asignada a estas figuras y con el objetivo de no perder posibles oportunidades espectrales, se filtran para identificar los segmentos locales que presenten tráficos bajos—. Para realizar este filtro, cada una de las figuras de tráfico medio será dividida en un conjunto de subfiguras; la división, al igual que el número de búsquedas que se realicen, es un parámetro que se ajusta de acuerdo con los criterios de la matriz de potencia.

Finalmente, después del filtro aplicado al tráfico medio y de descartar el tráfico alto, la información, incluyendo la clasificación de tráfico bajo será entregada al bloque final del modelo; este tomará los datos de tiempo y frecuencia para establecer el *ranking* de operación.

3.5.4.2 Generación de figuras

La generación de figuras se realiza en el bloque *Deep Figure Cognitive Radio* de la figura 3.29, el cual está dividido en dos procesos: el primero llamado “Potencia – Base de datos” convierte la base de datos de potencia espectral a una matriz RGB. La conversión se realiza a través de un ajuste lineal: el algoritmo determina los valores máximos y mínimos de potencia del rango de conversión —estos valores son tomados como base para un ajuste por unidad de los demás valores—; se asume el origen como un punto de inflexión, y este valor corresponde al *threshold* ajustado por el usuario. Se selecciona la escala en verde para tráfico bajo y la escala en rojo para tráfico alto. La figura 3.30 presenta el modelo lineal implementado y las gráficas obtenidas para “Potencia – Base de datos”.

El segundo proceso del bloque se llama “Potencia – Aleatorio” se encarga de generar un conjunto de figuras aleatorias para mejorar el proceso de entrenamiento. Sobre este bloque el usuario no tiene control, sin embargo, es indispensable para mejorar las características que se extraen de la red

neuronal profunda. Solo se requiere establecer un rango de *threshold*; el bloque realiza el ajuste lineal y gráfico.

Con las gráficas obtenidas en “Potencia – Base de datos” y “Potencia–Aleatorio”, se utiliza la metodología de validación cruzada para entrenamiento y validación del modelo.

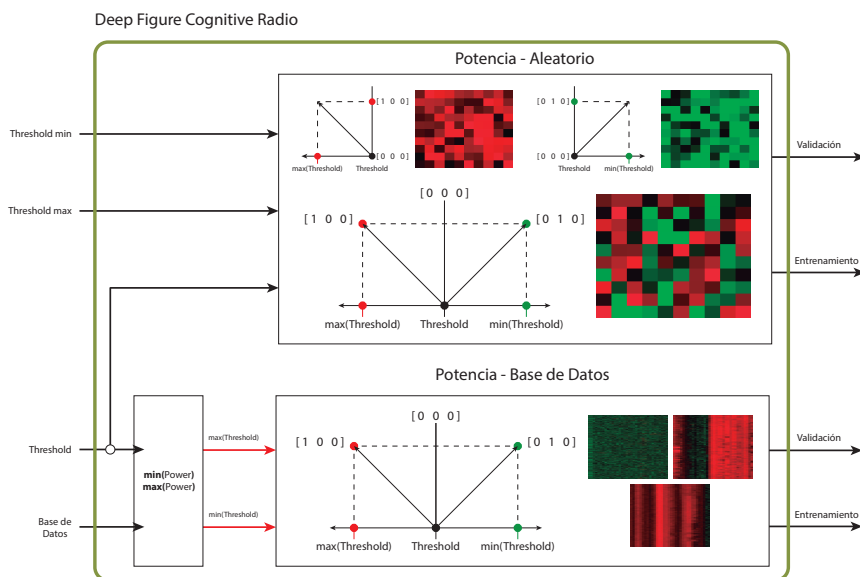


Figura 3.30. Generación de figuras para la matriz de potencia.

Fuente: elaboración propia.

3.5.4.3 Red neuronal convolucional AlexNet

AlexNet es una red neuronal convolucional profunda que ha sido pre-entrenada con más de un millón de imágenes, lo cual le permite generar características relevantes para una amplia gama de imágenes.

La figura 3.31 presenta la arquitectura de la red, que contiene ocho capas; las primeras cinco son convolucionales y las tres capas restantes están totalmente conectadas. La salida de la última capa produce una distribución de 1000 etiquetas de clases. La red maximiza el objetivo de regresión logística multinomial. Los núcleos de la segunda, cuarta y quinta capas convolucionales están conectados solo a los mapas de Kernel en la capa anterior.

La primera capa convolucional filtra la imagen de entrada. La segunda, toma como entrada la salida de la primera capa y filtra con 256 núcleos. Las capas convolucionales tercera, cuarta y quinta están conectadas entre sí sin cualquier agrupación intermedia o capas de normalización. La sexta capa convolucional tiene 384 núcleos conectados a las salidas de la segunda capa convolucional. La séptima capa convolucional tiene 384 núcleos, y la octava capa convolucional tiene 256 núcleos. Las capas completamente conectadas tienen 4096 neuronas cada una (Krizhevsky *et al.*, 2012).




Figura 3.31. Arquitectura red neuronal convolucional AlexNet.

Fuente: elaboración propia.

Para obtener las características de entrenamiento y activación de las capas de la red AlexNet utilizando Matlab, se requiere establecer el tipo de red y realizar la respectiva instalación de la librería, disponible en la página *web* de Mathworks. Adicionalmente, se debe seleccionar la capa de interés y las respectivas imágenes. La figura 3.32 presenta la estructura de las variables de entrada y salida.




Figura 3.32. Entradas y salidas red neuronal convolucional AlexNet.

Fuente: elaboración propia.

3.5.4.4 Máquina de soporte vectorial

La técnica de *machine learning* utilizada para la clasificación de las imágenes es la SVM usa tres tipos de clasificadores, por tanto, se requiere una SVM multiclase. El bloque asociado se presenta en la figura 3.33.

De acuerdo con los criterios para técnicas de clasificación, los parámetros de entrada son las imágenes de entrenamiento y de validación; las imágenes para el proceso de validación corresponden al ajuste realizado a través de la técnica de validación cruzada —estas imágenes serán las entregadas por el módulo colaborativo—. Las salidas corresponden a la matriz de confusión, herramienta indispensable para determinar el desempeño del algoritmo y la clasificación de las imágenes.

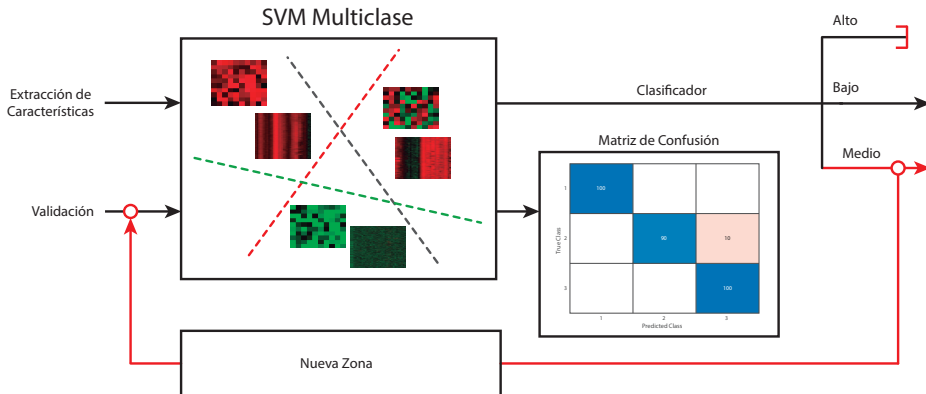


Figura 3.33. Máquina de soporte vectorial multiclase para clasificación de imágenes.

Fuente: elaboración propia.

La figura 3.34 presenta un ejemplo para la clasificación de la figura según el tipo de tráfico. Como se puede observar, esta imagen tiene zonas con niveles de tráfico alto (color rojo) y niveles de tráfico bajo (color verde).




Figura 3.34. Ejemplo de clasificación para tráfico alto y tráfico bajo.

Fuente: elaboración propia.

Como se muestra en la figura 3.33, se presenta una retroalimentación. Este proceso está directamente relacionado con las figuras de clasificación para tráfico medio y equivalen a escenarios con oportunidades espectrales intermedias. La figura 3.35 muestra un ejemplo para este tipo de tráfico: a mayor escala cuentan con zonas de tráfico bajo; el trabajo del bloque retroalimentado es ajustar la escala para obtener la información de las zonas color verde.




Figura 3.35. Figuras con oportunidades espectrales intermedias.

Fuente: elaboración propia.

3.5.4.5 Generación de nueva zona

Las figuras clasificadas con tráfico medio contarán con un procesamiento adicional que genera una nueva zona de análisis. El objetivo es poder realizar un conjunto de segmentaciones sobre la figura principal, de tal manera que se pueda obtener la información asociada a las zonas con tráfico bajo y alto.

La figura 3.36 presenta una descripción gráfica de la segmentación que se realiza a las figuras de tráfico medio. Se requiere de cuatro parámetros de entrada; el primero corresponde a la figura clasificada por la SVM que está siendo retroalimentada, los parámetros restantes son el tipo de división, número de búsquedas nivel medio a realizar y número de segmentaciones para la figura.

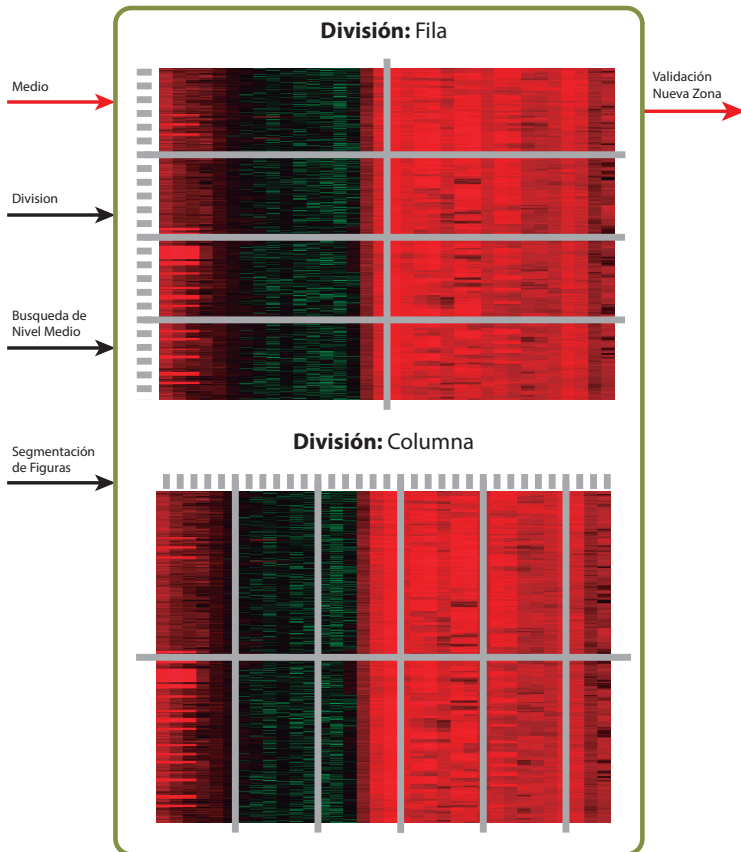


Figura 3.36. Procesamiento para segmentar las figuras de tráfico medio.

Fuente: elaboración propia.

En la tabla 3.11 se presenta la descripción de los parámetros que deben ser ajustados para la generación de la nueva zona cuando se presentan escenarios de tráfico medio.

Tabla 3.11. Descripción de los parámetros para la generación de la nueva zona.

División	Row: Se divide la figura en dos columnas y la segmentación se completa a través de múltiples divisiones por filas.
	Column: Se divide la figura en dos filas y la segmentación se completa a través de múltiples divisiones por filas.
Segmentación	Número de partes en que la figura será segmentada.
Búsqueda de nivel medio	El resultado de segmentar una figura no necesariamente permite obtener la información de las zonas con tráfico bajo y alto. La probabilidad de obtener una nueva clasificación de tráfico medio existe, por tanto, es posible realizar una nueva segmentación a una figura resultado de un proceso de segmentación. Este proceso se puede realizar un número finitos de veces, hasta asegurar que no existan zonas con tráfico medio, sin embargo, este proceso es computacionalmente alto y no necesariamente eficiente, por eso, corresponde a una variable de entrada y no se realiza de forma automática. De acuerdo con cada caso se puede decidir el número de veces que se va a realizar la búsqueda de tráfico medio en una figura.

Fuente: elaboración propia.

La salida del bloque corresponde a las figuras resultados del proceso de segmentación, la información es entregada al bloque “*Deep SVM Cognitive Radio*” para realizar la nueva clasificación. Este proceso se realiza el número de veces ajustado en “Búsqueda de nivel medio”.

3.5.4.6 *Ranking*

El resultado del filtro realizado a las figuras con tráfico medio puede generar dos escenarios para el bloque *ranking*. El primero corresponde a zonas sin tráfico medio y el segundo a zonas con tráfico medio y bajo. El primer caso es un escenario con menor probabilidad de ocurrencia; el segundo es más realista, por tanto, a diferencia del tráfico alto, no se descarta.

La información de tiempo y frecuencia de las figuras con tráfico bajo y medio se entregan al bloque *ranking*. Allí se realiza una clasificación de las figuras de acuerdo con el rango de frecuencias y tiempo, se comparan y

finalmente se asignan pesos a las zonas. La figura 3.37 presenta la estructura del bloque *ranking*.

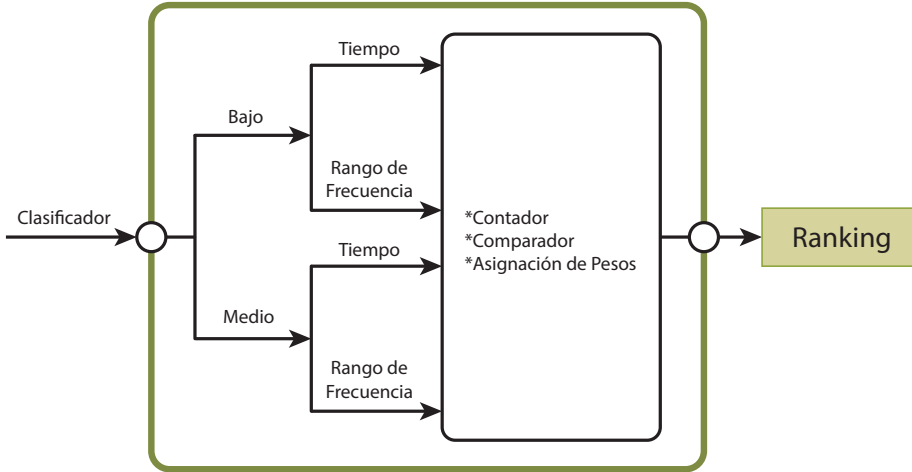


Figura 3.37. *Ranking* para el modelo de aprendizaje de transferencia utilizando *Deep Learning*.

Fuente: elaboración propia.

3.6 Otros algoritmos

Con el objetivo de realizar una evaluación comparativa del modelo propuesto, se implementan los algoritmos multicriterio: FFAHP, SAW, TOPSIS, VIKOR. Esta selección se realizó teniendo en cuenta que los métodos MCDM son una herramienta matemática adecuada para modelar el proceso asignación espectral, por tanto, han sido ampliamente utilizados en trabajos de investigación (Lahby *et al.*, 2011; Stevens *et al.*, 2008; Yang y Wu, 2008; Yang y Tseng, 2013; Zapata *et al.*, 2012). SAW (Hernández *et al.*, 2015c; Zhang, 2004); TOPSIS (Hernández *et al.*, 2015f; Zhang, 2004), VIKOR (Páez *et al.*, 2015; Stevens *et al.*, 2012) y FFAHP (Hernández *et al.*, 2016a).

Dado que los métodos FFAHP, SAW, TOPSIS y VIKOR se explicaron en el segundo capítulo, en este exponemos la estructura de programación implementada. El Algoritmo 4 presenta las variables de entrada, salida y la estructura para FFAHP; el Algoritmo 5 para SAW, el Algoritmo 6 para TOPSIS y, finalmente, el Algoritmo 7 para VIKOR.

Algoritmo 4. *Feedback Fuzzy Analytical Hierarchical Process (FFAHP).*

Variables de entrada	W	Puntuación asignada a AP, ETA, ASINR y ABW.
	AP	Probabilidad de disponibilidad.
	ETA	Tiempo medio de disponibilidad.
	ASINR	Promedio de relación señal a ruido más interferencia.
	ABW	Ancho de banda promedio.
	Ranking_Last	Canales ordenados de forma descendente de acuerdo con la primera puntuación (Sin retroalimentación).
Variables de salida	ScoreF	Puntuación asignada a cada canal.
	Ranking	Canales ordenados de forma descendente de acuerdo con el ScoreF (Con retroalimentación).
<pre> Average = [AP ; ETA ; ASINR ; ABW]; Ranking = W*Average; [~ , Columnas] = size(Ranking); %% Algoritmo FFAHP if Feedback == 0 %Vector Ranking Inicial ScoreF = sort(Ranking , 'descend'); %Ordena de manera descendente for i = 1 : Columnas [Posicion]=find(Ranking == ScoreF(i)); RankingF(1 , i)= Posicion; end elseif Feedback == 1 %Vector Ranking Actualizado Ranking = 0.6*Ranking + 0.4* Ranking _Last; ScoreF = sort(Ranking , 'descend') ; %Ordena de manera descendente for i = 1 : Columnas [Posicion] = find(Ranking == ScoreF(i)); RankingF(1 , i) = Posicion; end end end </pre>		

Algoritmo 5. *Simple Additive Weighting (SAW)*

Variables de entrada	W	Puntuación asignada a AP, ETA, ASINR y ABW.
	AP	Probabilidad de disponibilidad.
	ETA	Tiempo medio de disponibilidad.
	ASINR	Promedio de relación señal a ruido más interferencia.
	ABW	Ancho de banda promedio.
Variables de salida	ScoreF	Puntuación asignada a cada canal.
	Ranking	Canales ordenados de forma descendente de acuerdo con el ScoreF.
<pre>Average = [AP ; ETA ; ASINR ; ABW]; %% Algoritmo SAW [Row , ~] = size(Average); for f = 1 : Row X_m = max(Average(f , :)); r(f , :) = Average(f , :) ./ X_m; end Ranking = W*r; [~ , Columnas] = size(Ranking); ScoreF = sort(Ranking , 'descend') ; %Ordena de manera descendente %Vector Ranking Inicial for i = 1 : Columnas [Posicion] = find(Ranking == ScoreF(i)); RankingF(1 , i) = Posicion; end</pre>		

Algoritmo 6. *Technique for order preference by similarity to ideal solution (TOPSIS).*

Variables de entrada	W	Puntuación asignada a AP, ETA, ASINR y ABW.
	AP	Probabilidad de disponibilidad.
	ETA	Tiempo medio de disponibilidad.
	ASINR	Promedio de relación señal a ruido más interferencia.
	ABW	Ancho de banda promedio.
Variables de salida	ScoreF	Puntuación asignada a cada canal.
	Ranking	Canales ordenados de forma descendente de acuerdo con el ScoreF.


```

Average = [ AP ; ETA ; ASINR ; ABW ];
%% Algoritmo TOPSIS
[Row , Column] = size( Average );
B_C = [0 0 0 0]; % 1: Parámetro de costo-0: Parámetro de
beneficio
% 1. Normalizar la Matriz de Decisión
for f = 1 : Row
    b = sqrt( sum( Average(f , :) . ^ 2 ) );
    for c = 1 : Column
        r(f , c) = Average(f , c) / b;
    end
end
% 2. Pesos Ponderados
for f = 1 : Column
    V((1 : Row) , c) = r(:, c).*(W');
end
% 3: Solución ideal y solución ideal negativa
for f = 1 : Row
    if B_C(1 , f) == 0
        a1 = max( V(f , :) ); a2 = min( V(f , :) );
    else
        a1 = min( V(f , :) ); a2 = max( V(f , :) );
    end
    A1(1 , f) = a1; A2(1 , f) = a2;
end
% 4: Medida de separación
for c = 1 : Column
    S1(1 , c) = sqrt( sum( ( V(:,c)-A1' ) .^ 2 ) );
    S2(1 , c) = sqrt( sum( ( V(:, c)-A2' ) .^ 2 ) );
end
% 5: Relativa cercanía a la solución ideal
for c = 1 : Column
    Ranking(1 , c) = S2(1 , c) / ( S1(1 , c) + S2(1 , c) );
end
[ ~ , Columnas] = size( Ranking );
ScoreF = sort( Ranking , 'descend' ) ; %Ordena de manera
descendente
%Vector Ranking Inicial
for i = 1 : Columnas
    [Posicion] = find( Ranking == ScoreF(i) );
    RankingF(1 , i) = Posicion;
end

```

Algoritmo 7. Multi-Criteria Optimization and Compromise Solution (VIKOR).

Variables de entrada	W	Puntuación asignada a AP, ETA, ASINR y ABW.
	AP	Probabilidad de disponibilidad.
	ETA	Tiempo medio de disponibilidad.
	ASINR	Promedio de relación señal a ruido más interferencia.
	ABW	Ancho de banda promedio.
Variables de salida	ScoreF	Puntuación asignada a cada canal.
	Ranking	Canales ordenados de forma descendente de acuerdo con el ScoreF.
<pre>Average = [AP ; ETA ; ASINR ; ABW]; %% Algoritmo VIKOR [Row , Column] = size(Average); B_C = [0 0 0 0]; % 1: Parámetro de costo-0: Parámetro de beneficio % 1. Normalizar la Matriz de Decisión for f = 1 : Row if B_C(1 , f) == 0 f1 = max(Average(f , :)); f2 = min(Average(f , :)); else f1 = min(Average(f , :)); f2 = max(Average(f , :)); end F1(1 , f) = f1; F2(1 , f) = f2; end % 2. Calcula los valores Si y Ri for f = 1 : Column for i = 1 : row s(1 , i) (W(i) * ((F1(i)-Average(i , j)) / (F1(i)-F2(i)))); end S(1 , j) = sum(s); R(1 , j) = max(s); end % 3: Calcula los valores Q (Q = Ranking) S1 = min(S); S2 = max(S); R1 = min(R); R2 = max(R); Gamma = 0.5; %Step 5: relative closeness to the ideal solution for c = 1 : column Ranking(1 , c) = S2(1 , c) / (S1(1 , c) + S2(1, c)); end</pre>		

```

[ ~ , Columnas] = size( Ranking );
ScoreF = sort( Ranking , 'descend' ) ; %Ordena de manera
descendente
%Vector Ranking Inicial
for i = 1 : Columnas
    [Posicion] = find( Ranking == ScoreF(i) );
    RankingF(1 , i) = Posicion;
end

```

3.7 Criterios de decisión

Ahora, cada algoritmo seleccionado depende de los criterios de decisión que se seleccionen y de sus correspondientes valores. Para esta investigación se seleccionaron cuatro criterios de decisión: AP, ETA, 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 trabajen con los mismos cuatro criterios de decisión.

La variable AP corresponde al análisis del ciclo de trabajo normalizado de cada una de las 500 oportunidades espectrales potenciales. 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 de disponibilidad de entrenamiento para LT o HT.

La variable ETA corresponde al tiempo de disponibilidad promedio de cada canal. Primero se calculan todos los períodos en que cada canal estuvo disponible de forma continua y, luego, se toma el promedio sobre dichos períodos para cada canal. El resultado de ETA también es un vector de 1×500 para la matriz de disponibilidad de entrenamiento LT o HT.

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 disponibilidad de entrenamiento LT o HT, diferente de cero, se realiza la diferencia entre el elemento que tiene la misma posición en la matriz de potencia de entrenamiento LT o HT y el valor promedio del piso de ruido; el resultado de la diferencia se almacena en la misma posición de una matriz temporal denominada matriz de entrenamiento SINR-LT o SINR-HT. Segundo, se calcula el valor promedio de cada columna de la matriz

de entrenamiento SINR-LT o SINR-HT. Por tanto, el resultado de SINR también es un vector de 1×500 .

La variable BW corresponde al BW promedio de cada canal. Sin embargo, debido a que son canales, todos tienen el mismo BW —equivalente a 100kHz— por lo que el promedio será siempre el mismo, restándole importancia. Con el objetivo de que la variable BW tenga incidencia en el *ranking* de cada oportunidad espectral se decidió tomar, para cada potencial oportunidad espectral, 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 200kHz, 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 100kHz. Aunque se habría podido medir 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 un BW de 100 kHz para realizar un uso oportunista más eficiente del espectro disponible.

Una vez calculados los valores de los criterios de decisión se normalizaron para que los puntajes que definen la posición de las oportunidades espectrales en el *ranking* siempre sean justos, tanto en la clase de aplicación RT como BE. La normalización de los valores para los cuatro criterios de decisión consistió en ajustar su rango de escala de 0 a 100; para ello se multiplicaron todos los valores de un mismo criterio por un factor de escala equivalente a 100 dividido por el valor más alto del criterio correspondiente.

3.8 Métricas de evaluación

Para evaluar el desempeño de los algoritmos se determinaron ocho métricas de evaluación, descritas en las tablas 3.12 y 3.13. Las métricas de la tabla 3.12 se obtienen para modelos de predicción y no predicción, a diferencia de las descritas en la tabla 3.13, las cuales son adicionales y exclusivas para modelos de predicción. En dichas tablas se presenta la sigla, significado, descripción y tipo de métricas de evaluación —este último campo hace referencia a si la métrica es de beneficio (entre mayor mejor) o costo (entre menor mejor)—. La palabra promedio en las métricas de evaluación hace

referencia a que los resultados de estas corresponden al promedio de los valores arrojados por varios experimentos realizados.

Tabla 3.12. Métricas utilizadas en la evaluación de los modelos.

Sigla	Nombre	Descripción	Tipo de métrica de evaluación
AAH	Número de <i>handoff</i> promedio acumulado	Total de <i>handoff</i> realizados durante los nueve minutos de transmisión del SU.	Costo
AAFH	Número de <i>handoff</i> fallidos promedio acumulado	Cantidad de <i>handoff</i> que el SU no pudo materializar porque encontró las respectivas oportunidades espectrales objetivo ocupadas.	Costo
ABW	Ancho de banda promedio	BW promedio utilizado por el SU durante los 9 minutos de su transmisión.	Beneficio
AAD	Retardo promedio acumulado	Tiempo promedio total experimentado por el SU durante la transmisión de una determinada cantidad de información.	Costo
AAT	<i>Throughput</i> promedio acumulado	Tasa de datos efectiva transmitida por el SU durante los 9 minutos de comunicación.	Beneficio

Fuente: elaboración propia.

Tabla 3.13. Métricas adicionales para la evaluación de los modelos predictivos.

Sigla	Nombre	Descripción	Tipo de métrica de evaluación
AAIH	Número de <i>handoff</i> con interferencia promedio acumulado	Cantidad total de <i>handoff</i> reactivos realizados una vez llega el PU, durante el tiempo de transmisión del SU.	Costo
AAPH	Número de <i>handoff</i> perfecto promedio acumulado	Cantidad de <i>handoff</i> sin interferencia realizados muy cerca de la llegada del PU, pero sin causar interferencia a este último, durante el tiempo de transmisión del SU.	Costo
AAUH	Número de <i>handoff</i> anticipado promedio acumulado	Cantidad de <i>handoff</i> sin interferencia realizados de forma muy anticipada a la llegada del PU, durante el tiempo de transmisión del SU.	Costo

Fuente: elaboración propia.

Con el fin de facilitar el análisis comparativo de cada algoritmo se calcularon los valores relativos (en porcentaje) de cada métrica de evaluación. Para las métricas tipo beneficio se calculó el valor relativo (Rel) del algoritmo i a partir del valor absoluto (Abs) y el valor máximo (Max) de la métrica de evaluación, como se describe en la ecuación (3.7). Para las métricas tipo costo se calculó el valor relativo (Rel) del algoritmo i a partir del valor absoluto (Abs) y el valor mínimo (Min) de la métrica de evaluación, como se describe en la ecuación (3.8).

$$X_i^{Rel} = \frac{X_i^{Abs}}{X_{Max}^{Abs}} \times 100\% \quad (3.7)$$

$$X_i^{Rel} = \frac{X_i^{Min}}{X_i^{Abs}} \times 100\% \quad (3.8)$$

4. *Software* de simulación desarrollado


La herramienta de simulación propuesta fue desarrollada en (Matlab, 2020), diseñada para permitir al usuario trabajar bajo un ambiente amigable y parametrizable según las pruebas que se requieran implementar, basada en datos de ocupación espectral reales capturados de las bandas de frecuencia GSM y Wi-Fi, a fin de incorporar el comportamiento real del PU en la evaluación del desempeño del algoritmo de *handoff* espectral seleccionado. Consta de una arquitectura de siete módulos que incluye un análisis colaborativo, parametrización multiusuario y cuenta con siete posibles modelos, dos no predictivos y cinco predictivos.

4.1 Interfaz herramienta de simulación desarrollada

La figura 4.1 muestra el entorno principal de la herramienta de simulación denominada App MultiColl-DCRN. El *software* “Collaborative CRN” se desarrolló utilizando el entorno App Designer de Matlab, diseñado para permitir al usuario trabajar bajo un ambiente amigable y parametrizable según las pruebas que se requieran. El *software* está dividido en siete módulos (1) *Project Information*, (2) *Collaborative*, (3) *Multi-User*, (4) *Parameters*, (5) *No Prediction*, (6) *Prediction*, (7) *Output*.

Help

About



UNIVERSIDAD DISTRITAL
FRANCISCO JOSÉ DE CALDAS

Project Name

Load Database

▼

...

Save Folder

...

Collaborative Module



Collaborative
Module

Setting Collaborative

Collaborative Module

Default

Division

Row

Number User

1

Segmentation


Continuous

User Percentage

100

Setting Summary

Multi-user Module



Multi-user
Module

Setting Multi-user

Multi-user Module

Default

Serial Users

1

Random User Figure

☐

Multichannel Bands

1

Simulation Mode

Conventional

Setting Summary

Parameters Module

Input Data

Threshold

BW Fixed

Noise Floor

Multichannels

Input
Data

Availability

SINR

Bandwidth

Threshold

BW Fixed

Noise Floor

Multichannels

Default Parameters

☐

Traffic Level

▼

H

M

L

☐


☐

☐


Time [minutes]

▼

Prediction Module




No
Prediction




Prediction


Output



Run



Close



Update

Figura 4.1. Interfaz gráfica App MultiColl-DCRN.

Fuente: elaboración propia.

4.2 Descripción general

El software “App MultiColl-DCRN” —*Application Multi-user Collaborative Spectral Decision for Decentralized Cognitive Radio Networks*— está diseñado en la herramienta App Designer de Matlab; conformado por 106 funciones, tres interfaces gráficas y un manual de usuario. El simulador funciona a partir de las métricas de potencia de dos tipos de red: GSM y Wi-Fi, sin embargo, está desarrollado para que se puedan incluir otro tipo de métricas.

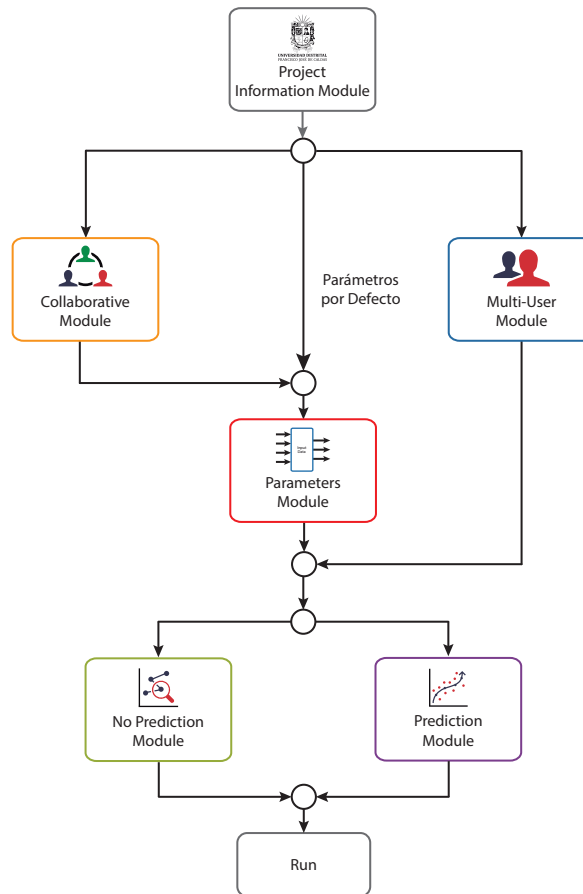


Figura 4.2. Arquitectura por módulos APP MultiColl-DCRN.

Fuente: elaboración propia.

La figura 4.2 presenta el diagrama de bloques general del simulador. Como expone la gráfica, trabaja con arquitectura por módulos, descritos en la tabla 4.1.

Tabla 4.1. Descripción módulos APP MultiColl-DCRN.

Módulo	Descripción
<i>Project Information</i>	Permite parametrizar la información básica del proyecto y el tipo de red.
<i>Collaborative</i>	Permite parametrizar los escenarios colaborativos, ajustando la cantidad y el método de selección de información.
<i>Multi-User</i>	Permite parametrizar el número de usuarios seriales, usuarios aleatorios y características multicanal.
<i>Parameters</i>	Permite parametrizar las variables <i>threshold</i> , <i>Noise floor</i> , <i>Bandwidth fixed</i> y <i>Multichannels</i> . Adicionalmente, caracteriza el nivel de tráfico y tiempo de transmisión.
<i>No Prediction</i>	Permite parametrizar algoritmos de no predicción: Movilidad espectral y <i>Feature Extraction</i> .
<i>Prediction</i>	Permite parametrizar algoritmos de predicción: <i>Markov Chain</i> , <i>Genetic Algorithm</i> , <i>Naive Bayes</i> , <i>Logistic Regression</i> y <i>Time Series</i> .
<i>Output</i>	Permite ejecutar el caso de estudio (<i>Run</i>), cerrar la ventana (<i>Close</i>) y actualizar una nueva interfaz (<i>Update</i>).

Fuente: elaboración propia.

En las siguientes secciones se describe en detalle cada uno de los módulos, sus variables de entrada, salida y la respectiva metodología. Según el módulo, cada variable de salida se representa por un color, al igual que las variables internas, la información de entrada ajustada en la interfaz y la información que se visualiza. La figura 4.3 presenta la convención de colores utilizada para la descripción de los módulos.

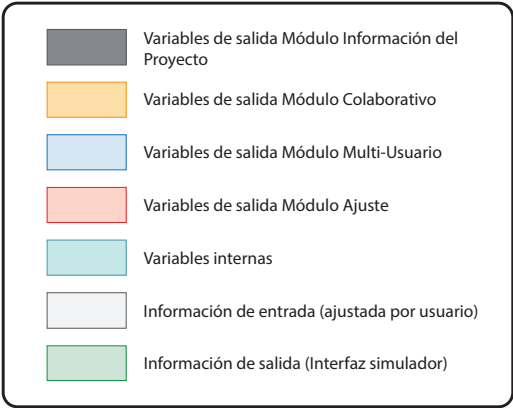


Figura 4.3. Convención de colores para la descripción de los módulos.

Fuente: elaboración propia.

4.3 Project Information Module

El simulador está diseñado para guiar al usuario en todo el proceso de parametrización. Inicialmente, con excepción de algunos controles, los parámetros comienzan en estado inhabilitado. El objetivo es disminuir la probabilidad de ajustes erróneos, por tanto, los módulos se habilitarán en forma ordenada si los ajustes se realizan correctamente. El primer módulo que se debe parametrizar es “*Project Information*”.

Dentro de las excepciones que no inician inhabilitadas se encuentran dos variables de este módulo. La figura 4.4 presenta la interfaz correspondiente. El módulo contiene los parámetros asociados al nombre y ruta de la carpeta donde se guardarán los resultados de las respectivas simulaciones y la base de datos de ocupación espectral. Como se identifica en la figura 4.4 las variables habilitadas son “*Project Name*” y “*Load Database*”.

Figura 4.4. Módulo “*Project Information*”.

Fuente: elaboración propia.

En las secciones 4.3.1, 4.3.2 y 4.3.3 se presenta la descripción detallada de las variables de entrada, salida y metodología del módulo “*Project Information*”.

4.3.1 Variables de entrada

La figura 4.5 presenta las variables de entrada para el módulo “*Project Information*”. El usuario debe definir un nombre para el proyecto, seleccionar entre dos posibles tipos de red (GSM, Wi-Fi) y la ruta donde se almacenarán los resultados de la simulación. El simulador cuenta con la posibilidad de cargar una base de datos personalizada “*Custom*”. La figura 4.5 incluye las funciones que se requieren para la información del proyecto, estas funciones serán analizadas en detalle en las secciones posteriores.

Por defecto el simulador crea una carpeta con el nombre “App MultiColl-DCRN” en la ruta definida en “Save folder”. Dentro de esta carpeta se crean los diferentes proyectos (subcarpetas) de acuerdo con los “Project name” generados.

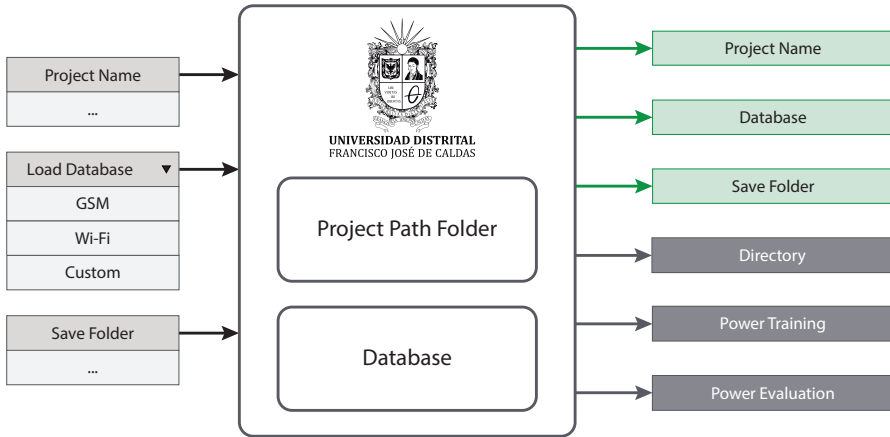


Figura 4.5. Descripción variables de entrada y salida del módulo “Project Information”.

Fuente: elaboración propia.

La tabla 4.2 presenta la descripción de las variables de entrada que se requieren para la parametrización del módulo “Project Information”.

Tabla 4.2. Variables de entrada del módulo “Project Information”.

Variable	Descripción
<i>Project Name</i>	Los resultados de cada simulación son almacenados en un ruta y carpeta específica. La ruta se establece en la variable “Save Folder” y la carpeta se crea de forma automática con el nombre “App MultiColl-DCRN”. Dentro de esta carpeta el usuario tiene la posibilidad de almacenar los resultados de múltiples simulaciones. Para diferenciar los diferentes resultados se crean subcarpetas con diferentes nombres, estos corresponden a la asignación que realice el usuario en la variable “Project Name”.
<i>Load Database</i>	Se selecciona la base de datos asociada al tipo de red: GSM, Wi-Fi, el simulador tiene la posibilidad de cargar una base de datos diferente a las predefinidas. Esta característica se habilita al seleccionar la opción “Custom”.
<i>Save Folder</i>	Ruta donde se almacenan los resultados de cada simulación.

Fuente: elaboración propia.

4.3.1.1 Base de datos

El simulador trabaja con dos bases de datos de ocupación espectral, una de entrenamiento “*Power Training*” y otra de evaluación “*Power Evaluation*”. Las bases de datos están conformadas por las potencias medidas experimentalmente en las bandas GSM y Wi-Fi, —durante una campaña de medición previa esta información permite que los resultados de la evaluación de los algoritmos sean más confiables al trabajar con datos reales del comportamiento del usuario primario—. La base de datos de entrenamiento se utiliza para configurar los parámetros iniciales de los algoritmos de *handoff espectral*, y la base de datos de evaluación se utiliza para calcular las métricas de los algoritmos seleccionados. Ambas bases de datos tienen información de 550 canales de frecuencia, durante una hora para el caso de “*Power Training*” y nueve minutos para el caso de “*Power Evaluation*”, con una resolución de un tercio de segundo para las dos bases de datos. La cantidad de información correspondiente se muestra en la tabla 4.3; las filas representan el tiempo en segundos y las columnas los canales de frecuencia. El tiempo de muestreo para la toma de datos fue de 290ms.

Tabla 4.3. Bases de datos de ocupación espectral.

Tecnología	Cantidad de datos capturados		
	Filas	Columnas	Total Datos
GSM	1.145.700	550	631.280.700
Wi-Fi	2.490.000		1.147.890.000

Fuente: elaboración propia.

Adicionalmente, la base de datos “*Power Training*” y “*Power Evaluation*” es clasificada de acuerdo con la AP, esto permite caracterizar la información de acuerdo con el nivel de tráfico: alto, medio y bajo. Según la clasificación realizada, el tamaño de la base de datos es modificada. En total el simulador cuenta con 12 bases de datos: seis para GSM y seis para Wi-Fi.

Las figuras 4.6 y 4.7 describen la AP para cada canal GSM de acuerdo con el tráfico de disponibilidad alto y bajo, respectivamente.




Figura 4.6. AP para la caracterización de GSM en tráfico alto.

Fuente: elaboración propia.




Figura 4.7. AP para la caracterización de GSM en tráfico bajo.

Fuente: elaboración propia.

4.3.2 Variables de salida

La figura 4.5 presenta las variables de salida para el módulo “*Project Information*”. Las variables “*Power Training*” y “*Power Evaluation*” corresponden a las bases de datos seleccionadas de acuerdo con el tipo de red y son indispensables para la simulación de diferentes casos de estudio. Como se identifica en la figura 4.5 y según el código de colores descrito en la figura 4.3, son las variables de salida principales del módulo; las demás, están asociadas a variables de visualización.

La tabla 4.4 presenta la descripción de las variables de entrada que se requieren para la parametrización del módulo “*Project Information*”.

Tabla 4.4. Variables de salida del módulo “*Project Information*”.

Variable	Descripción
<i>Project Name</i>	Interfaz donde se visualiza el nombre asignado al proyecto.
<i>Database</i>	Interfaz donde se visualiza la tecnología seleccionada.
<i>Save Folder</i>	Interfaz donde se visualiza la ruta de almacenamiento de los resultados de la información.
<i>Directory</i>	Corresponde a la ruta donde accederán los módulos no predictivos y predictivos para guardar la información resultado de las simulaciones.
<i>Power Training</i>	Corresponde a la matriz de entrenamiento de potencia para el tipo de red seleccionada.
<i>Power Evaluation</i>	Corresponde a la matriz de evaluación de potencia para el tipo de red seleccionada.

Fuente: elaboración propia.

4.3.3 Metodología módulo “*Project Information*”

La exposición específica del módulo requiere analizar dos funciones asociadas a la descripción del proyecto y a la selección de la base de datos. La figura 4.5 presenta el diagrama con las funciones del módulo: “*Project Path Folder*” y “*Database*”, cada una analizada en detalle en las figuras 4.8 y 4.9, respectivamente.

Función “Project Path Folder”

La figura 4.8 presenta el diagrama de bloques de la función que, como variable externa, requiere la información de entrada “*Project Name*” y “*Save Folder*”. La función maneja tres variables de salida: dos corresponden a la información que se visualiza en el módulo de información del proyecto en la interfaz principal (figura 4.4). Estas variables son “*Database*”, “*Save Folder*”, y “*Directory*”, que contienen la información interna requerida por los módulos predictivos y no predictivos para guardar los resultados de las simulaciones.

La función “*Project Path Folder*” es la encargada de generar las carpetas asociadas al simulador. Por defecto, el simulador crea una carpeta con el nombre “App MultiColl-DCRN” en la ruta definida en “*Salve Folder*”; dentro

de esta carpeta —siempre y cuando la ruta “*Save Folder*” se seleccione permanente— se podrán generar múltiples subcarpetas. Cada una representa un proyecto (simulación o caso de estudio). Para diferenciar los resultados, se le asigna un nombre a cada una, a través de la variable “*Project Name*”. La variable interna “*Directory*” contiene la información de ruta del proyecto.




Figura 4.8. Función “*Project Path Folder*”.

Fuente: elaboración propia.

Función “*Database*”

La figura 4.9 presenta el diagrama de bloques de esta función. Como variable externa requiere la información de entrada “*Load Database*”. Maneja tres variables de salida: una corresponde a la información que se visualiza en el módulo de información del proyecto en la interfaz principal (figura 4.4); esta variable es “*Database*”. Las variables restantes contienen la información interna “*Power Training*” y “*Power Evaluation*”, que corresponden a la base de datos de acuerdo con el tipo de red seleccionada.

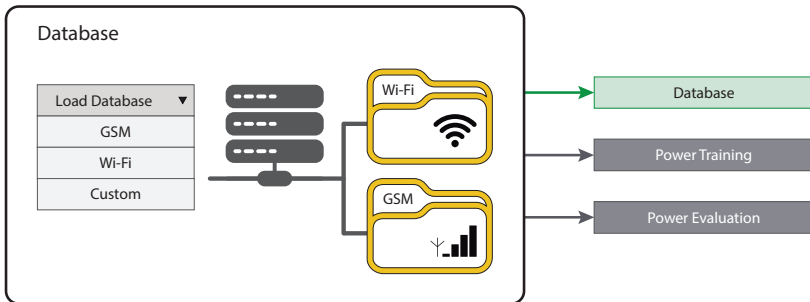


Figura 4.9. Función “*Database*”.

Fuente: elaboración propia.

4.4 Módulo colaborativo

Las estrategias colaborativas han brindado nuevos modelos para el uso eficiente de los recursos de radio y para el proceso de toma de decisiones en las CRN. En la decisión colaborativa, los usuarios se comunican entre sí para intercambiar mediciones de disponibilidad e interferencia; el objetivo es aprovechar la diversidad espacial. Para lograrlo, el usuario no licenciado comparte su información con los usuarios vecinos (Salgado *et al.*, 2016b). El enfoque colaborativo tiene más ventajas que el enfoque no colaborativo. Un desafío en la selección del espectro corresponde a cómo combinar la información de los usuarios de forma colaborativa mientras se realiza la transmisión (Thakur *et al.*, 2017).

Para analizar el proceso de toma de decisiones en escenarios colaborativos, donde los usuarios comparten diferentes cantidades de información de ocupación espectral, “*Collaborative Module*” segmenta la matriz de potencia según un número establecido de usuarios y diferentes niveles de colaboración. Cada nivel representa el porcentaje de información que será compartido para el entrenamiento y posterior validación del modelo. Los niveles son seleccionados de acuerdo con los límites de los datos: 10% y 100% corresponden a criterios de pocos y muchos datos; 50% a un valor intermedio entre los límites. Como elementos de salida se obtiene la matriz de potencia de entrenamiento segmentada.

La figura 4.10 presenta la interfaz correspondiente al resumen del módulo colaborativo disponible en la interfaz principal del simulador. Este módulo contiene dos botones; el primero, “*Collaborative Module*”, permite acceder a la ventana de parámetros del módulo, y el segundo, “*Setting Summary*”, generar un archivo en formato .xlsx con el resumen de los ajustes realizados. Para acceder al módulo solo se requiere seleccionar la opción “*Collaborative Module*” que estará habilitada solo si el módulo “*Project Information*” se parametrizó correctamente. Se abrirá una nueva ventana (figura 4.11) donde estará disponible cada uno de los ajustes del módulo.

Collaborative Module

Setting Collaborative

Collaborative Module **Default** Division Row Number User **1**

Segmentation Continuous User Percentage 100 Setting Summary

Figura 4.10. Resumen de parámetros “*Collaborative Module*”, interfaz principal App MultiColl-DCRN.

Fuente: elaboración propia.

Inicialmente, como se muestra en la figura 4.11, el único parámetro habilitado en el “*Collaborative Module*” es la variable “*Segmentation*”. Cuando se ajuste este parámetro se habilitará “*Division*”, la cual habilita “*User percentage*” y, a su vez, esta última habilita “*Number of Users*”. Además de los ajustes de habilitación de parámetros la ventana cuenta con un indicador color rojo que permanecerá si la información parametrizada está incompleta.

Help About

Collaborative Module

User Relation

Segmentation

Division

User Percentage

Number of Users

1 - 10 User

10 - 100 User

100 - 200 User

200 - 1000 User

Number Users

Output Module

Load Information

Default Values

UNIVERSIDAD DISTRITAL FRANCISCO JOSÉ DE CALDAS

Figura 4.11. Interfaz “*Collaborative Module*” App MultiColl-DCRN.

Fuente: elaboración propia.

Si el módulo se ajusta correctamente, el botón “*Load Information*” se habilita y el indicador cambia a color verde. Para regresar a la ventana principal solo se debe ejecutar el botón “*Load Information*”. En cualquier momento el usuario puede cargar los valores por defecto, solo se requiere seleccionar la opción “*Default Values*”.

El diagrama general del módulo colaborativo se presenta en la figura 4.12. Cuenta con cuatro parámetros de entrada: tres corresponden a variables ajustadas por el usuario en la interfaz y la cuarta variable es la matriz de salida del módulo “*Project Information*”. La lógica del algoritmo consiste en

tomar la matriz de entrenamiento “*Power Training*” y segmentarla de acuerdo con las entradas “*User Relation*” y “*Number of User*”. Como salida del módulo se obtiene la matriz de potencia segmentada para el entrenamiento e información del ajuste del módulo que se visualizara en la interfaz principal.




Figura 4.12. Estructura general “*Collaborative Module*”.

Fuente: elaboración propia.

En las secciones 4.4.1, 4.4.2 y 4.4.3 se presenta la descripción detallada de las variables de entrada, salida y metodología de los “*Collaborative Modules*”.

4.4.1 Variables de entrada

La figura 4.13 presenta en detalle las variables de entrada para el “*Collaborative Module*”, elaborada con el fin de describir específicamente el control que tiene el usuario sobre las variables del módulo, además, de la relación en términos de interfaz gráfica de la figura 4.11. Adicionalmente, incluye las funciones que se requieren para la segmentación de la matriz de potencia —estas serán analizadas en detalles en las secciones posteriores—. Como se mencionó previamente, en cualquier momento el usuario puede cargar los valores por defecto, solo se requiere seleccionar la opción “*Default Values*”. La figura 4.13 describe la asignación de cada variable si se selecciona esta opción.

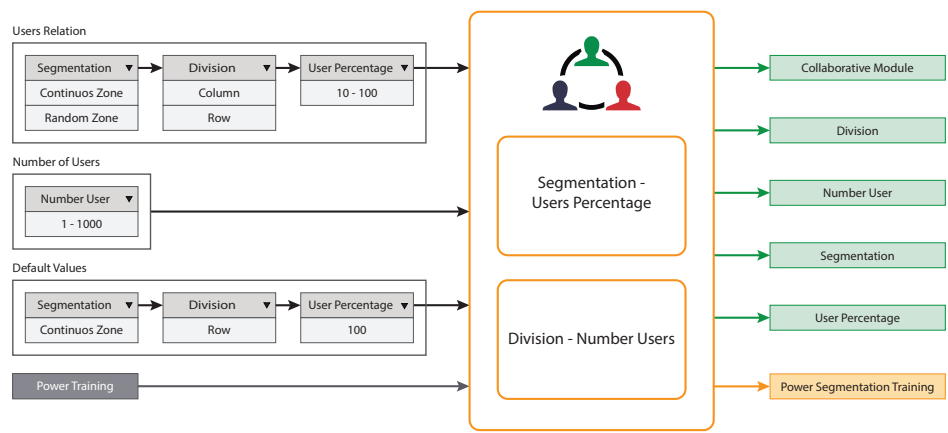


Figura 4.13. Variables de entrada y funciones “Collaborative Module”.

Fuente: elaboración propia.

Como se identifica en la figura 4.13, el módulo tiene tres conjuntos de variables de entrada: “User Relation”, “Number User” y “Power Training”. La descripción de cada una de las variables se presenta en las tablas 4.5, 4.6 y 4.7. En la tabla 4.8 se describen los valores asignados por defecto si no se parametriza el módulo colaborativo.

Tabla 4.5. Relación de usuarios “Collaborative Module”.

Variable	Elemento	Descripción
Segmentation	Random Zone	El porcentaje de usuarios seleccionados para la simulación se toman de forma aleatoria.
	Continuous Zone	El porcentaje de usuarios seleccionados para la simulación se toman en orden, por filas o por columnas.
Division	Column	Se dividen las filas de la matriz de potencia en 10 partes iguales y las columnas se dividen en n partes hasta completar el número de usuarios.
	Row	Se dividen las columnas de la matriz de potencia en 10 partes iguales y las filas se dividen en n partes hasta completar el número de usuarios.
User percentage	10-100	Porcentaje de usuarios que participarán en el entrenamiento.

Fuente: elaboración propia.

Tabla 4.6. Número de usuarios “*Collaborative Module*”.

Variable	Elemento	Descripción
<i>Number of users</i>	1-1000 User	Número de usuarios que conforman (dividen) la matriz de potencia para el entrenamiento.

Fuente: elaboración propia.

Tabla 4.7. Matriz de potencia “*Collaborative Module*”.

Variable	Tráfico	Descripción
<i>Power Training</i>	<i>High</i>	Matriz de tráfico de potencia para el entrenamiento, correspondiente a la variable de salida del módulo “ <i>Project Information</i> ”.
	<i>Low</i>	

Fuente: elaboración propia.

Tabla 4.8. Valores por defecto “*Collaborative Module*”.

Variable	Descripción
<i>Segmentation</i>	<i>Continuous Zone</i>
<i>Division</i>	<i>Row</i>
<i>User percentage</i>	100

Fuente: elaboración propia.

4.4.2 Variables de salida

Como se identifica en la figura 4.13 el algoritmo tiene seis variables de salida, la descripción de estas variables se presenta en la tabla 4.9.

Tabla 4.9. Variables de salida “*Collaborative Module*”.

Variable	Descripción
<i>Collaborative Module</i>	Interfaz donde se visualiza si el módulo colaborativo fue parametrizado (<i>Enable</i>) o si utiliza valores por defecto (<i>Default</i>).
<i>Division</i>	Interfaz donde se visualiza el tipo de división para la selección de usuarios.
<i>Number User</i>	Interfaz donde se visualiza la cantidad de usuarios que segmentan la matriz de entrada.
<i>Segmentation</i>	Visualización de la metodología para la selección de los usuarios.
<i>User Percentage</i>	Visualización del porcentaje de usuarios que compartirán información en la fase de entrenamiento.
<i>Power Segmentation Training</i>	Información de los usuarios seleccionados para el proceso de entrenamiento.

Fuente: elaboración propia.

4.4.3 Metodología del módulo

La descripción específica del módulo colaborativo requiere analizar dos funciones que permiten segmentar la matriz. La figura 4.13 presenta el diagrama con las funciones del modelo colaborativo: “*Division – Number Users*” y “*Segmentation–Users Percentage*”. Cada una de estas funciones es analizada en detalle en las figuras 4.14 y 4.15, respectivamente.

Función “Division – Number Users”

La figura 4.14 presenta el diagrama de bloques de la función. Como variable externa requiere de la matriz “*Power Training*”, la cual corresponde a la variable de salida del módulo “*Project Information*”. Adicionalmente, requiere la información de entrada de “*Number User*” y “*Division*”. La función maneja cuatro variables de salida —tres corresponden a la información que se visualiza en el resumen de parámetros del módulo colaborativo en la interfaz principal (figura 4.10)—. Estas variables son “*Collaborative module*”, “*Division*” y “*Number User*”; “*Power Segmentation*” es la cuarta variable y contiene la información interna que requiere la función “*Segmentation–Users Percentage*”.

La función “*Division – Number Users*” es la encargada de dividir la matriz de entrada “*Power Training*” en submatrices. Cada submatriz corresponde a la información que caracteriza a un usuario, por tanto, el número de submatrices responde al número de usuarios. La cantidad de usuarios (n) se ajusta de acuerdo con el parámetro “*Number User*” y “*Division*” establece la metodología para realizar la división. Si el número de usuarios es mayor a diez ($Number\ User \geq 10$) y la división se parametriza por filas ($Division = Row$), se dividen las filas de “*Power Training*” en 10 partes iguales y las columnas se dividen en m partes hasta completar el número de usuarios ($Number\ User = 10(m)$); si se realiza por columnas ($Division = Column$), se dividen las columnas de “*Power Matrix*” en 10 partes iguales y las filas se dividen en m partes hasta completar el número de usuarios ($Number\ User = 10(m)$). Para un número de usuarios menor a diez ($Number\ User < 10$), la división por filas ($Division = Row$) o por columnas ($Division = Column$) se realiza en dos partes iguales; la variable dependiente se divide en m partes hasta completar el número de usuarios ($Number\ User = 2(m)$). La variable interna “*Power Segmentation*” contiene la información de las n submatrices generadas en la división.

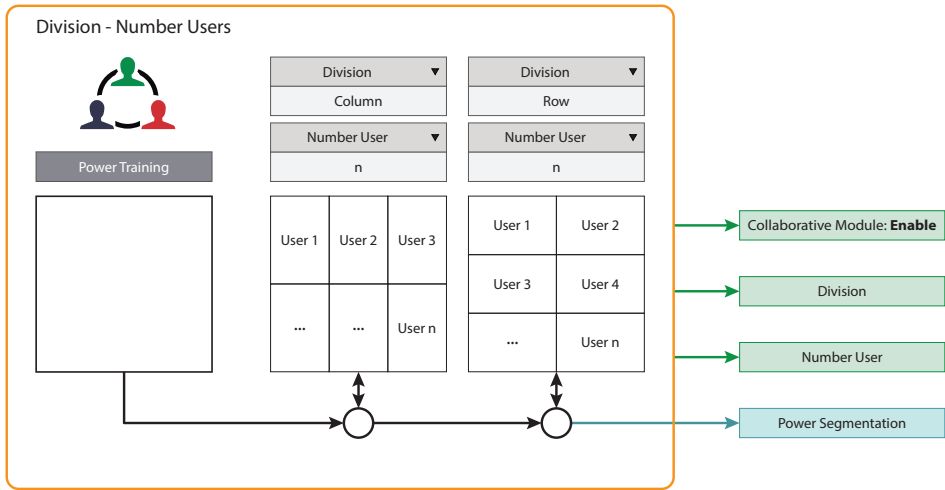


Figura 4.14. Función “*Division – Number Users*”.

Fuente: elaboración propia.

Función “Segmentation–Users Percentage”

La figura 4.15 presenta el diagrama de bloques de la función. Como variable interna requiere de la matriz *Power Segmentation* la información de entrada de “*Segmentation*” y “*User Percentage*”. La función maneja tres variables de salida: dos corresponden a la información que se visualiza en el resumen de parámetros del módulo colaborativo en la interfaz principal (figura 4.10). Estas variables son “*Segmentation*” y “*User Percentage*”. “*Power Segmentation Training*” es la tercera variable y contiene la información de salida del “*Collaborative Module*”.

La función “*Segmentation–Users Percentage*” es la encargada de establecer los diferentes niveles de colaboración, seleccionando la cantidad de información que se compartirá en la fase de entrenamiento de los modelos. Los niveles de colaboración se ajustan de acuerdo con el porcentaje ajustado en la variable “*Users Percentage*”: 10% y 100% corresponden a los criterios de mínimo nivel y total colaboración, respectivamente. Para seleccionar los usuarios que harán parte del proceso de colaboración, el módulo utiliza dos metodologías disponibles en la variable “*Segmentation*”. En la primera opción el simulador selecciona de forma aleatoria los usuarios (*Segmentation = User Zone Random*), y en la segunda opción elige de forma continua (*Segmentation*

= *User Zone Continuous*). La figura 4.15 presenta las dos metodologías. La variable de salida “*Power Segmentation*” contiene la información de los usuarios seleccionados para el proceso de entrenamiento, esta variable se requiere como parámetro de entrada del “*Parameters Module*”.

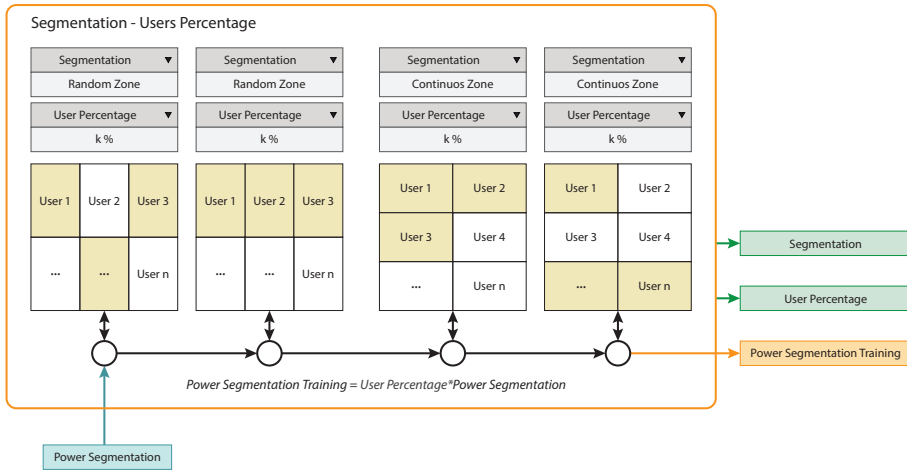


Figura 4.15. Función “*Segmentation–Users Percentage*”.

Fuente: elaboración propia.

4.5 Módulo multiusuario

Para analizar el proceso de toma de decisiones bajo escenarios multiusuario, “*Multi-user Module*” permite ajustar tres parámetros de escenarios realistas. El primero corresponde al número de SU que participarán en el proceso. El segundo permite asignar canales múltiples a los diferentes usuarios. El tercero simula usuarios aleatorios en tiempo específicos.

La figura 4.16 presenta la visualización correspondiente al resumen del módulo multiusuario disponible en la interfaz principal del simulador. Este módulo contiene dos botones; el primero —*Multi-user Module*— permite acceder a la ventana de parámetros del módulo, y el segundo —*Setting Summary*—, generar un archivo en formato .xlsx con el resumen de los ajustes realizados. Para acceder solo se requiere seleccionar la opción “*Multi-user Module*”, que estará habilitada si el módulo “*Project Information*” se parame-trizó correctamente. Se abrirá una nueva ventana (figura 4.17) donde estará disponible cada uno de los ajustes del módulo.




Figura 4.16. Resumen de parámetros “Multi-user Module”, interfaz principal App MultiColl-DCRN.

Fuente: elaboración propia.

Inicialmente, como se muestra en la figura 4.17, el único parámetro habilitado en “Multi-user Module” es la variable “Multichannel Bands”. Cuando se ajuste este parámetro se habilitarán los bloques “Channels” y “Percent”. Según el número de “Multichannel Bands”, “Channels” y “Percent” se habilita “Simulation Mode” y este último habilita “Serial Users”. Para incluir dentro de las gráficas el comportamiento de los usuarios aleatorios “Simulation Mode” se debe seleccionar “Real Mode”. Además de los ajustes de habilitación de parámetros la ventana cuenta con un indicador color rojo que permanecerá si la información parametrizada está incompleta.

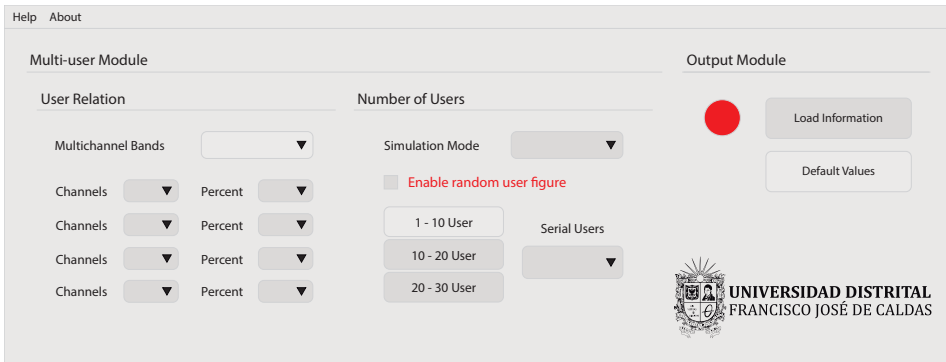


Figura 4.17. Interfaz “Multi-user Module” App MultiColl-DCRN.

Fuente: elaboración propia.

Si el módulo se ajusta correctamente, el botón “Load Information” se habilita y el indicador cambia a color verde. Para regresar a la ventana principal, solo se debe ejecutar “Load Information”. En cualquier momento el usuario puede cargar los valores por defecto, solo se requiere seleccionar la opción “Default Values”.

El diagrama general del módulo colaborativo se presenta en la figura 4.18. Cuenta con cuatro parámetros de entrada: tres corresponden a variables

ajustadas por el usuario en la interfaz y la cuarta a variable es la matriz de salida del módulo “*Project Information*”. La lógica del algoritmo consiste en tomar la matriz de entrenamiento “*Power Training*” y segmentarla de acuerdo con las entradas “*User Relation*” y “*Number of User*”. Como salida del módulo se obtiene la matriz de potencia segmentada para el entrenamiento e información del ajuste del módulo que se visualizará en la interfaz principal.

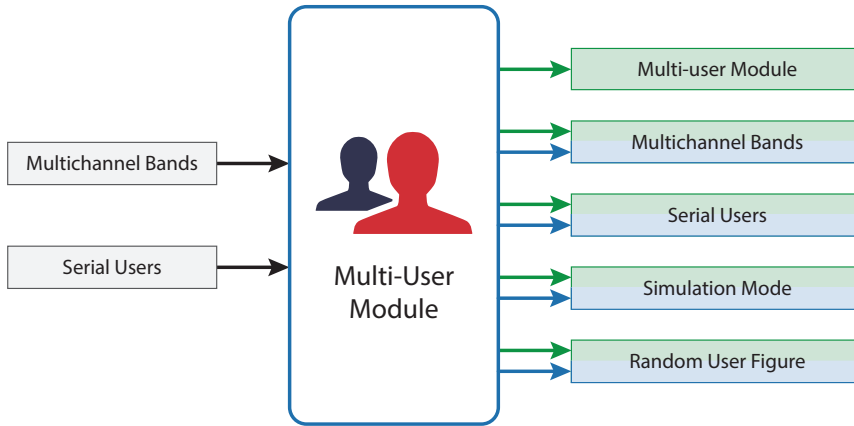


Figura 4.18. Estructura general “*Multi-user Module*”.

Fuente: elaboración propia.

En las secciones 4.5.1, 4.5.2 y 4.5.3 se presenta la descripción detallada de las variables de entrada, salida y metodología de “*Multi-user Module*”.

4.5.1 Variables de entrada

La figura 4.19 presenta en detalle las variables de entrada para el “*Multi-user Module*”. Esta figura fue elaborada con el objetivo de describir específicamente el control que tiene el usuario sobre las variables del módulo, además, de la relación en términos de la interfaz gráfica, de la figura 4.17. Adicionalmente, incluye las funciones que se requieren para el análisis de escenarios multiusuario. Estas funciones serán analizadas en detalle en las secciones posteriores. Como se mencionó previamente, en cualquier momento el usuario puede cargar los valores por defecto, solo se requiere seleccionar la opción “*Default Values*”. En la figura 4.19 se describe la asignación de cada variable si se selecciona esta opción.

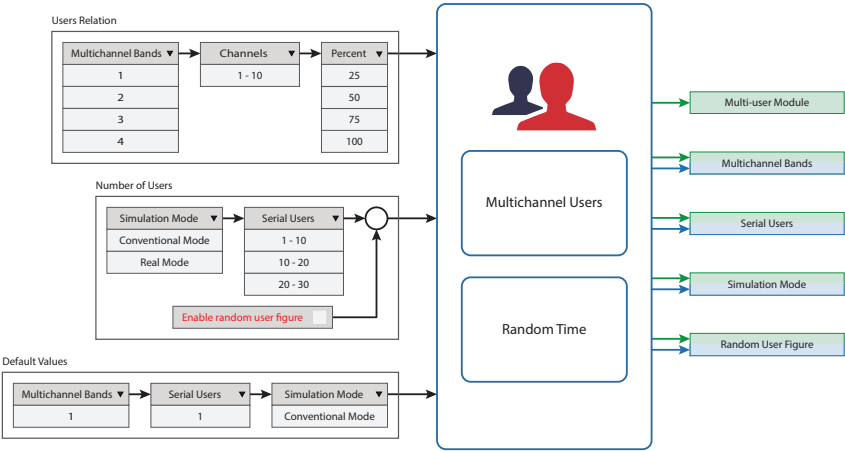


Figura 4.19. Variables de entrada y funciones “Multi-user Module”.

Fuente: elaboración propia.

Como se identifica en la figura 4.19, el módulo tiene dos conjuntos de variables de entrada: “User Relation”, “Number User”, la descripción de cada una de las variables se presenta en las tablas 4.10 y 4.11. En la tabla 4.12 se describen los valores asignados por defecto si no se parametriza el módulo multiusuario.

Tabla 4.10. Relación de usuarios “Multi-user Module”.

Variable	Elemento	Descripción
<i>Multichannel Bands</i>	1–4	Número de aplicaciones seleccionados para la simulación.
<i>Channels</i>	1–10	Número de canales necesarios para cada aplicación seleccionado.
<i>Percent</i>	25 %–100 %	Porcentaje de usuarios que adquieren la característica de la aplicación y de la cantidad de canales.

Fuente: elaboración propia.

Tabla 4.11. Número de usuarios “Multi-user Module”.

Variable	Elemento	Descripción
<i>Simulation Mode</i>	<i>Conventional Mode</i>	Simulación sin usuarios aleatorios en tiempos específicos.
	<i>Real Mode</i>	Simulación con usuarios aleatorios en tiempos específicos.
<i>Serial Users</i>	1–30	Número de usuarios seriales.

Variable	Elemento	Descripción
<i>Enable random user figure</i>	<i>Enable</i>	La métrica de evaluación incluye a los usuarios aleatorios.
	<i>Disabled</i>	La métrica de evaluación no incluye los usuarios aleatorios.

Fuente: elaboración propia.

Tabla 4.12. Valores por defecto “*Multi-user Module*”.

Variable	Descripción
<i>Multichannel Bands</i>	<i>Continuous Zone</i>
<i>Serial Users</i>	<i>Row</i>
<i>Simulation Mode</i>	<i>Conventional Mode</i>

Fuente: elaboración propia.

4.5.2 Variables de salida

Como se identifica en la figura 4.19 el algoritmo tiene cinco variables de salida, la descripción de estas variables se presenta en la tabla 4.13.

Tabla 4.13. Variables de salida “*Multi-user Module*”.

Variable	Descripción
<i>Multi-user Module</i>	Visualización en la interfaz del módulo multiusuario. Parametrizado (<i>Enable</i>) o valores por defecto (<i>Default</i>).
<i>Multichannel Bands</i>	Información de número de aplicaciones seleccionados, adicionalmente, se visualiza en la interfaz.
<i>Serial Users</i>	Información de número de usuarios seriales, adicionalmente, se visualiza en la interfaz.
<i>Simulation Mode</i>	Habilita o deshabilita los usuarios aleatorios, se visualiza en la interfaz.
<i>Random User Figure</i>	Visualiza en la interfaz si las métricas incluyen el comportamiento de los usuarios aleatorios.

Fuente: elaboración propia.

4.5.3 Metodología del módulo

La descripción específica del módulo multiusuario requiere analizar dos funciones que permiten caracterizar el comportamiento de los usuarios. La figura 4.19 presenta el diagrama con las funciones del modelo colaborativo:

“*Multichannel Users*” y “*Segmentation–Users Percentage*”, cada una de estas funciones es analizada en detalle en las figuras 4.20 y 4.21, respectivamente.

Función “*Multichannel Users*”

La figura 4.20 presenta el diagrama de bloques de la función: se requiere la información de entrada de “*Multichannel Bands*”, “*Channels*” y “*Percent*”. Maneja dos variables de salida: “*Multi-user Module*” y “*Multichannel Bands*”.

La función “*Multichannel Users*” es la encargada de parametrizar el número de aplicaciones, el número de canales para cada aplicación y el porcentaje de usuarios que adquiere la característica de la aplicación y de la cantidad de canales.

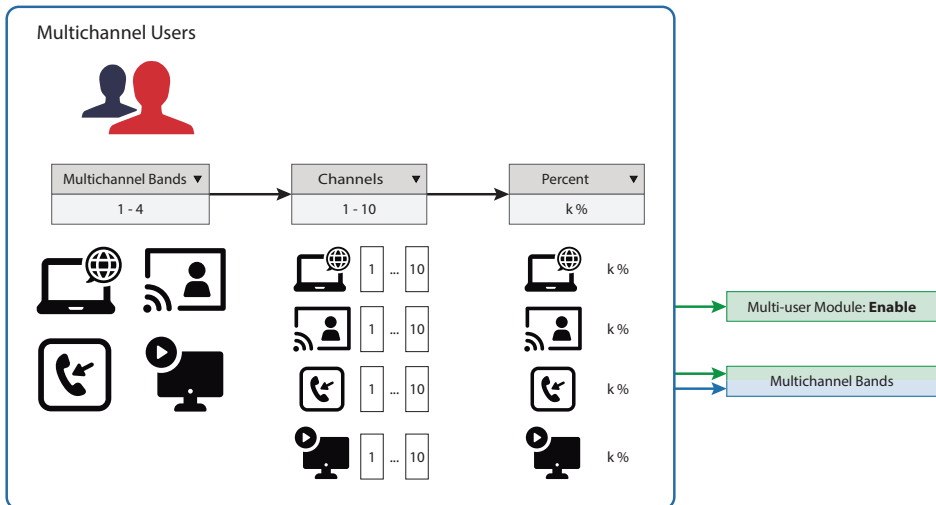


Figura 4.20. Función “*Multichannel Users*”.

Fuente: elaboración propia.

Función “*Random Users*”

Es la encargada de seleccionar el número de usuarios seriales y si la simulación cuenta con usuarios aleatorios. La figura 4.21 presenta el diagrama de bloques de esta función. Se requiere información de entrada de “*Serial Users*”, “*Simulation Mode*” y “*Enable random user figure*”. La función maneja tres variables de salida: “*Serial Users*”, “*Simulation Mode*” y “*Random User Figure*”.

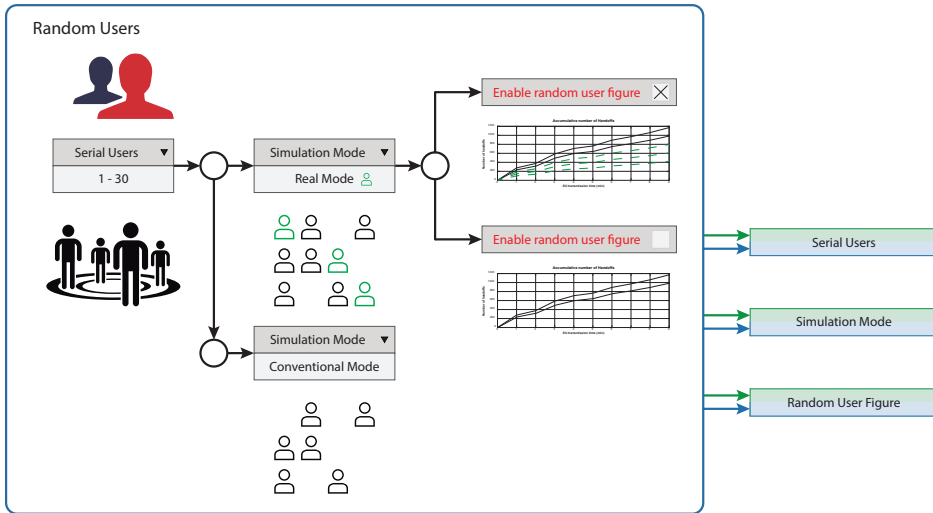


Figura 4.21. Función “Random Users”.

Fuente: elaboración propia.

4.6 Parameters Module

La figura 4.22 presenta la interfaz correspondiente a “Parameters Modules”, en este módulo se parametriza el *Threshold*, *Noise Floor*, *Bandwidth Fixed* y *Multichannels*. Adicionalmente, se caracteriza el nivel de tráfico y tiempo de transmisión.




Figura 4.22. “Parameters Modules” MultiColl-DCRN.

Fuente: elaboración propia.

“Parameters Modules” se habilita si “Project Information” es parametrizado correctamente, como se muestra en la figura 4.22. El diagrama general del módulo se presenta en la figura 4.23. Cuenta con cinco parámetros de entrada: cuatro corresponden a variables ajustadas por el usuario en la interfaz, y la quinta variable es la matriz de salida del “Collaborative Module”. No requiere

ajustes de “*Multi-User Module*”; el simulador asume valores por defecto si el caso de estudio no requiere incorporar análisis colaborativo.

La lógica del algoritmo es la elaboración de una nueva base de datos de variables de entrada y selección de información. Para la nueva base de datos se almacena la información de “*Threshold*”, “*Noise Floor*”, “*Bandwidth Fixed*”, “*Multichannels*” y “*Time*”. Posteriormente, esta nueva base de datos se incorpora en las estrategias de predicción y no predicción. Para la selección de información, toma de la matriz “*Power Segmentation Training*” (generada a través del “*Collaborative Module*” o de los valores por defecto) la base de datos de entrenamiento. De acuerdo con el nivel de tráfico, se aplica el mismo proceso para la matriz “*Power Evaluation*” generada a través de “*Project Information*”. Como salida del módulo se obtiene la base de datos de las variables parametrizadas y la base de datos de potencia para el entrenamiento y validación de acuerdo con el nivel de tráfico.

En las secciones 4.6.1, 4.6.2 y 4.6.3 se presenta la descripción detallada de las variables de entrada, salida y metodología de “*Parameters Modules*”.

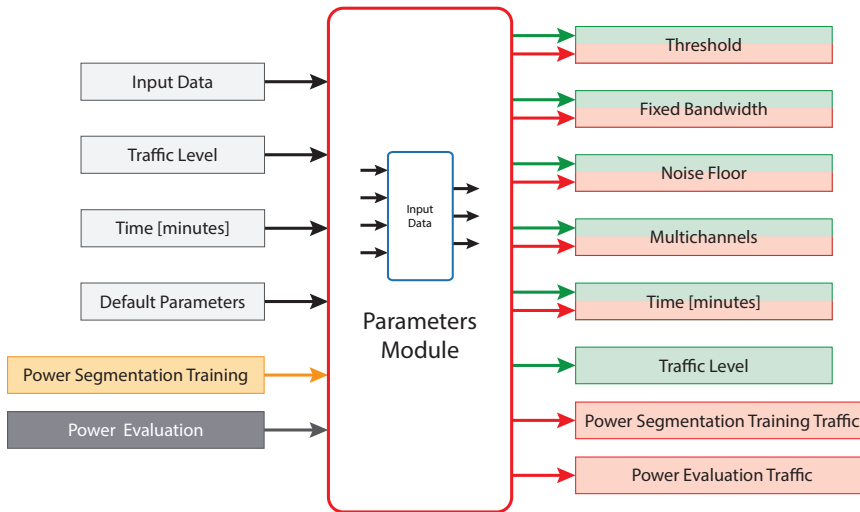


Figura 4.23. Estructura general “*Parameters Module*”.

Fuente: elaboración propia.

4.6.1 Variables de entrada

La figura 4.24 fue elaborada con el objetivo de describir específicamente el control que tiene el usuario sobre las variables del módulo, además, de la relación en términos de la interfaz gráfica de la figura 4.22. Incluye las funciones que se requieren para la construcción de la nueva base de datos y la selección de la matriz potencia para el entrenamiento y validación de las técnicas —estas funciones serán analizadas en detalles en las secciones posteriores—. En cualquier momento el usuario puede cargar los valores por defecto, solo se requiere seleccionar la opción “*Default Values*”. En la figura 4.24 se describe la asignación de cada variable si se selecciona esta opción.

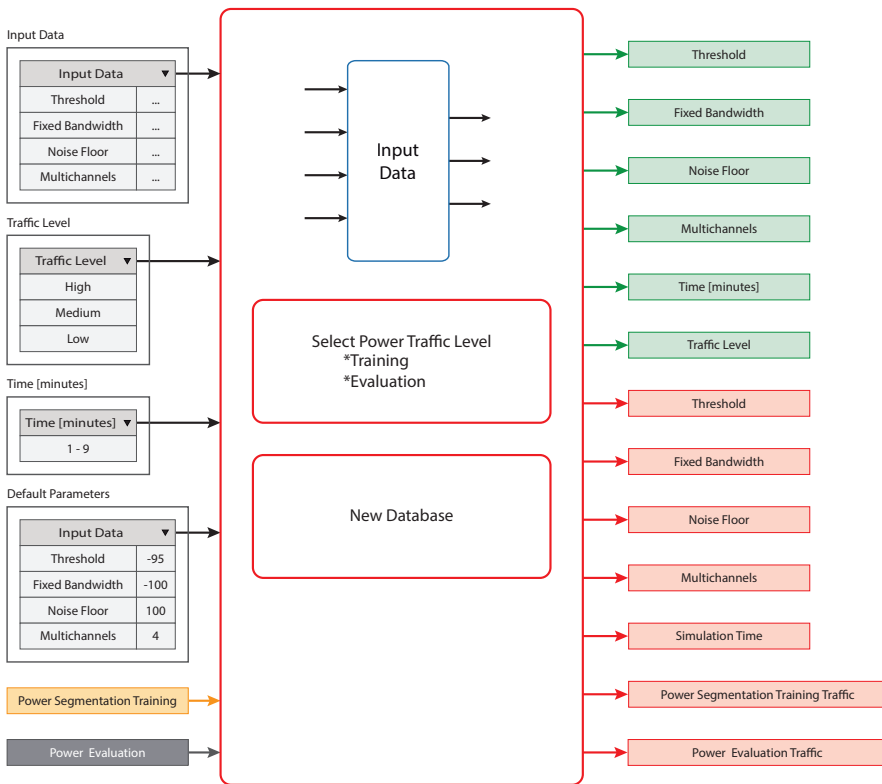


Figura 4.24. Variables de entrada y funciones “*Parameters Module*”.

Fuente: elaboración propia.

Como se identifica en la figura 4.24, el módulo tiene cinco conjuntos de variables de entrada: “*Input Data*”, “*Traffic Level*”, “*Time*”, “*Power Segmentation*

Training” y *Power Evaluation*”. La descripción de cada una de las variables se presenta en las tablas 4.14, 4.15, 4.16, 4.17 y 4.18. En la tabla 4.19 se describen los valores asignados por defecto.

Tabla 4.14. Datos de entrada “*Parameters Module*”.

Parámetros	Descripción
Threshold	Umbral de decisión para determinar si una oportunidad espectral está disponible.
Noise Floor	Piso de ruido promedio.
BW Fixed	BW fijo para cada canal de frecuencia.
Multichannels	Número máximo de canales adyacentes disponibles que se pueden agrupar para formar un solo canal.

Fuente: elaboración propia.

Tabla 4.15. Nivel de tráfico “*Parameters Module*”.

Variable	Elemento	Descripción
<i>Traffic Level</i>	<i>High</i>	Trazas de información que representan el comportamiento del espectro cuando la red tiene un nivel de tráfico alto, medio y bajo.
	<i>Medium</i>	
	<i>Low</i>	

Fuente: elaboración propia.

Tabla 4.16. Tiempo “*Parameters Module*”.

Variable	Elemento	Descripción
<i>Time [minutes]</i>	1-9	Tiempo de transmisión en minutos del SU.

Fuente: elaboración propia.

Tabla 4.17. Matriz de potencia segmentada para entrenamiento “*Parameters Module*”.

Variable	Descripción
<i>Power Segmentation Training</i>	Contiene la información de la matriz segmentada de potencia de acuerdo con el nivel de tráfico para el entrenamiento de las técnicas de predicción y no predicción.

Fuente: elaboración propia.

Tabla 4.18. Matriz de potencia para evaluación “*Parameters Module*”.

Variable	Descripción
<i>Power Evaluation</i>	Información de la matriz de potencia de acuerdo con el nivel de tráfico para la validación de las técnicas de predicción y no predicción.

Fuente: elaboración propia.

Tabla 4.19. Valores por defecto “*Parameters Module*”.

Variable	Descripción
<i>Threshold</i>	-95
<i>Noise Floor</i>	-100
<i>BW Fixed</i>	100
<i>Multichannels</i>	4

Fuente: elaboración propia.

4.6.2 Variables de salida

Como se identifica en la figura 4.24 el algoritmo tiene seis variables de salida para visualización en la interfaz, y ocho variables de salida del módulo que requieren los modelos de no predicción y predicción, la descripción de las variables se presenta en la tabla 4.20.

Tabla 4.20. Variables de salida “*Parameters Module*”.

Variable	Descripción
<i>Threshold</i>	Visualización asociada al umbral de decisión parametrizado.
<i>Noise Floor</i>	Visualización asociada al piso de ruido promedio parametrizado.
<i>BW Fixed</i>	Visualización asociada al BW fijo parametrizado.
<i>Multichannels</i>	Visualización asociada al número máximo de canales adyacentes disponibles parametrizado.
<i>Traffic Level</i>	Visualización asociada al nivel de tráfico seleccionado.
<i>Time [minutes]</i>	Visualización asociada al tiempo de transmisión en minutos del SU seleccionado.
<i>Power Segmentation Training Traffic</i>	Corresponde a la matriz de entrenamiento de potencia segmentada para tráfico seleccionado.
<i>Power Evaluation Traffic</i>	Corresponde a la matriz de evaluación de potencia para el tráfico seleccionado.

Fuente: elaboración propia.

4.6.3 Metodología del módulo

Para la descripción específica del módulo se requiere analizar las funciones que generan la base de datos y selecciona la información de acuerdo con el tipo de tráfico. La figura 4.24 presenta el diagrama con las funciones

“Parameters Module”: “Select Power Traffic Level” y “New Database”. Cada una de estas funciones es analizada en detalle en las figuras 4.25 y 4.26, respectivamente.

Función “Select Power Traffic Level”

La figura 4.25 presenta el diagrama de bloques de la función. Como variable externa requiere la matriz “Power Evaluation” y “Power Segmentation Training”, la cual corresponde a las variables de salida del módulo “Project Information” y “Collaborative Module”, respectivamente. Además, requiere la información de entrada “Traffic Level”. La función maneja dos variables de salida, equivalentes a la matriz de potencia de entrenamiento y validación.

La función “Select Power Traffic Level” es la encargada de seleccionar de la base de datos principal la matriz de evaluación de acuerdo con el tráfico ajustado; el criterio de selección se realiza para la matriz de potencia segmentada que se utilizara para el entrenamiento.

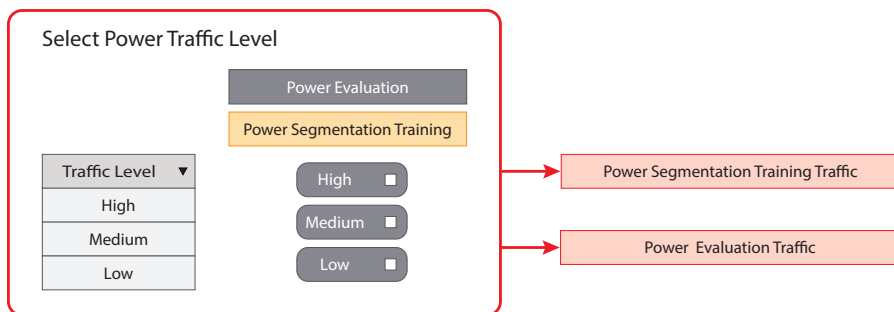


Figura 4.25. Función “Select Power Traffic Level”.

Fuente: elaboración propia.

Función “New Database”

La figura 4.26 presenta el diagrama de bloques de la función; solo requiere información de entrada de la interfaz, la cual es almacenada a través de una nueva base de datos. Cada una de las variables almacenadas se utilizará para el ajuste de las técnicas de predicción y no predicción. Además, estas variables son utilizadas para visualización de información en la interfaz. La base de datos guarda los ajustes realizados a las variables “Threshold”, “Noise Floor”, “Bandwidth Fixed”, “Multichannels” y “Time”.

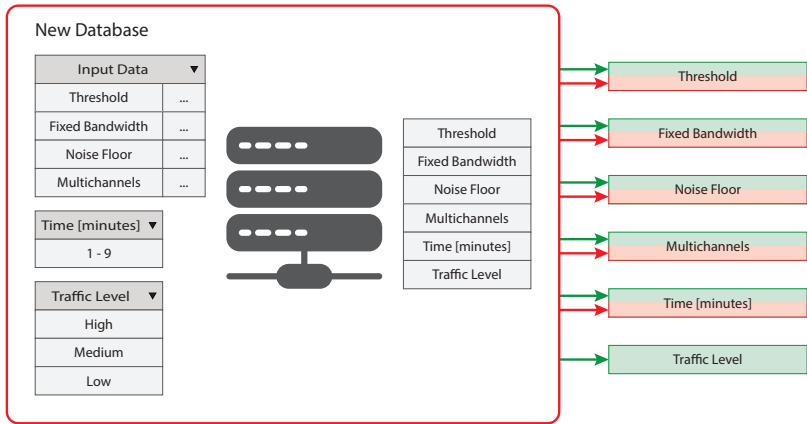


Figura 4.26. Función “New Database”.

Fuente: elaboración propia.

4.7 Models module

Contiene las diferentes estrategias que se pueden utilizar para el análisis de toma de decisiones. Los usuarios tienen disponibles siete modelos (11, si se incluyen cinco modelos autorregresivos que forman las series de tiempo). Como se muestra en la figura 4.27, cinco modelos para técnicas de predicción y dos modelos para el análisis de técnicas no predictivas.

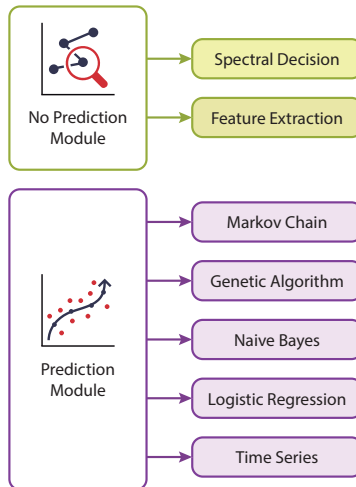


Figura 4.27. Modelos disponibles.

Fuente: elaboración propia.

La figura 4.28 presenta la interfaz correspondiente a “*Prediction module*”. El usuario puede seleccionar entre dos opciones: “*No prediction*” y “*Prediction*”; como su nombre lo indica, cada opción está asociada al conjunto de modelos disponible.

“*Parameters Modules*” se habilita si “*Project Information*” es parametrizado correctamente, como se muestra en la figura 4.28.




Figura 4.28. Módulo de técnicas de no predicción y predicción MultiColl-DCRN.

Fuente: elaboración propia.

En las siguientes secciones se describe en detalle cada una de las estrategias implementadas. Cada modelo es independiente, sin embargo, requieren de parámetros y algoritmos en común. Los parámetros están asociados a las variables de salida de los módulos, los algoritmos se citan en la siguiente lista:

- Algoritmo parámetros iniciales
- Algoritmo *ranking* multicriterio
- Algoritmo de búsqueda
- Algoritmo indicador de predicción

A continuación, se realiza la descripción de los algoritmos, posteriormente se detalla la estructura de cada una de las técnicas implementadas.

4.7.1 Algoritmo parámetros iniciales

Independiente de los ajustes realizado al tipo de red, nivel de tráfico, niveles de colaboración, número de usuarios y a la técnica de análisis, el simulador requiere establecer tres parámetros iniciales: Disponibilidad, SINR y BW.

Estos se determinan a través de la función “*Initial Parameters*”. La figura 4.29 presenta el flujo de variables de entrada y de salida como se describe en la figura, se requieren seis variables de entrada, las cuales son tomadas del “*Parameters Modules*”.

El simulador transforma los datos de las matrices “*Power Evaluation Traffic*” y “*Power Segmentation Training*” en valores binarios según la restricción dada por el valor “*Threshold*”; el resultado obtenido representa la matriz “*Evaluation Availability*” y “*Training Availability*”. El valor “*Noise Floor*” permite calcular la matriz “*SINR*” basada en los datos de potencia. Finalmente, “*Fixed Bandwidth*” y “*Multichannels*” conforman los parámetros para el “*Bandwidth*” que se obtiene con la matriz de disponibilidad.

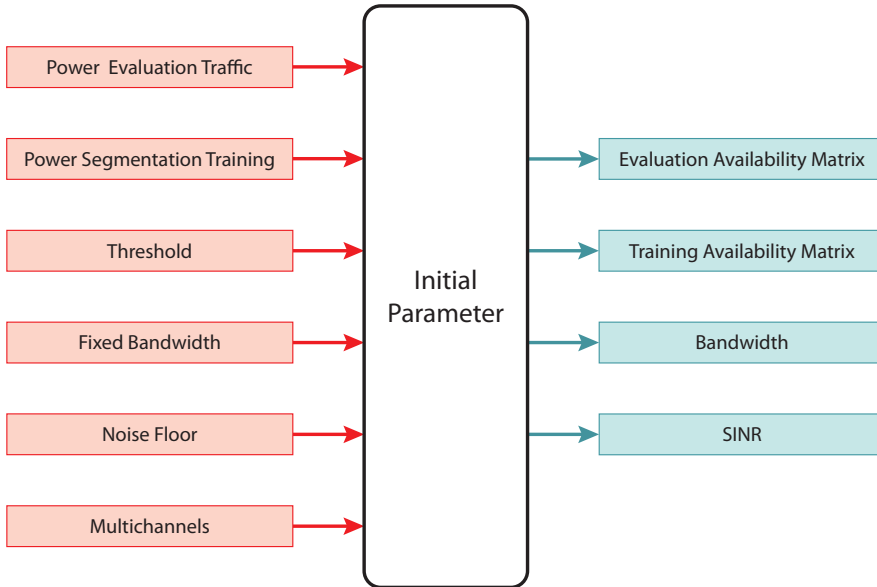


Figura 4.29. Función “*Initial Parameter*”.

Fuente: elaboración propia.

En las secciones 4.7.1.1, 4.7.1.2 y 4.7.1.3 se presenta la descripción y algoritmos implementados para cada uno de los parámetros iniciales.

4.7.1.1 Disponibilidad

El simulador transforma los datos de potencia que están en un rango entre [-40 y -147] a valores binarios según la restricción dada al campo *Threshold*,

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. El Algoritmo 8 presenta la estructura de programación implementada para obtener “*Evaluation Availability*” y “*Training Availability*”.

Algoritmo 8. Estructura matriz de disponibilidad.

Availability Matrix
<pre> % Evaluation Availability Matrix If Power Evaluation Traffic > Threshold Evaluation Availability Matrix = 1 else Evaluation Availability Matrix = 0 end % Evaluation Availability Matrix If Power Segmentation Training > Threshold Evaluation Availability Matrix = 1 else Evaluation Availability Matrix = 0 end </pre>

Fuente: elaboración propia.

4.7.1.2 Relación señal a ruido más interferencia (SINR)

A partir de “*Noise Floor*” y de las matrices “*Power Evaluation Traffic*” y “*Power Segmentation Training*” se determina la SINR: se realiza la resta entre la matriz de datos de potencia y la variable “*Noise floor*”. El Algoritmo 9 presenta la estructura de programación implementada para obtener “*SINR*”.

Algoritmo 9. Estructura SINR

SINR-Relación Señal a Ruido más Interferencia
<pre> function [SINR] = Initial_Parameter(Power, Noise_floor) SINR = Power-Evaluation Availability Matrix end </pre>

Fuente: elaboración propia.

4.7.1.3 Bandwidth (BW)

Para determinar la matriz de BW se utiliza la matriz de disponibilidad previamente obtenida y los parámetros de “*Fixed Bandwidth*” y “*Multichannels*”. El Algoritmo 10 presenta la estructura de programación implementada para obtener “*Bandwidth*”.

Algoritmo 10. Estructura matriz ancho de banda.

Matriz Ancho de Banda		
function	[Bandwidth]	= Initial_Parameter (Available, Multichannel, <i>Fixed_Bandwidth</i>)
	i = Current Time Step	
	j = Current Frequency	
	switch Availability	
	case 0	
	Bandwidth(i , j) = <i>Fixed_Bandwidth</i> ;	
	case 1	
	for d = 1 : Multichannel	
	if Available(i , j+d) == 1	
	Accountant = Accountant + 1;	
	end	
	end	
	for d = 1 : Multichannel	
	if Available(i , j-d) == 1	
	Accountant = Accountant + 1;	
	end	
	end	
	Bandwidth(i, j) = <i>Fixed_Bandwidth</i> * (Accountant + Available(i , j));	
end		

Fuente: elaboración propia.

4.7.2 Algoritmo *ranking* multicriterio

El algoritmo *ranking* utiliza análisis multicriterio para asignarle una puntuación a los diferentes canales. Se utilizan los criterios AP, ETA, promedio de SINR y promedio BW, para establecer los canales con mayor probabilidad de oportunidad espectral. La figura 4.30 presenta el flujo de variables de entrada y de salida; como se describe en la figura, para establecer el *ranking*, se requiere implementar dos funciones, la primera —denominada “*Parameter*

Ranking”, determina los criterios de probabilidad y promedio— utiliza cuatro variables de entrada; tres son variables internas que se obtienen del algoritmo de parámetros iniciales y una cuarta variable de información de entrada. La segunda función “*Ranking*”, toma los datos de “*Parameter Ranking*” y dos variables de información de entrada para calcular la puntuación de los canales con mayor probabilidad de oportunidad espectral.

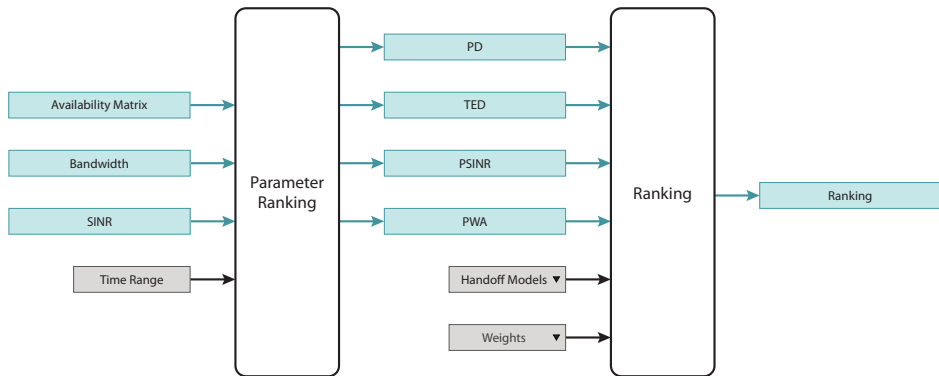


Figura 4.30. Funciones “Ranking”.

Fuente: elaboración propia.

En las secciones 4.7.2.1 y 4.7.2.2 se presenta la descripción y algoritmos implementados para las funciones del algoritmo *ranking* multicriterio.

4.7.2.1 *Parameter Ranking*

La función “*Parameter Ranking*” determina los criterios de AP, ETA, promedio de SINR y ABW, estos criterios son calculados para cada uno de los canales de la matriz de disponibilidad, la sigla y descripción de cada uno de los criterios se presenta en la tabla 4.21.

Tabla 4.21. Vectores para el análisis multicriterio.

Siglas	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.
ASINR	Promedio de SINR	Promedio de cada columna de la matriz de SINR sin tener en cuenta los ceros.

Siglas	Promedio	Descripción
ABW	Ancho de banda promedio	Promedio de cada una de las columnas de la matriz BW.

Fuente: elaboración propia.

El tamaño de cada uno de los vectores es de $1 \times n$, donde n corresponde a la cantidad de canales (columnas) de la matriz de disponibilidad. El Algoritmo 10 presenta la estructura de programación implementada para obtener los criterios AP, ETA, ASINR y ABW.

Algoritmo 11. Estructura criterios AP, ETA, ASINR y ABW.

Criterios AP, ETA, ASINR y ABW
<pre>function [AP, ETA, ASINR, ABW] = Parameter_Ranking(Available, SINR, Bandwidth) i = Current Time Step j = Total channels % AP y ABW AP = mean(Available(i , :)); ABW = mean(Bandwidth(i , :)); for k = 1 : j % ASINR S = SINR(i , k); S(S==0) = []; ASINR(1 , k) = mean(S); % ETA Channel = Available(: , k); Ones_Channel_Total = sum(Channel); NumObjects = bwconncomp(Channel).NumObjects; ETA(1 , k) = Ones_Channel_Total/NumObjects; end</pre>

* bwconncomp: Busca componentes binarias conectadas.

Fuente: elaboración propia.

La variable de información de entrada de la función “*Parameter Ranking*” es “*Time Range*”, la cual parametriza el número de filas que se van a utilizar para determinar los criterios. El usuario establece si se quiere realizar para todas las filas de la matriz de disponibilidad o para un rango en específico.

4.7.2.2 *Ranking*

La función “*Ranking*” determina los canales con mayor probabilidad de oportunidad espectral, toma los vectores de los criterios AP, ETA, ASINR y ABW, y los multiplica por el vector “*Weights*” (puntuación) que se le asigna a cada uno de estos criterios. La ecuación (4.1) presenta la operación matricial realizada para determinar la variable de salida “*Ranking*”, [Weights] es la puntuación asignada a cada criterio y [P] la matriz de criterios por cada canal.

$$Ranking = [Weights]_{1 \times 4} \times [P]_{4 \times n}$$

$$[Weights]_{1 \times 4} = [W_{AP} \quad W_{ETA} \quad W_{ASINR} \quad W_{ABW}]^T$$

$$[P]_{4 \times n} = \begin{bmatrix} AP_{1,1} & \dots & \dots & AP_{1,n} \\ ETA_{2,1} & \dots & \dots & ETA_{2,n} \\ ASINR_{3,1} & \dots & \dots & ASINR_{3,n} \\ ABW_{4,1} & \dots & \dots & ABW_{4,n} \end{bmatrix} \quad (4.1)$$

La asignación de los pesos para la construcción del vector [Weights] se realiza de acuerdo con la técnica multicriterio que se requiera utilizar, las técnicas corresponden a los diferentes algoritmos de “*Handoff Models*”, cada uno programado conforme el estado de arte realizado. En total, se cuenta con nueve técnicas de toma de decisión multicriterio (figura 4.31).

Cada uno de los “*Handoff Models*” requiere la asignación de un vector fila de pesos de tamaño 1x4 (figura 4.31), los pesos pueden ser ajustados por el usuario, excepto el modelo *Random* que genera de manera aleatoria el vector de pesos, el simulador tiene la posibilidad de cargar pesos por defecto si el usuario lo requiere.

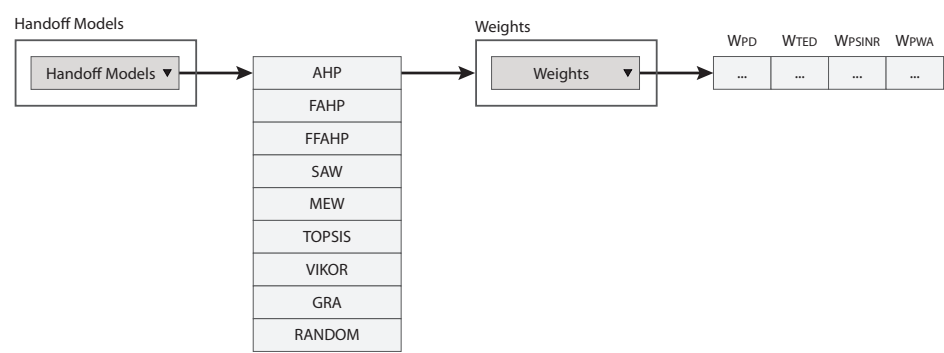


Figura 4.31. Algoritmos multicriterio “*Handoff Models*”.

Fuente: elaboración propia.

El Algoritmo 12 presenta la estructura de programación implementada para obtener “*Ranking*”. Es importante aclarar que la descripción es general, cada técnica multicriterio tiene su propia estructura de programación para obtener el vector final “*Ranking*”; sin embargo, los nueve algoritmos multicriterio “*Handoff Models*” requieren como parámetro de entrada los criterios y pesos.

Algoritmo 12. Estructura *Ranking*.

```
Ranking  
  
function [Ranking] = Ranking(AP, ETA, ASINR, ABW, Multicriteria)  
Weights = [W_AP W_ETA W_ASINR W_ABW];  
Average = [AP ; ETA ; ASINR ; ABW];  
    If Multicriteria == 'Handoff Models'  
        % Multicriteria Algorithm  
        Ranking = W*Average;  
    end  
end
```

Fuente: elaboración propia.

4.7.3 Algoritmo de búsqueda

Es el encargado del análisis de movilidad espectral. Según el vector de posiciones entregado por el algoritmo “*Ranking*”, realiza saltos de columna en la matriz de disponibilidad hasta encontrar un canal disponible; al encontrarlo hace un cambio de fila en la matriz de disponibilidad —cada fila representa un instante de tiempo y la condición de parada del algoritmo

de búsqueda—. La condición de parada es ajustada en el parámetro “*Time [minutes]*” de la interfaz, correspondiente a la variable de salida “*Simulation Time*” de “*Parameters Module*”, es decir, el algoritmo de búsqueda realizará saltos de fila hasta completar el tiempo establecido. Los saltos de columna y fila, el tiempo y la disponibilidad son almacenados en un vector y retroalimentados al finalizar la simulación en una base de datos.

Adicional a la condición de parada “*Simulation Time*” el algoritmo tiene una variable de entrada llamada “*Criteria Time*” la cual establece el criterio de tiempo para el análisis de movilidad espectral de acuerdo con el vector “*Ranking*”, determinado con la matriz de entrenamiento. Cuando el algoritmo de búsqueda se encuentre en el instante de tiempo $t = \text{criteria time}$, se calculará un nuevo vector “*Ranking*”, pero en este caso con la matriz de evaluación y para un número definido de filas de la matriz de disponibilidad, SINR y BW. 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 tanto, si $\text{Simulation Time} > n * \text{Criteria Time}$, el vector de posiciones se actualizará n veces.

El Algoritmo 13 presenta la estructura de programación implementada para el algoritmo de búsqueda de un solo usuario sin ajuste por “*Criteria Time*”. La figura 4.32, el flujo de datos de entrada y salida para el algoritmo de búsqueda.

Algoritmo 13. Estructura algoritmo de búsqueda para un solo usuario.

Algoritmo de búsqueda para un solo usuario

```

r = Simulation_Time;
i = 1; j = 1; Handoffs = 0; Blokings = 0; time = 0;
while i <= Simulation_Time
    Availability = Available(i , Ranking(j));
    time = time + 1;
    switch Availability
    case 0
        Free(1 , time) = Available(i , RankingF(j));
        AB(1 , time) = BW(i , RankingF(j));
        F_used(2 , time) = Handoffs;
        j = j + 1; % Cambia de canal
        Handoffs = Handoffs + 1;
        if Available(i , Ranking(j-1))==0 && Available(i
        , Ranking(j))==0
            Blokings = Blokings + 1;
            F_busy(2 , time+1) = Blokings;
        else
            F_busy(2 , time+1) = Blokings;
        end
    case 1
        Free(1 , time) = Available(i , Ranking(j));
        AB(1 , time) = BW(i , Ranking(j));
        F_used(2,time) = Handoffs;
        i = i + 1; % Cambia de fila
        if Available(i-1 , Ranking(j))==1 &&
        Available(i,Ranking(1))==0
            Blokings = Blokings+1;
            F_busy(2 , time+1) = Blokings;
        else
            F_busy(2 , time+1) = Blokings;
        end
    end
end
Used_Frecuency = F_used;
Busy_Frecuency = F_busy;
Bandwidth Frequency Used = AB;

```

Fuente: elaboración propia.

4.7.3.1 Algoritmo de búsqueda multiusuario

El algoritmo incorpora el análisis de saltos espectrales para varios usuarios seriales, para la caracterización de la búsqueda. El proceso es equivalente tanto para un usuario con un canal como para múltiples usuarios con múltiples canales; la diferencia más relevante se presenta en el cambio de fila, la cual, para múltiples usuarios, solo se realiza cuando todos los usuarios encuentran oportunidades espectrales, o cuando los requerimientos de canales son superiores a la disponibilidad.

Para la búsqueda multiusuario el algoritmo puede encontrar dos escenarios: el primero es donde todos los usuarios encuentran oportunidades espectrales para todos los requerimientos de canales y, el segundo, donde las oportunidades espectrales son menores a los requerimientos de los múltiples usuarios; para este último caso, el algoritmo informa sobre el evento y, posteriormente, salta al final para iniciar nuevamente la búsqueda en el siguiente instante de tiempo. La figura 4.34 presenta el flujo de variables de entrada y salida para el algoritmo de búsqueda multiusuario.

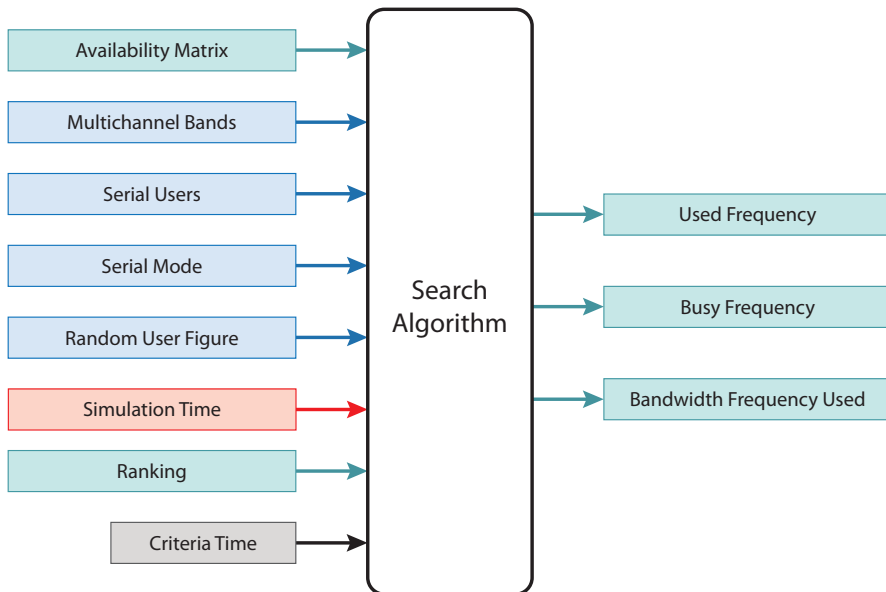


Figura 4.32. Algoritmo de búsqueda para el análisis de movilidad espectral.

Fuente: elaboración propia.

4.7.4 Algoritmos indicadores de predicción

El algoritmo compara la precisión de la predicción de canales durante un tiempo de transmisión y evalúa si las predicciones de disponibilidad pueden conducir a un uso beneficioso de los canales. Los modelos utilizados para la predicción de canales generan una nueva matriz basada en probabilidad, donde los estados del canal están definidos por “1” (disponible) y “0” (ocupado). Estas probabilidades son asignadas a una matriz llamada “*Prediction Availability Matrix*”; la predicción de disponibilidad se realiza por canal durante un tiempo definido de simulación.

La figura 4.33 exhibe el flujo de variables de entrada y salida de la función. Es importante resaltar que el algoritmo de búsqueda descrito en la sección 4.7.3 hace parte del algoritmo indicadores de predicción, la diferencia radica en una entrada y salida adicional; la entrada corresponde a “*Prediction Availability Matrix*”, obtenida a través de las predicciones de disponibilidad, la cual es comparada con “*Evaluation Availability Matrix*” para obtener las métricas de precisión. Los resultados de la comparación equivalen a la variable de salida “*Prediction*”.

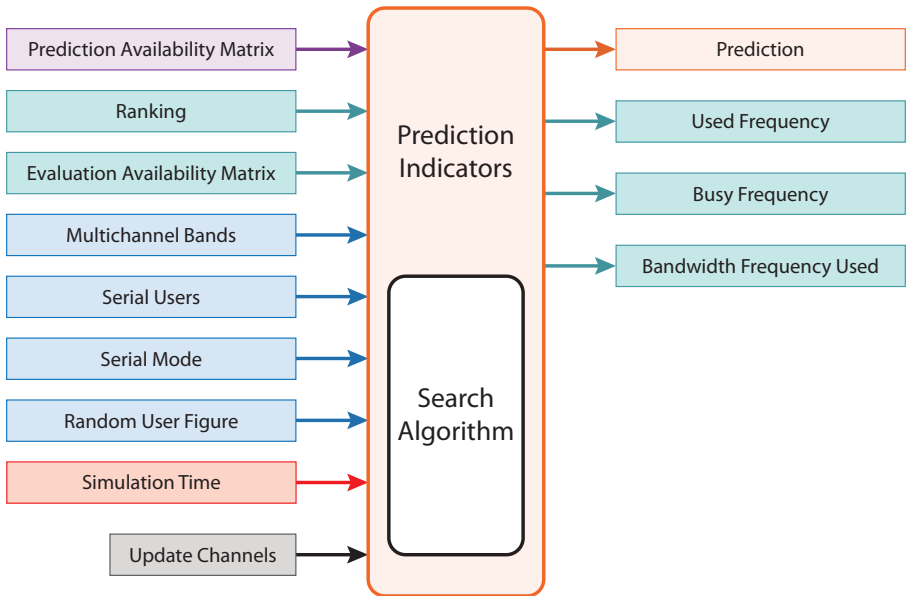


Figura 4.33. Algoritmo indicadores de predicción.

Fuente: elaboración propia.

4.7.4.1 Algoritmo métricas de desempeño

La evaluación de los *handoffs* espectrales se realiza a través de la matriz de entrenamiento y validación. Para el análisis de los resultados el simulador exporta la información a través de una base de datos y un conjunto de figuras. La figura 4.34 presenta el flujo de datos de entrada y salida para el algoritmo asociado a las métricas de desempeño. Se requieren cinco variables de entrada: tres son tomadas del algoritmo de búsqueda; la ruta donde se almacenarán los resultados es tomada del módulo “*Project Information*” y finalmente una variable de información.

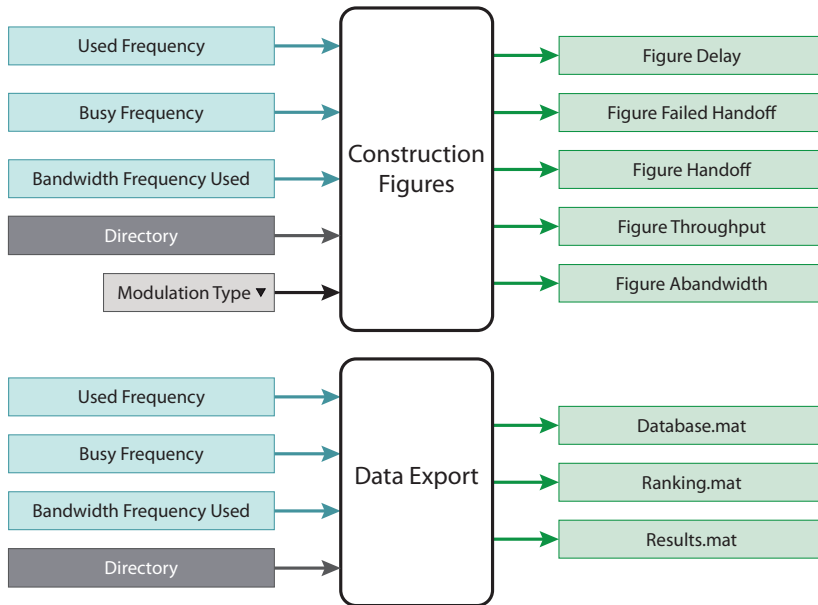


Figura 4.34. Algoritmo métricas de desempeño.

Fuente: elaboración propia.

La base de datos contiene la información de la matriz de potencia, la matriz de disponibilidad, las métricas del algoritmo de búsqueda: canales, saltos de fila, tiempo, disponibilidad y BW. Finalmente, las métricas del algoritmo *ranking* y puntuaciones asignadas durante la simulación. En la tabla 4.22 se muestran los archivos exportados y el tipo de respectivo formato.

Tabla 4.22. Tipo de formato.

Archivo	Descripción	Formato del archivo
<i>Results</i>	Métricas de desempeño del algoritmo del <i>ranking</i> .	Documento en Matlab .mat
<i>Ranking</i>	Métricas de desempeño del algoritmo del <i>ranking</i> .	Documento en Matlab .mat
<i>Database</i>	Matriz de potencia y matriz de disponibilidad utilizadas para el entrenamiento y la validación.	Documento en Matlab .mat

Fuente: elaboración propia.

El simulador genera cinco figuras, en dos formatos diferentes: .png y .fig (editable en Matlab). Tanto las figuras (.png, .fig) como los archivos exportados (.mat) se guardan en la ruta seleccionada por el usuario (“*Directory*” del “*Project Information*”).

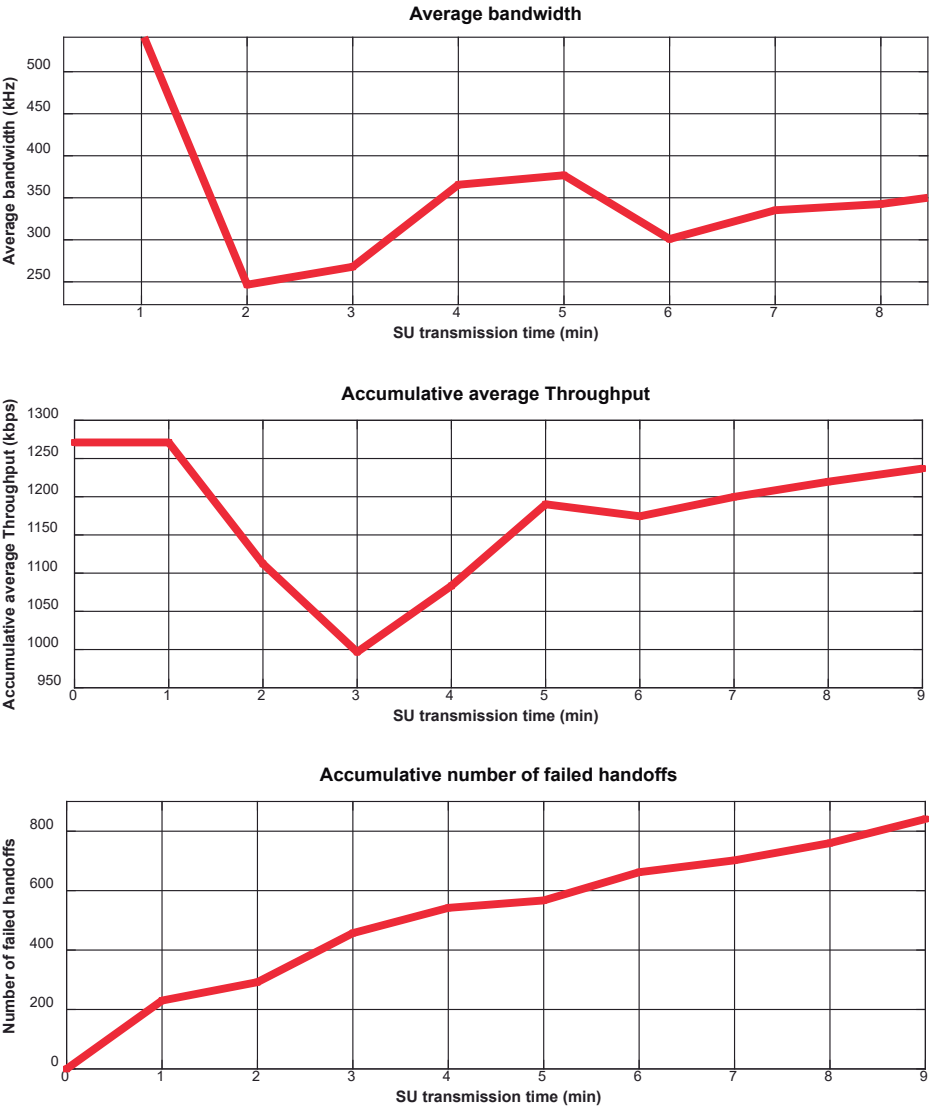
Los resultados corresponden a las figuras AAD, AAFH, AAH, AAT y ABW la tabla 4.23 presenta la descripción de las métricas de desempeño.

Tabla 4.23. Métricas de desempeño multicriterio.

Sigla	Nombre	Descripción
AAH	Número de <i>handoff</i> promedio acumulado	Número total de <i>handoff</i> realizados durante el tiempo de transmisión del SU.
AAFH	Número de <i>handoff</i> fallidos promedio acumulado	Número de <i>handoff</i> que el SU no pudo materializar porque encontró las respectivas oportunidades espectrales objetivo ocupadas.
ABW	Ancho de banda promedio	Es el BW promedio utilizado por el SU durante el tiempo de transmisión del SU.
AAD	Retardo promedio acumulado	Tiempo promedio total experimentado por el SU durante la transmisión de una determinada cantidad de información.
AAT	<i>Throughput</i> promedio acumulado	Tasa de datos efectiva transmitida por el SU durante el tiempo de transmisión del SU.

Fuente: elaboración propia.

La figura 4.35 muestra un ejemplo de resultados obtenidos por el algoritmo asociado a las métricas de desempeño.






Figura 4.35. Ejemplo figuras algoritmo métricas de desempeño.

Fuente: elaboración propia.

4.7.4.2 Algoritmo métricas de predicción

Como se describió en la sección 4.7.4.1, la evaluación *handoffs* espectrales se realiza a través de la matriz de entrenamiento y validación, los resultados corresponden a las figuras de AAD, AAFH, AAH, AAT y ABW. Los modelos utilizados para la predicción de canales cuentan con métricas adicionales asociadas a la calidad de las predicciones realizadas, como se muestra en la figura 4.36 las métricas son: “*Figure Anticipated*”, “*Figure Interference*”, “*Figure Perfect*”.




Figura 4.36. Algoritmo métricas de predicción.
Fuente: elaboración propia.

Los resultados corresponden a las figuras de *handoffs* acumulado; con interferencia, perfectos y anticipados, la tabla 4.24 presenta la descripción de las métricas de desempeño para las técnicas de predicción.

Tabla 4.24. Métricas de desempeño modelos de predicción.

Sigla	Nombre	Descripción
AAIH	Número de <i>handoff</i> con interferencia promedio acumulado	Número total de <i>handoff</i> reactivos realizados una vez llega el PU, durante el tiempo de transmisión del SU.
AAPH	Número de <i>handoff</i> perfecto promedio acumulado	Número de <i>handoff</i> sin interferencia realizados muy cerca de la llegada del PU, pero sin causar interferencia a este último, durante el tiempo de transmisión del SU.
AAUH	Número de <i>handoff</i> anticipado promedio acumulado	Número de <i>handoff</i> sin interferencia realizados de forma muy anticipada a la llegada del PU, durante el tiempo de transmisión del SU.

Fuente: elaboración propia.

La figura 4.37 muestra un ejemplo de resultados por el algoritmo asociado a las métricas de desempeño.




Figura 4.37. Ejemplo figuras algoritmo métricas de predicción.

Fuente: elaboración propia.

4.8 No Predicton Module

La figura 4.38 presenta en detalle las variables de entrada y salida para el “No Prediction Module”.

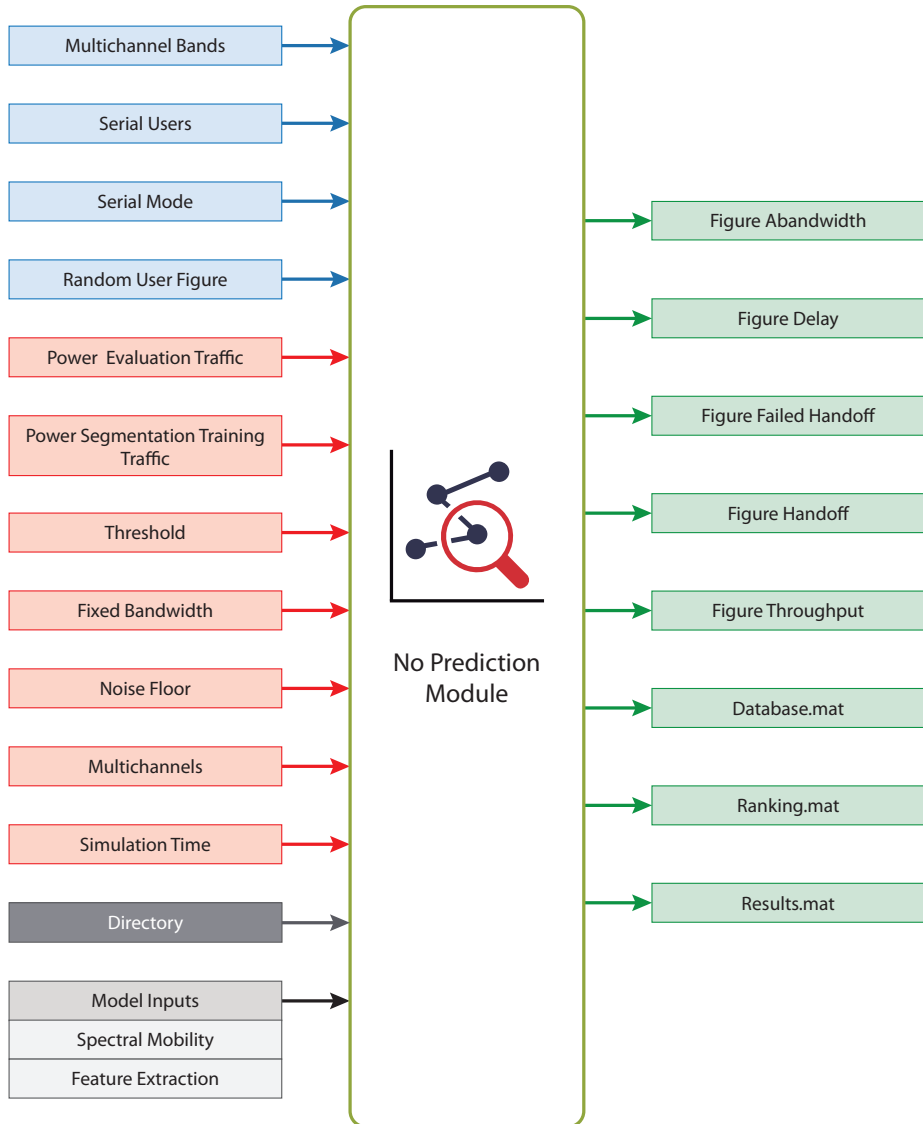


Figura 4.38. Descripción variables de entrada y salida “No Prediction Module”.

Fuente: elaboración propia.

4.8.1 Movilidad espectral (No predicción)

La movilidad espectral es una función del ciclo cognitivo asociada al cambio de canal del SU cuando las condiciones del mismo se degradan o un PU aparece, también conocido como *handoff* espectral. Es un aspecto clave en el desempeño de las comunicaciones del SU en las redes de radio cognitiva, y la decisión espectral juega un papel muy importante para mejorar dicho desempeño. Las técnicas de decisión espectral establecen mediante un conjunto de reglas, cuando y donde realizar un *handoff* espectral. A continuación, se describe el modelo propuesto, las variables de entrada y funciones, el diagrama de bloques del modelo y las métricas utilizadas.

4.8.1.1 Modelo propuesto

El análisis de movilidad espectral se realiza implementando en cascada los algoritmos: “*Initial Parameter*”, “*Parameter Ranking*”, “*Ranking*”, “*Search Algorithm*”, “*Construction Figures*” y “*Data Export*”. La figura 4.39 presenta el diagrama de bloques del modelo propuesto.

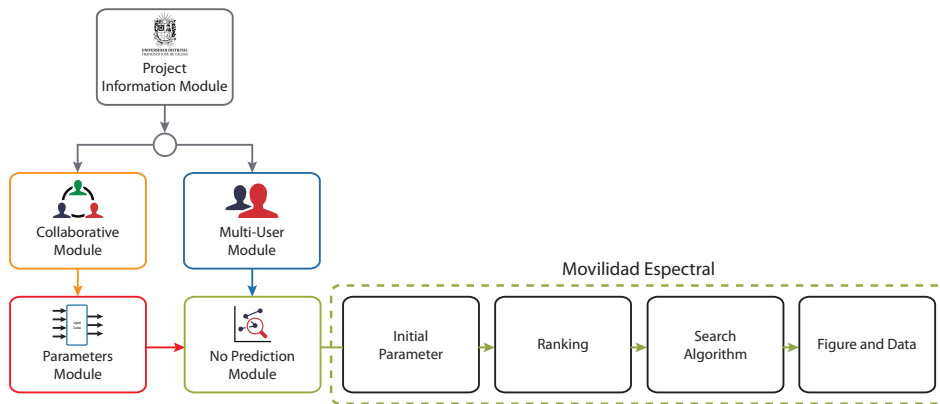


Figura 4.39. Modelo propuesto Movilidad espectral.

Fuente: elaboración propia.

4.8.1.2 Descripciones variables de entrada y funciones

La figura 4.40 fue elaborada con el objetivo de describir específicamente el control que tiene el usuario sobre las variables del modelo; presenta en detalle las funciones y variables de información de entrada (no contempla

las variables de entrada asociadas a las salidas de los módulos —esta descripción se detalla en la figura 4.38 y en el diagrama de bloques de la figura 4.40—).

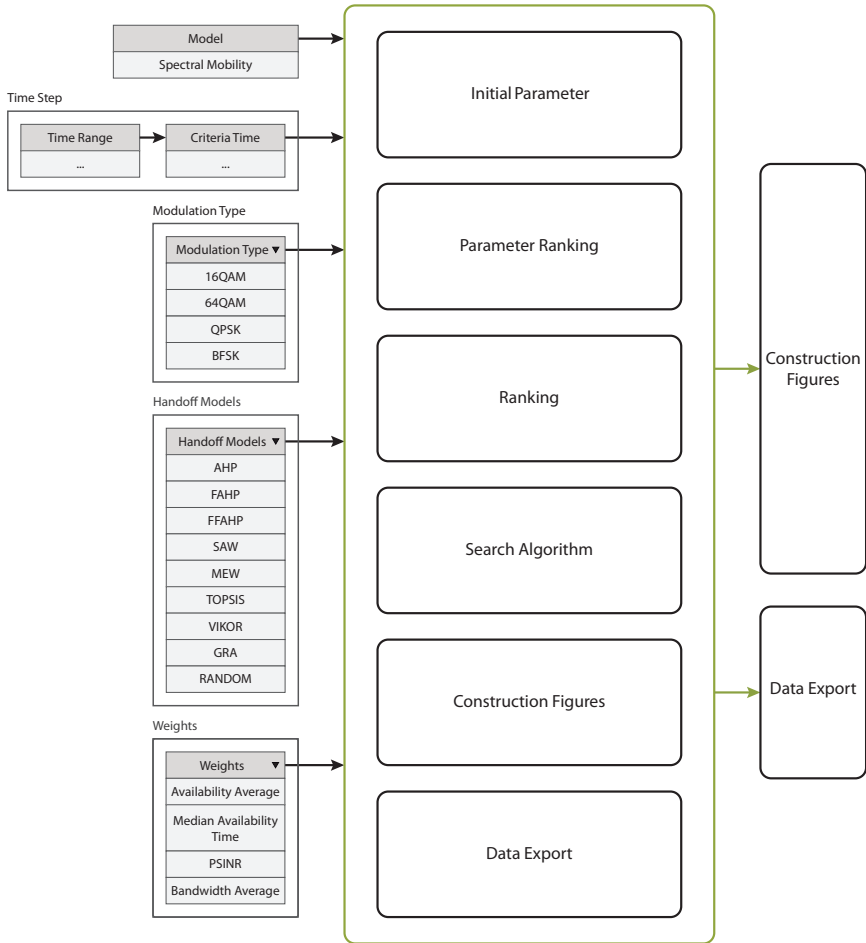


Figura 4.40. Descripción variables de entrada y salida modelo de Movilidad espectral.

Fuente: elaboración propia.

4.8.1.3 Diagrama de bloques

La figura 4.41 presenta el diagrama de bloques del modelo de movilidad espectral, el cual permite identificar el flujo de datos de las funciones y la información tomada de los respectivos módulos. Cada uno de los colores se ajusta a la convención descrita en la figura 4.3.

4.8.1.4 Evaluación modelo movilidad espectral

Para la evaluación del modelo se utiliza el algoritmo métricas de desempeño para obtener las figuras de AAD, AAFH, AAH, AAT y ABW.

4.8.2 *Feature Extraction*

El *Deep Learning* es un método que emula el aprendizaje humano; sus modelos utilizan grandes volúmenes de información para extraer características directamente de los datos. La mayoría de los métodos de *Deep Learning* utilizan redes neuronales. Una de las formas de aplicar una red profunda para la clasificación de objetos es la extracción de características, donde, las capas de las redes neuronales profundas aprenden ciertas características de las imágenes, las cuales se pueden extraer en cualquier momento. Estas características se pueden utilizar para el entrenamiento de clasificadores basados en estrategia de *machine learning* como las SVM.

4.8.2.1 Modelo propuesto

El modelo consiste en implementar la red AlexNet para la selección de características. El objetivo es utilizar una red neuronal convolucional para extraer de una de sus capas un conjunto acertado de rasgos, y posteriormente, a través de estos entrenar una máquina de soporte vectorial que permita desarrollar un proceso de clasificación. La figura 4.42 presenta el diagrama de bloques del modelo propuesto.

4.8.2.2 Descripciones variables de entrada y funciones

La figura 4.43 fue elaborada con el objetivo de describir específicamente el control que tiene el usuario sobre las variables del modelo. Presenta en detalle las funciones y variables de información de entrada, no contempla las variables de entrada asociadas a las salidas de los módulos; esta descripción se realiza en detalle en la figura 4.38 y en el diagrama de bloques de la figura 4.44.

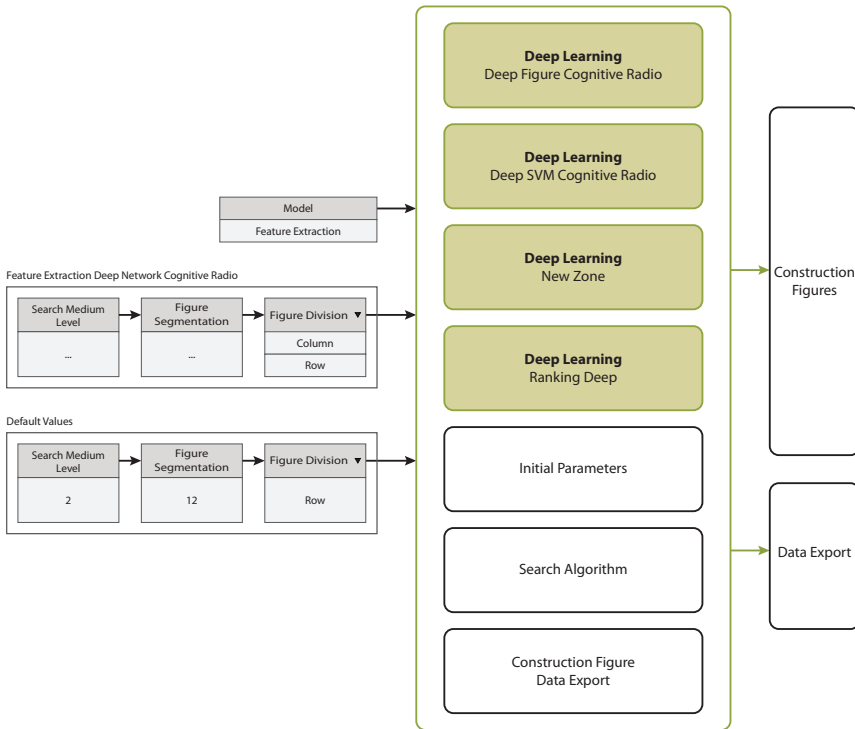


Figura 4.43. Descripción variables de entrada y salida modelo *Feature Extraction*.

Fuente: elaboración propia

4.8.2.3 Diagrama de bloques

En la figura 4.44 se presenta el diagrama de bloques del modelo de extracción de características, permite identificar el flujo de datos de las funciones y la información tomada de los respectivos módulos; cada uno de los colores se ajusta a la convención descrita en la figura 4.3.

4.8.2.4 Evaluación modelo movilidad espectral

Para la evaluación del modelo se utiliza el algoritmo métricas de desempeño para obtener las figuras de AAD, AAFH, AAH, AAT y ABW.

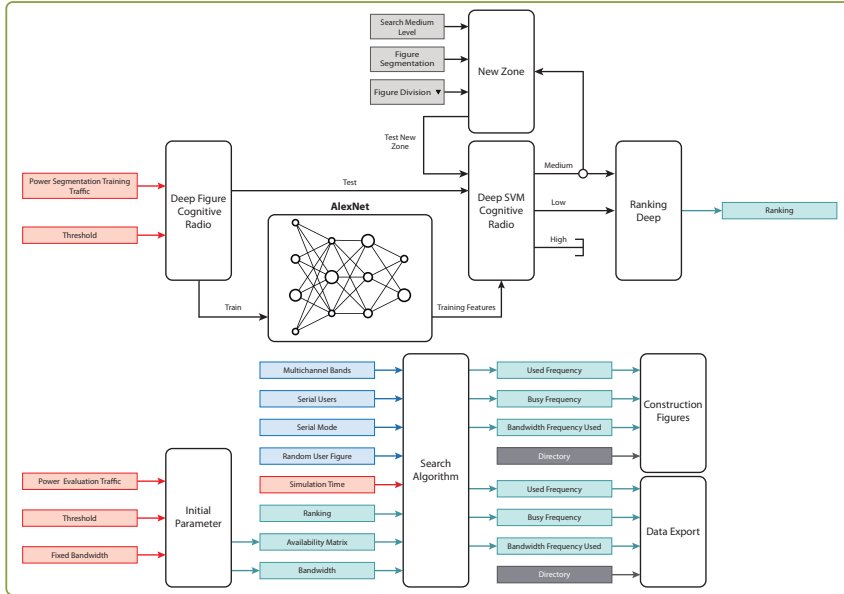


Figura 4.44. Diagrama de bloques modelo no predictivo técnica *Feature Extraction*.

Fuente: elaboración propia.

4.9 Prediction Module

La figura 4.45 presenta en detalle las variables de entrada y salida para el "No Prediction Module".

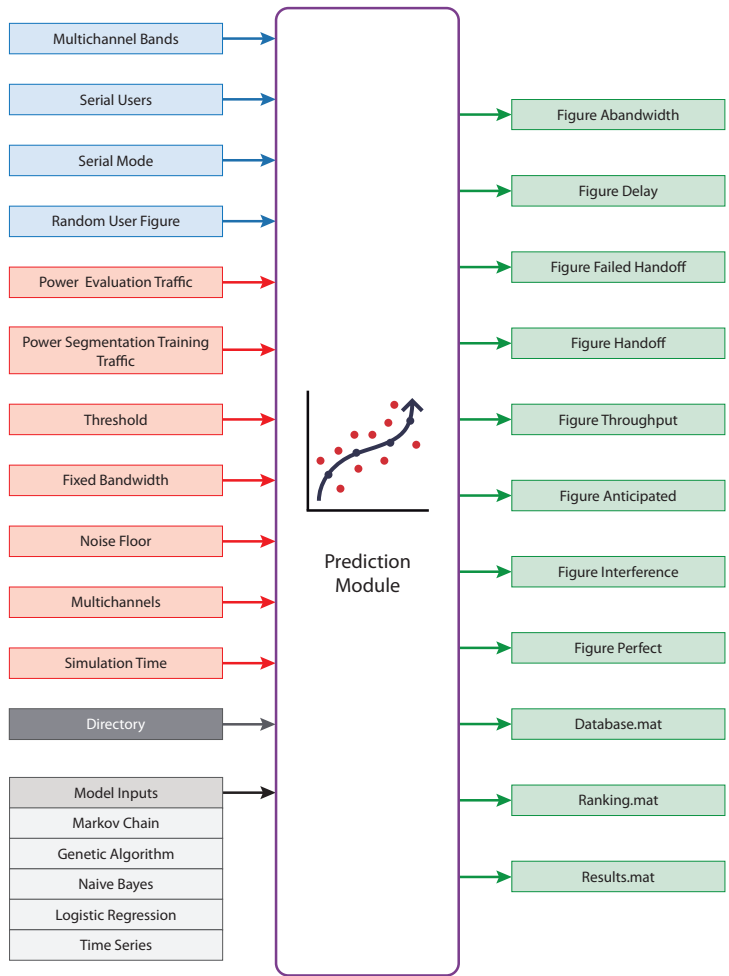


Figura 4.45. Descripción variables de entrada y salida “*Prediction Module*”.

Fuente: elaboración propia.

4.9.1 Markov Chain

Las cadenas de Markov son una técnica estocástica basada en el análisis de la dinámica interna del sistema que simula la predicción del estado actual en un tiempo determinado a partir de los estados anteriores. Es un proceso aleatorio 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 $u < t$.

4.9.1.1 Modelo propuesto

El modelo elaborado para la evaluación de *handoff* espectral utilizando cadenas de Markov está dividido en cinco etapas, la figura 4.46 presenta el diagrama de bloques del modelo propuesto. La primera etapa corresponde a los módulos “*Project Information*”, “*Collaborative Module*”, “*Multi-User Module*” y “*Parameters Module*”; en la segunda se realiza una selección de canales para la matriz de entrada con dos algoritmos de selección, el objetivo es reducir los canales de estudio para mejorar los tiempos de simulación; 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.

Selección de canales

A través de “*Channel Selection*” se escogen 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 cuales canales seleccionar; a través de “*Ranking Markov*” se realiza la selección, se utilizan dos técnicas: “*Handoff Models*” y un modelo aleatorio “*Random*”.

Matriz de transición

El objetivo es determinar la matriz de probabilidades de transición, determinando las probabilidades de estado actual y futuro que son necesarias para la implementación de las cadenas, luego son utilizadas en la matriz de validación para cuantificar los *handoffs* espectrales. Markov establece como requerimiento conocer el estado actual y futuro del sistema, se define un estado futuro como: $time\ steps + 1$.

La técnica utilizada para los estados actuales está orientada a modelar cada *time steps* 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, 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, se determinan los estados de mayor y menor ocurrencia evaluando todos los canales del *time steps* futuro, posteriormente, se normalizan los resultados.

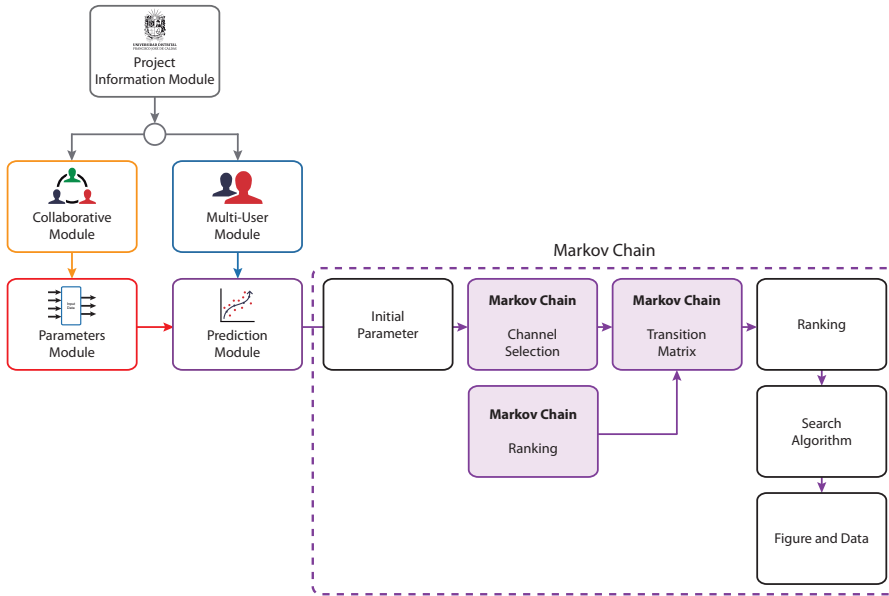


Figura 4.46. Modelo propuesto Markov Chain.

Fuente: elaboración propia.

4.9.1.2 Descripciones variables de entrada y funciones

La figura 4.47 fue elaborada con el objetivo de describir específicamente el control que tiene el usuario sobre las variables del modelo. Presenta en detalle las funciones y variables de información de entrada, no contempla las variables de entrada asociadas a las salidas de los módulos, esta descripción se realiza detalladamente en la figura 4.45 y en el diagrama de bloques de la figura 4.48.

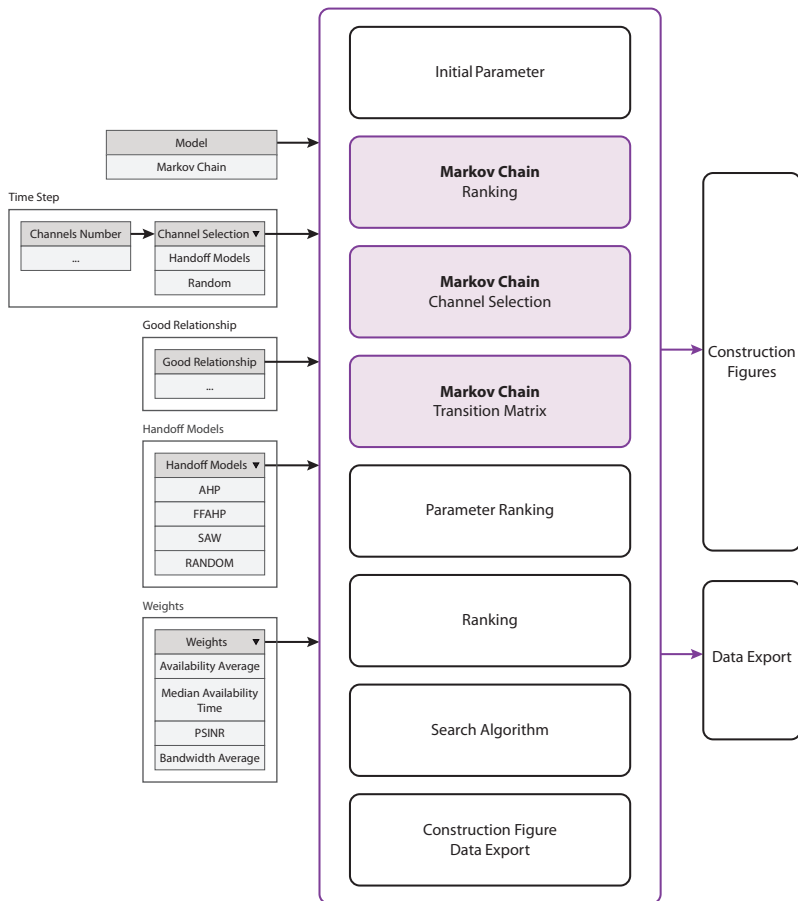


Figura 4.47. Descripción variables de entrada y salida modelo Markov Chain.

Fuente: elaboración propia.

4.9.1.3 Diagrama de bloques

En la figura 4.48 se presenta el diagrama de bloques del modelo de extracción de características que permite identificar el flujo de datos de las funciones y la información tomada de los respectivos módulos, cada uno de los colores se ajusta a la convención descrita en la figura 4.3.

4.9.1.4 Evaluación modelo movilidad espectral

Se analizan los *handoffs* espectrales evaluando las probabilidades de transición sobre la matriz de validación; para la evaluación del modelo se utiliza el

algoritmo métricas de desempeño para obtener las figuras de AAD, AAFH, AAH, AAT y ABW. Adicionalmente, se vincula a la base de datos de salida indicadores asociados a las predicciones —exactas, buenas, regulares y malas—. En la tabla 4.25 se presenta la descripción de estos indicadores.

Tabla 4.25. Indicadores de predicción *Markov Chain*.

Indicadores	Descripción
Predicción exacta	Condición donde la predicción del futuro es 100 % acertada.
Predicción buena	Condición donde la predicción del futuro tiene un acierto mayor al 70 % y menor al 100 %.
Predicción regular	Condición donde la predicción del futuro tiene un acierto mayor al 30 % y menor al 70 %.
Predicción mala	Condición donde la predicción del futuro tiene un acierto menor al 30 %.

Fuente: elaboración propia.

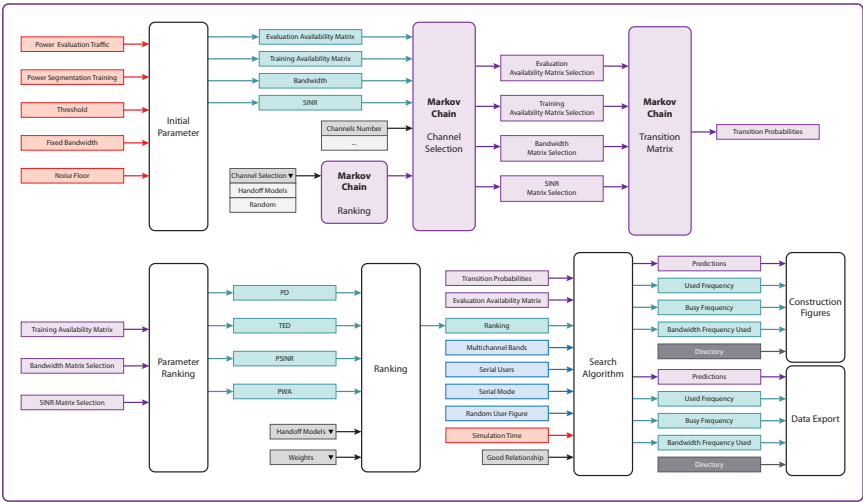


Figura 4.48. Diagrama de bloques modelo no predictivo técnica *Markov Chain*.

Fuente: elaboración propia.

4.9.2 Algoritmos genéticos

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: la representación binaria se llama cromosoma y cada bit dentro de este se denomina gen. Un algoritmo genético se caracteriza a través de cinco definiciones o equivalentes genéticos descritos en la tabla 4.26 (para una población específica se muestra en la figura 4.49).

Tabla 4.26. Equivalentes genéticos.

Parámetro genético	Descripción
Alelo	Cada uno de los estados distintos que puede presentar un gen en una misma posición.
Gen	Valor de un alelo dentro de un arreglo.
Cromosoma	Colección de genes en forma de arreglo.
Posición	Lugar que ocupa un gen dentro del cromosoma.
Índice	Posición que tiene el individuo dentro de la población.

Fuente: elaboración propia.




Figura 4.49. Equivalentes genéticos población específica.

Fuente: elaboración propia.

4.9.2.1 Modelo propuesto

El modelo 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) es una variable que se parametriza con criterio de prueba y error y se ajusta bajo parámetros de rendimiento como tiempos de simulación.

El modelo está dividido en cinco etapas, la figura 4.50 presenta el diagrama de bloques del modelo propuesto. La primera etapa corresponde a los módulos “*Project Information*”, “*Collaborative Module*”, “*Multi-User Module*” y “*Parameters Module*”; en la segunda se realiza una selección de canales para la matriz de entrada con dos algoritmos de selección, el objetivo es reducir los canales de estudio para mejorar los tiempos de simulación. En la tercera etapa —a partir de las operaciones selección directa, cruce y mutación (tasas de mutación pequeñas)— se genera una población final equivalente a la matriz de entrenamiento; en la cuarta se evalúa la matriz de transición. Finalmente, en la quinta, se procesan los resultados de la evaluación y se muestran de forma gráfica los indicadores relevantes.

Selección de canales

A través de “*Channel Selection*” se escogen 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 como y cuales canales seleccionar; a través de “*Ranking Genetic*” se elige entre dos técnicas: “*Handoff Models*” y un modelo aleatorio “*Random*”.

Matriz de entrenamiento

Para la matriz de entrenamiento se diseña un algoritmo genético. El modelo 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 4.50 presenta el diagrama de flujo del algoritmo genético.

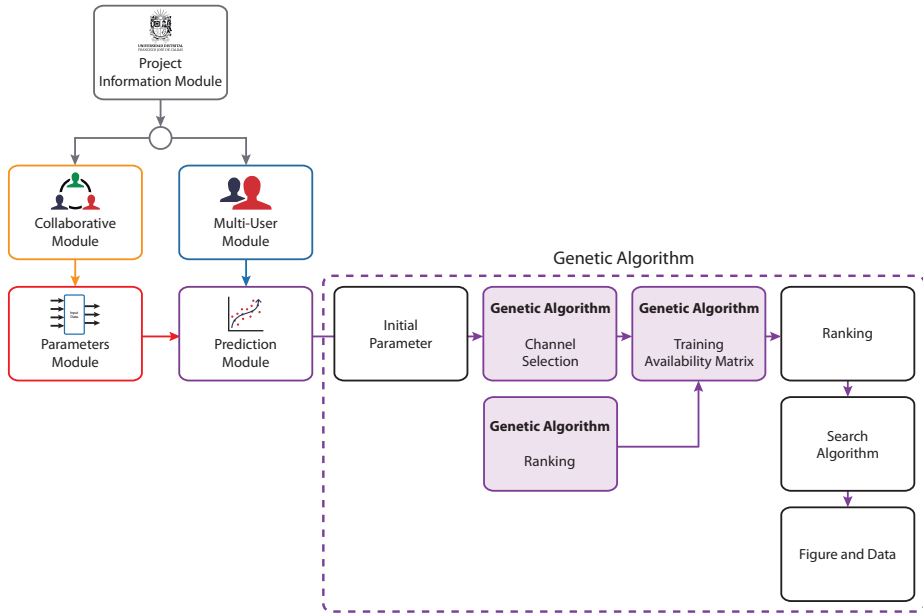


Figura 4.50. Modelo propuesto *Genetic Algorithm*.

Fuente: elaboración propia.

4.9.2.2 Descripciones variables de entrada y funciones

La figura 4.51 fue elaborada con el objetivo de describir específicamente el control que tiene el usuario sobre las variables del modelo. Presenta en detalle las funciones y variables de información de entrada; no contempla las variables de entrada asociadas a las salidas de los módulos —esta descripción se realiza en detalle en la figura 4.45 y en el diagrama de bloques de la figura 4.52.

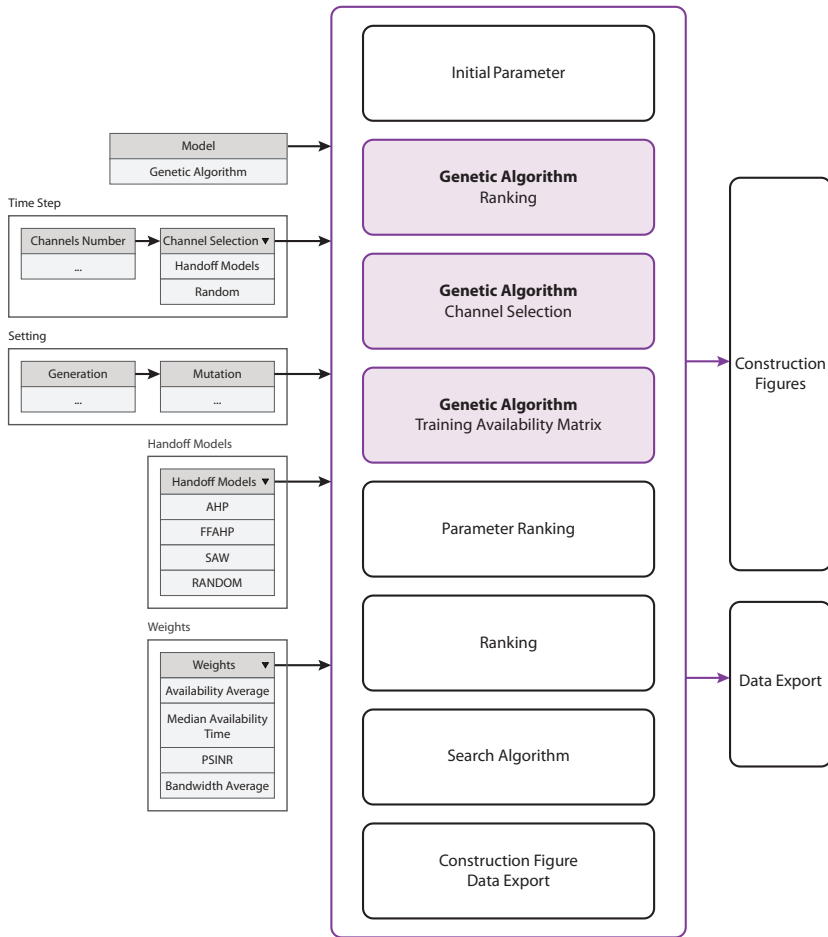


Figura 4.51. Descripción variables de entrada y salida *Genetic Algorithm*.

Fuente: elaboración propia.

4.9.2.3 Diagrama de bloques

La figura 4.52 presenta el diagrama de bloques del modelo de extracción de características, permite identificar el flujo de datos de las funciones y la información tomada de los respectivos módulos, cada uno de los colores se ajusta a la convención descrita en la figura 4.3.

4.9.2.4 Evaluación modelo movilidad espectral

Se utiliza el algoritmo métricas de desempeño para obtener las figuras de AAD, AAFH, AAH, AAT y ABW. Aunque no forma parte de la evaluación, entrega información del algoritmo genético: número de generaciones, población inicial, porcentaje de mutación, entre otras.

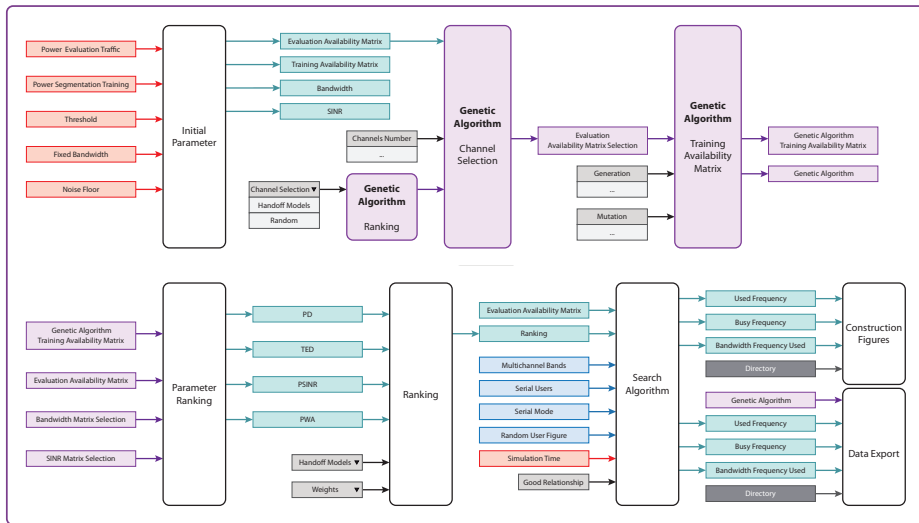


Figura 4.52. Diagrama de bloques modelo no predictivo técnica *Genetic Algorithm*.

Fuente: elaboración propia.

4.9.3 Naive Bayes

Modelo que depende de la interacción de diferentes nodos para, así, generar aprendizaje en cada nodo involucrado en el proceso. El enfoque bayesiano es una técnica de aprendizaje probabilístico; provee exactas inferencias y estima modelos de probabilidad completa, donde el conocimiento *a priori* o los resultados son usados para construir un modelo actualizado.

Una de las principales consideraciones para la selección de modelos de predicción es que se tienen múltiples características o criterios que pueden mejorar el pronóstico. Una estructura basada en *Naive Bayes* 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.

4.9.3.1 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 serie dicotómicas donde “0” representa ocupación del canal y “1”, disponibilidad de canal. Con este procesamiento de información se entrena el algoritmo *Naive Bayes*.

El modelo está dividido en cuatro etapas, la figura 4.53 presenta el diagrama de bloques del modelo propuesto. La primera etapa corresponde a los módulos “*Project Information*”, “*Collaborative Module*”, “*Multi-User Module*” y “*Parameters Module*”; la segunda consta de dos funciones: (1) “*Naive Bayes Algorithm*”, (2) “*Channel allocation prediction*”. Para calcular los parámetros de costo y gradiente que ajustan el predictor, la primera función utiliza como variables el vector ASINR, ETA y AP. La segunda función realiza una asignación de 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. La tercera etapa compara las matrices para determinar los indicadores de predicción. Finalmente, en la cuarta etapa se procesan los resultados de la evaluación y se muestran de forma gráfica los indicadores relevantes.

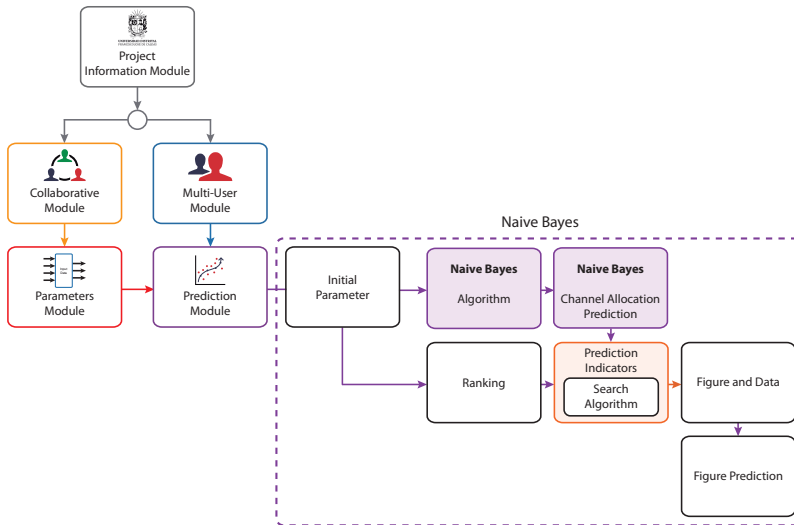


Figura 4.53. Modelo propuesto *Naive Bayes*.

Fuente: elaboración propia.

4.9.3.2 Descripciones variables de entrada y funciones

La figura 4.54 fue elaborada con el objetivo de describir específicamente el control que tiene el usuario sobre las variables del modelo. Presenta en detalle las funciones y variables de información de entrada —no contempla las variables de entrada asociadas a las salidas de los módulos, esta descripción se detalla en la figura 4.45 y el diagrama de bloques de la figura 4.55—.

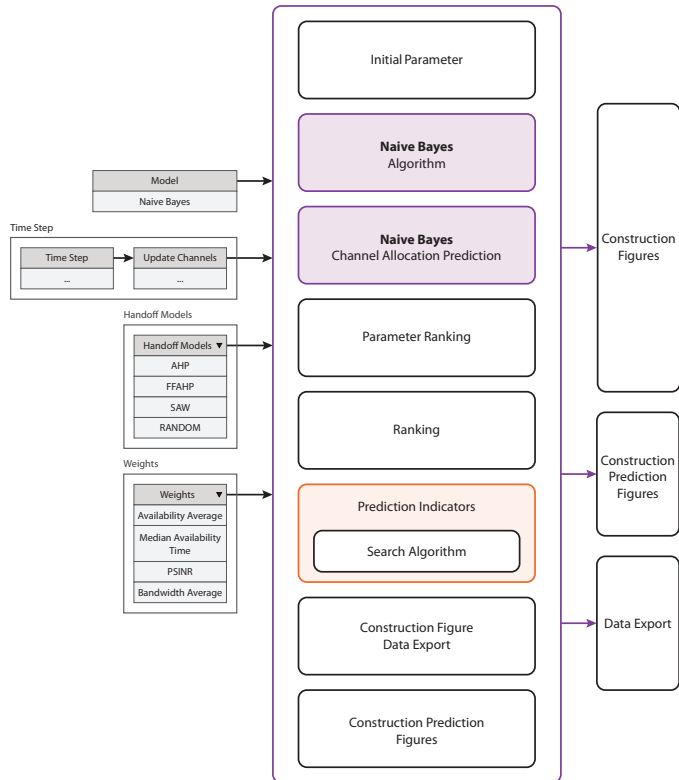


Figura 4.54. Descripción variables de entrada y salida modelo *Naive Bayes*.

Fuente: elaboración propia

4.9.3.3 Diagrama de bloques

La figura 4.55 presenta el diagrama de bloques del modelo de extracción de características, el cual permite identificar el flujo de datos de las funciones y la información tomada de los respectivos módulos, cada uno de los colores se ajusta a la convención descrita en la figura 4.3.

4.9.3.4 Evaluación modelo movilidad espectral

Para la evaluación del modelo, se utiliza el algoritmo métricas de desempeño para obtener las figuras de AAD, AAFH, AAH, AAT y ABW. Adicionalmente, por ser un modelo que predice una matriz de disponibilidad, se utiliza el algoritmo de métricas de predicción descrito en la sección 4.7.4.2. Por tanto, se incluyen las métricas AAIH, AAPH, AAUH.

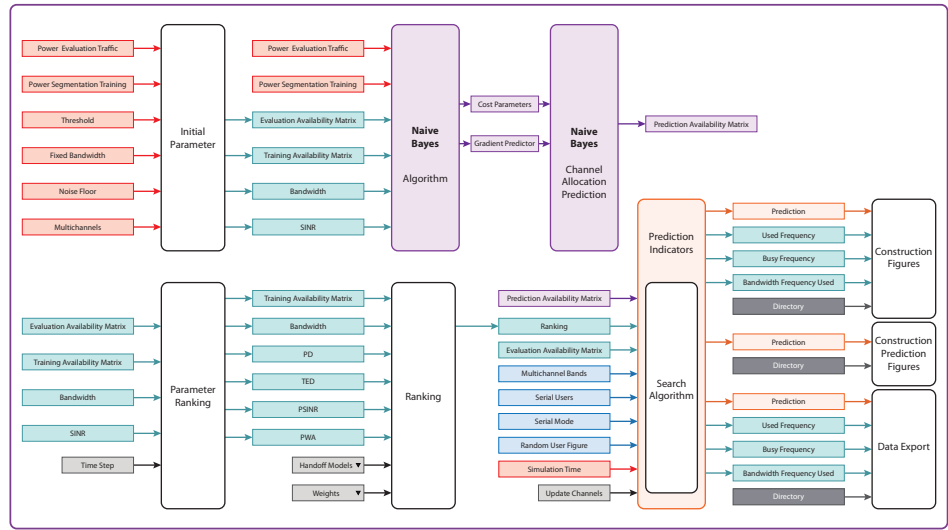


Figura 4.55. Diagrama de bloques modelo no predictivo, técnica *Naive Bayes*.

Fuente: elaboración propia.

4.9.4 Logistic Regression

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 estas sobre la variable respuesta. Si se examinan las variables explicativas de forma independiente, ignorando la covarianza entre las variables, se puede caer en confusión.

4.9.4.1 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, los datos pasan por el bloque de procesamiento

de información espectral, el cual los convierte en serie dicotómicas donde “0” representa ocupación del canal y “1” representa disponibilidad de canal. Con este procesamiento de información se entrena el algoritmo *Logistic Regression*.

El modelo está dividido en cuatro etapas, la figura 4.56 presenta el diagrama de bloques del modelo propuesto. La primera etapa corresponde a los módulos “*Project Information*”, “*Collaborative Module*”, “*Multi-User Module*” y “*Parameters Module*”; la segunda consta de dos funciones: (1) “*Logistic Regression Algorithm*”, (2) “*Channel Allocation Prediction*”. Para calcular los parámetros de costo y gradiente que ajusta el predictor, la primera función utiliza como variables el vector ASINR, ETA y AP. La segunda función realiza una asignación de la ocupación de canal mediante “1” y “0”, lo cual genera como variable de salida una matriz de predicción de disponibilidad de BW. En la tercera etapa se comparan las matrices para determinar los indicadores de predicción. Finalmente, en la cuarta, se procesan los resultados de la evaluación y se muestran de forma gráfica los indicadores relevantes.

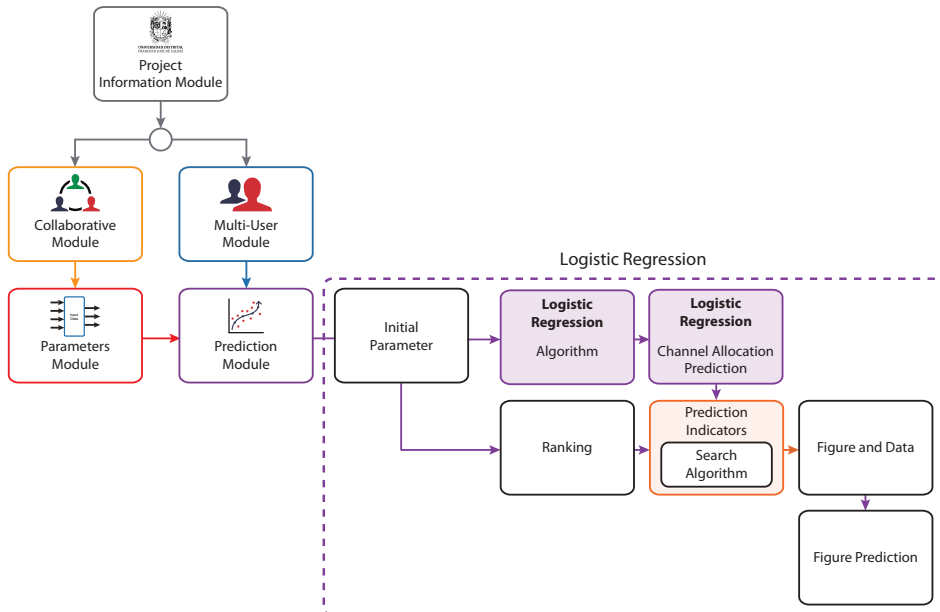


Figura 4.56. Modelo propuesto *Logistic Regression*.

Fuente: elaboración propia.

4.9.4.2 Descripciones variables de entrada y funciones

La figura 4.57 fue elaborada con el objetivo de describir específicamente el control que tiene el usuario sobre las variables del modelo; presenta en detalle las funciones y variables de información de entrada. No contempla las variables de entrada asociadas a las salidas de los módulos —esta descripción se detalla en la figura 4.45 y en el diagrama de bloques de la figura 4.58—.

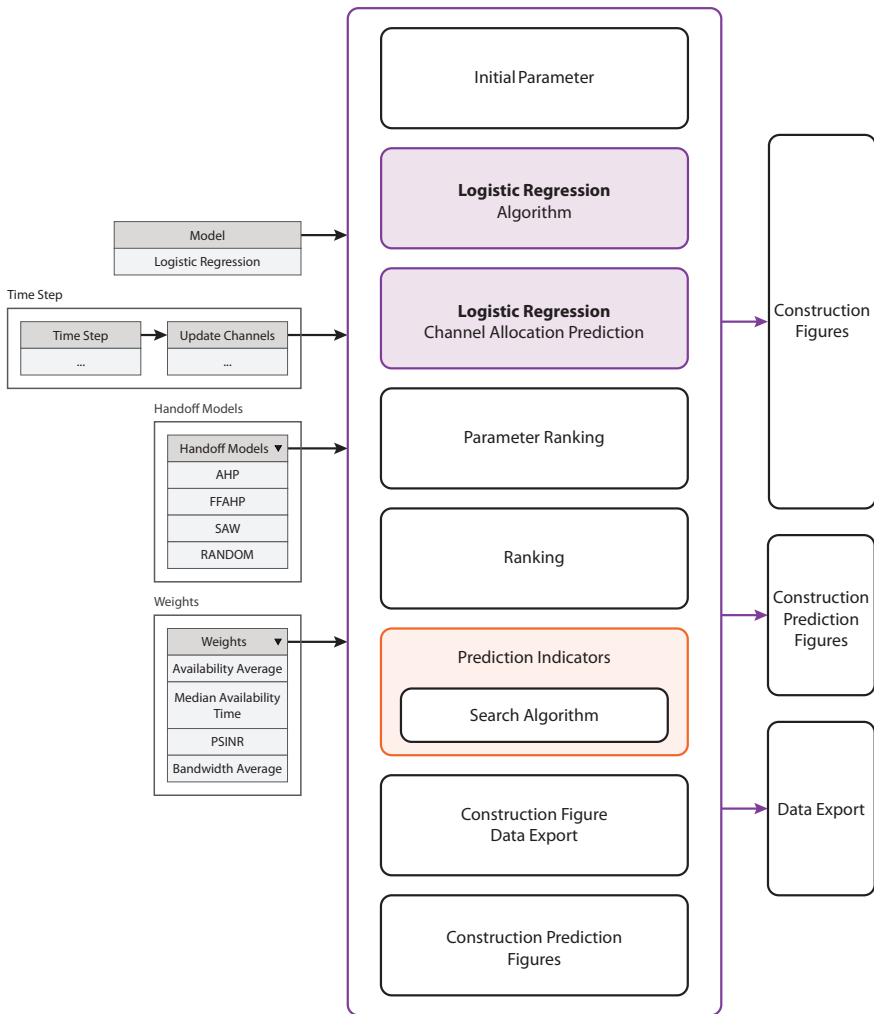


Figura 4.57. Descripción variables de entrada y salida modelo *Logistic Regression*.

Fuente: elaboración propia.

4.9.4.3 Diagrama de bloques

La figura 4.58 presenta el diagrama de bloques del modelo de extracción de características que permite identificar el flujo de datos de las funciones y la información tomada de los respectivos módulos; cada uno de los colores se ajusta a la convención descrita en la figura 4.3.

4.9.4.4 Evaluación modelo movilidad espectral

Para la evaluación del modelo se utiliza el algoritmo métricas de desempeño para obtener las figuras de AAD, AAFH, AAH, AAT y ABW. Adicionalmente, por ser un modelo que predice una matriz de disponibilidad, se utiliza el algoritmo de métricas de predicción descrito en la sección 4.7.4.2. Por tanto, se incluyen las métricas AAIH, AAPH, AAUH.

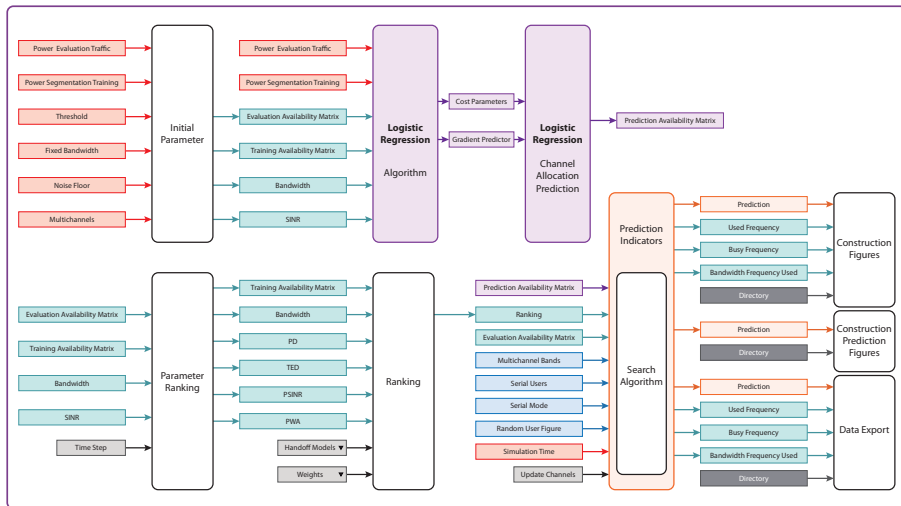


Figura 4.58. Diagrama de bloques modelo no predictivo, técnica *Logistic Regression*.

Fuente: elaboración propia.

4.9.5 Time Series

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 AR, MA, ARMA, ARIMA y SARIMA.

4.9.5.1 Modelo propuesto

La figura 4.59 presenta el diagrama de bloques del modelo propuesto, dividido en cuatro etapas. La primera etapa corresponde a los módulos “*Project Information*”, “*Collaborative Module*”, “*Multi-User Module*” y “*Parameters Module*”; la segunda toma la información del canal seleccionado y aplica regresiones AR, MA, AR, ARMA, SARIMA para predecir la llegada de la PU en el canal seleccionado. La tercera etapa compara las matrices para determinar los indicadores de predicción. Finalmente, en la cuarta, se procesan los resultados de la evaluación y se muestran de forma gráfica los indicadores relevantes.

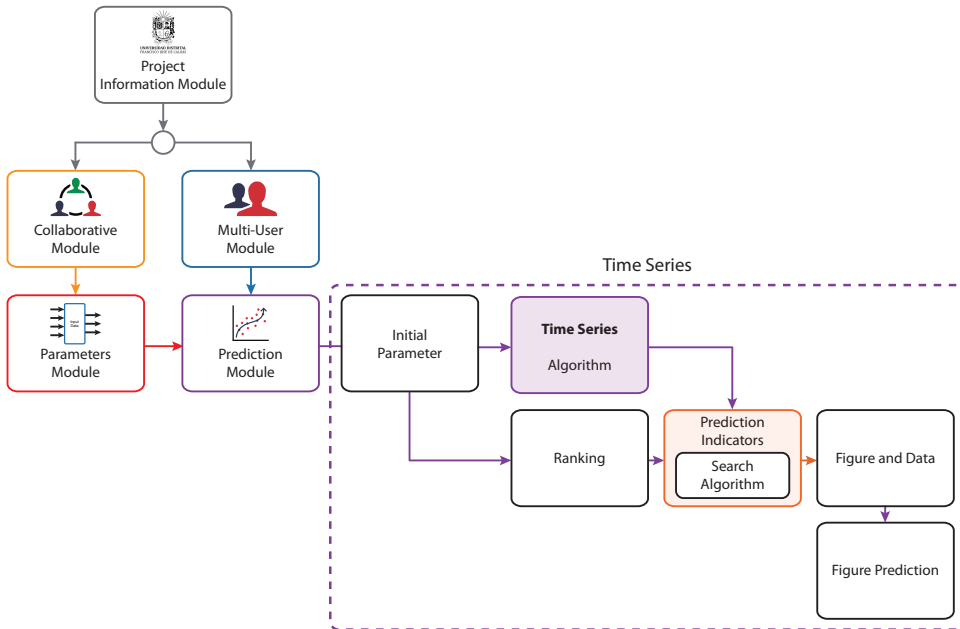


Figura 4.59. Modelo propuesto *Time Series*.

Fuente: elaboración propia.

4.9.5.2 Descripciones variables de entrada y funciones

La figura 4.60 fue elaborada con el objetivo de describir específicamente el control que tiene el usuario sobre las variables del modelo. Presenta en detalle las funciones y variables de información de entrada —no contempla las variables de entrada asociadas a las salidas de los módulos, estas se detallan en la figura 4.45 y el diagrama de bloques de la figura 4.61—.

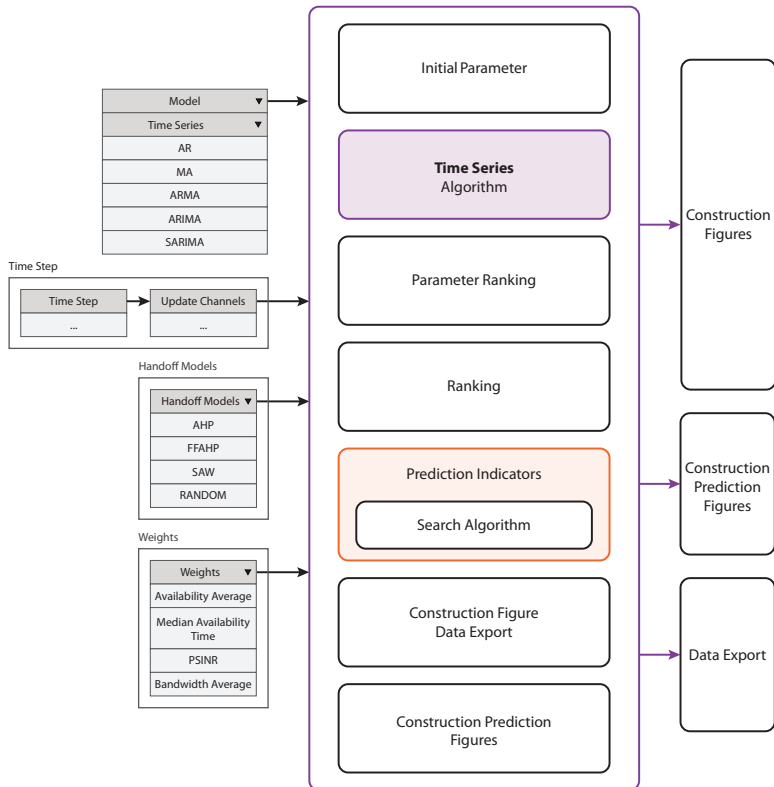


Figura 4.60. Descripción variables de entrada y salida modelo *Time Series*.

Fuente: elaboración propia.

4.9.5.3 Diagrama de bloques

En la figura 4.61 se presenta el diagrama de bloques del modelo de extracción de características que permite identificar el flujo de datos de las funciones y la información tomada de los respectivos módulos; cada uno de los colores se ajusta a la convención descrita en la figura 4.3.

4.9.5.4 Evaluación modelo movilidad espectral

Para la evaluación del modelo se utiliza el algoritmo métricas de desempeño para obtener las figuras de AAD, AAFH, AAH, AAT y ABW. Adicionalmente, por ser un modelo que predice una matriz de disponibilidad, se utiliza el algoritmo de métricas de predicción descrito en la sección 4.7.4.2. Por tanto, se incluyen las métricas AAIH, AAPH, AAUH.

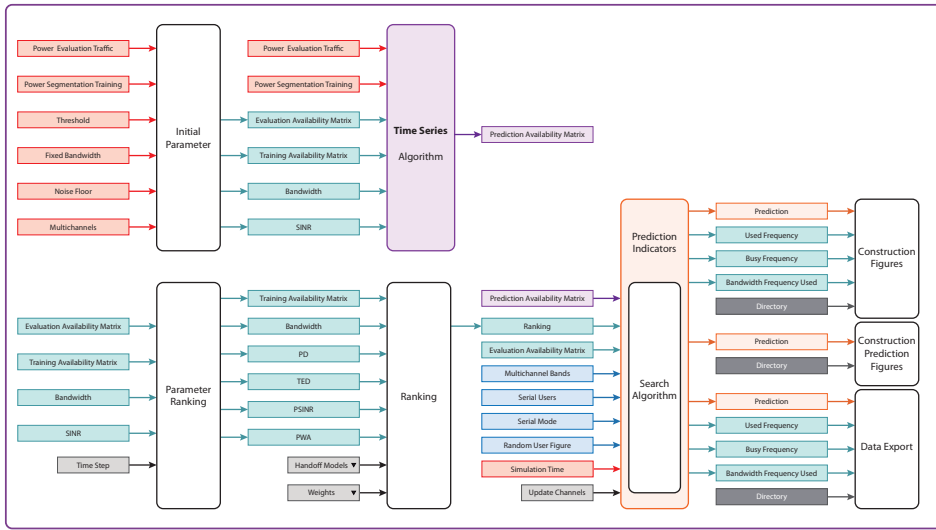


Figura 4.61. Diagrama de bloques modelo no predictivo, técnica *Time Series*.

Fuente: elaboración propia.

4.10 Módulo Salida

La figura 4.62 presenta la interfaz correspondiente a “*Output*”. Este módulo contiene los botones “*Run*”, “*Close*” y “*Update*”. Para cerrar el software, antes o después de la simulación, se selecciona el botón “*Close*”. Si el *software* presenta algún mensaje de error, advertencia o se quiere iniciar una nueva configuración descartando la información introducida, se selecciona el botón “*Update*”.

Finalmente, si todos los módulos fueron configurados correctamente, se habilita el botón “*Run*” encargado de ejecutar la simulación.


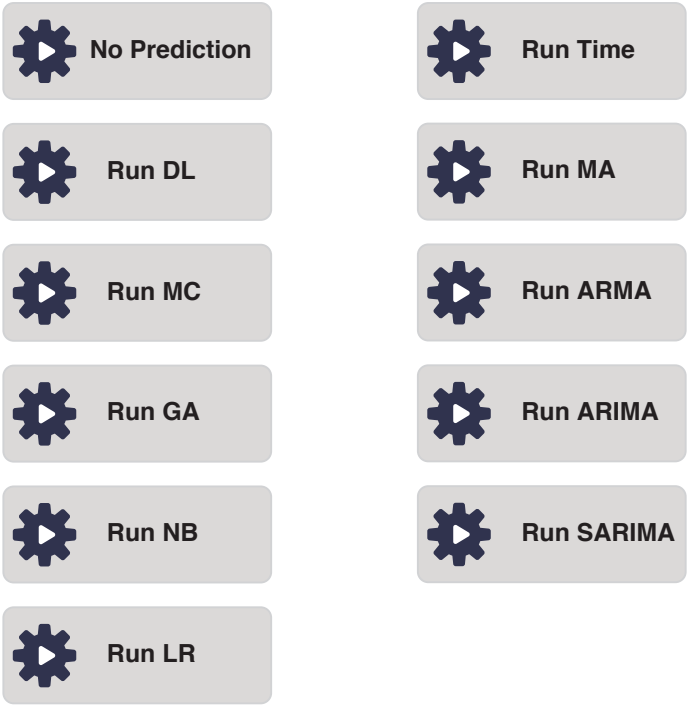


Figura 4.62. Salida MultiColl-DCRN.

Fuente: elaboración propia.

Cada modelo tiene su propio botón “Run”; el objetivo es indicarle al usuario la estrategia parametrizada. En la tabla 4.27 se presenta la figura que se visualiza según el modelo.

Tabla 4.27. Botón “Run” según modelo.



Fuente: elaboración propia.

5. Resultados de la investigación

Este capítulo presenta la evaluación del modelo propuesto para la asignación espectral multiusuario en redes de radio cognitiva descentralizadas. La presentación de los resultados está organizada en siete secciones; los títulos y la respectiva paginación se describen en la tabla 5.1.

Tabla 5.1. Estructura de resultados del modelo implementado.

Sección	Título		Páginas
5.1	Evaluación de los modelos no predictivos		
5.2	Evaluación de los <i>Modelos Predictivos</i>		
5.3	Evaluación comparativa y selección de los modelos		
5.4	Evaluación del nivel de colaboración de los modelos		
	5.4.1	Evaluación comparativa de los niveles de colaboración	
5.5	Evaluación con enfoque multiusuario de los modelos		
	5.5.1	Evaluación multiusuario <i>Deep Learning</i>	
	5.5.2	Evaluación multiusuario FFAHP	
	5.5.3	Evaluación multiusuario <i>Naive Bayes</i>	
	5.5.4	Evaluación multiusuario SAW	
	5.5.5	Evaluación multiusuario TOPSIS	
	5.5.6	Evaluación multiusuario VIKOR	
	5.5.7	Evaluación comparativa multiusuario	
5.6	Evaluación integral colaborativa y multiusuario de los modelos		
5.7	Propuesta definitiva de modelo multiusuario colaborativo		

Fuente: elaboración propia.

Las figuras 5.1 a 5.5 de la sección 5.1 describen el AAH, AAFH, ABW, AAD y AAT, para los modelos no predictivos: FFAHP, VIKOR, TOPSIS, SAW y *Deep Learning*, durante una transmisión de nueve minutos, con una traza de HT y LT, en una red GSM. Las tablas 5.2 y 5.3 muestran los porcentajes comparativos de las métricas de evaluación para cada modelo no predictivo, con una traza de HT y LT, en una red GSM.


Las figuras 5.6 a 5.13 de la sección 5.3 describen el AAH, AAFH, ABW, AAD, AAT, AAIH, AAUH, AAPH, para los modelos predictivos: *Logistic Regression* y *Naive Bayes*, durante una transmisión de nueve minutos, con una traza de HT y LT, en una red GSM. Las tablas 5.4 y 5.5 muestran los porcentajes comparativos de las métricas de evaluación para cada modelo predictivo, con una traza de HT y LT, en una red GSM.

Las figuras 5.14, 5.16, 5.18, 5.20 y 5.22 de la sección 5.4 describen el AAH, AAFH, ABW, AAD, AAT, AAIH, AAUH y AAPH, para los modelos *Deep Learning*, FFAHP y *Naive Bayes*, durante una transmisión de nueve minutos, con una traza de HT, en una red GSM, para cuatro diferentes niveles de cooperación entre SU (10 %, 40 %, 70 % y 100 %). Las figuras 5.15, 5.17, 5.19, 5.21 y 5.23 de la sección 5.4 describen el AAH, AAFH, ABW, AAD, AAT, AAIH, AAUH y AAPH, para los modelos: SAW, TOPSIS y VIKOR, durante una transmisión de 9 minutos, con una traza de HT, en una red GSM, para cuatro diferentes niveles de cooperación entre SU (10 %, 40 %, 70 % y 100 %). Finalmente, la figura 5.24 de la sección 5.4, describe el AAIH, AAUH, AAPH, para *Naive Bayes*, durante una transmisión de nueve minutos, con una traza de HT, en una red GSM, para cuatro diferentes niveles de cooperación entre SU (10 %, 40 %, 70 % y 100 %). Finalmente, las tablas 5.6, 5.7 y 5.8 de la sección 5.4.1 muestran los porcentajes comparativos de las métricas de evaluación para cada modelo.


Las figuras 5.25 a 5.36 de la sección 5.5.1 describen el AAH en modo convencional y en modo real para el modelo *Deep Learning*, durante una transmisión de nueve minutos, con una traza de HT y LT, en una red GSM, para seis diferentes estructuras multiusuario (1 SU, 2 SU, 4 SU, 6 SU, 8 SU y 10 SU). Las figuras 5.37 a 5.48 de la sección 5.5.2 exponen el AAH en modo convencional y en modo real para el modelo FFAHP, durante una transmisión de nueve minutos, con una traza de HT y LT, en una red GSM, para seis

diferentes estructuras multiusuario (1 SU, 2 SU, 4 SU, 6 SU, 8 SU y 10 SU). Las figuras 5.49 a 5.72 de la sección 5.5.3 detallan el AAH y el AAIH, en modo convencional y en modo real para el modelo *Naive Bayes*, durante una transmisión de nueve minutos, con una traza de HT y LT, en una red GSM, para seis diferentes estructuras multiusuario (1 SU, 2 SU, 4 SU, 6 SU, 8 SU y 10 SU). Las figuras 5.73 a 5.84 de la sección 5.5.4 presentan el AAH y el AAIH, en modo convencional y en modo real para el modelo SAW, durante una transmisión de nueve minutos, con una traza de HT y LT, en una red GSM, para seis diferentes estructuras multiusuario (1 SU, 2 SU, 4 SU, 6 SU, 8 SU y 10 SU). Las figuras 5.85 a 5.96 de la sección 5.5.5 describen el AAH, en modo convencional y en modo real para el modelo TOPSIS, durante una transmisión de nueve minutos, con una traza de HT y LT, en una red GSM, para seis diferentes estructuras multiusuario (1 SU, 2 SU, 4 SU, 6 SU, 8 SU y 10 SU). Las figuras 5.97 a 5.108 de la sección 5.5.6 exhiben el AAH, en modo convencional y en modo real para el modelo VIKOR, durante una transmisión de nueve minutos, con una traza de HT y LT, en una red GSM, para seis diferentes estructuras multiusuario (1 SU, 2 SU, 4 SU, 6 SU, 8 SU y 10 SU). Finalmente, las tablas 5.9, 5.10, 5.11 y 5.12 presentan los porcentajes comparativos del desempeño de cada algoritmo para el módulo multiusuario en modo convencional y el modo real para 1, 2, 4, 6, 8 y 10 usuarios. Lo anterior, con el objetivo de analizar el nivel los escenarios multiusuarios. Las tablas 5.9 y 5.10 exponen la evaluación comparativa por multiusuario para HT y LT en modo convencional y real. La tabla 5.11 muestra la evaluación comparativa global por tipo de tráfico para HT y LT en modo convencional y real. Finalmente, la tabla 5.12 presenta la evaluación comparativa por multiusuario para las métricas de predicción de *Naive Bayes*. Las tablas 5.9 y 5.10 de la sección 5.5.7, dan los porcentajes comparativos de las métricas de evaluación para cada modelo, traza de HT y LT.

5.1 Evaluación de los modelos no predictivos




a. GSM HT




b. GSM LT

Figura 5.1. AAH de modelos no predictivos en GSM para HT y LT.

Fuente: elaboración propia.




a. GSM HT




b. GSM LT

Figura 5.2. AAFH de modelos no predictivos en GSM para HT y LT.

Fuente: elaboración propia.




a. GSM HT




b. GSM LT

Figura 5.3. ABW de modelos no predictivos en GSM para HT y LT.

Fuente: elaboración propia.




a. GSM HT




b. GSM LT

Figura 5.4. AAD de modelos no predictivos en GSM para HT y LT.

Fuente: elaboración propia.



a. GSM HT



b. GSM LT

Figura 5.5. AAT de modelos no predictivos en GSM para HT y LT.

Fuente: elaboración propia.

Tabla 5.2. Valores relativos de las métricas para modelos no predictivos en GSM con HT.

Métrica de Evaluación	FFAHP	SAW	TOPSIS	VIKOR	<i>Deep Learning</i>
AAH	96,22	86,43	89,67	81,16	100
AAFH	96,67	82,53	87,06	77,01	100
ABW	96,86	89,34	90,56	84,01	100
AAD	98,07	100	92,94	90,46	84,94
AAT	100	87,72	91,79	79,44	96,72
Score	97,56	89,2	90,4	82,42	96,33


Fuente: elaboración propia.

Tabla 5.3. Valores relativos de las métricas de modelos no predictivos en GSM con LT.


Métrica de Evaluación	FFAHP	SAW	TOPSIS	VIKOR	<i>Deep Learning</i>
AAH	77,89	92,5	100	90,24	15,01
AAFH	33,33	45,45	100	33,33	2,18
ABW	99,88	100	39,07	99,78	90,18
AAD	90,75	98,27	100	98,27	32,82
AAT	99,4	100	99,86	99,93	79,75
Score	80,25	87,24	87,79	84,31	43,99

Fuente: elaboración propia.

5.2 Evaluación de los modelos predictivos




a. GSM HT




b. GSM LT

Figura 5.6. AAH de modelos predictivos en GSM para HT y LT.

Fuente: elaboración propia.




a. GSM HT




b. GSM LT

Figura 5.7. AAFH de modelos predictivos en GSM para HT y LT.

Fuente: elaboración propia.




a. GSM HT




b. GSM LT

Figura 5.8. ABW de modelos predictivos en GSM para HT y LT.
Fuente: elaboración propia.




a. GSM HT




b. GSM LT

Figura 5.9. AAD de modelos predictivos en GSM para HT y LT.

Fuente: elaboración propia.




a. GSM HT




b. GSM LT

Figura 5.10. AAT de modelos predictivos en GSM para HT y LT.

Fuente: elaboración propia.




a. GSM HT




b. GSM LT

Figura 5.11. AAIH de Modelos Predictivos en GSM para HT y LT.

Fuente: elaboración propia.




a. GSM HT




b. GSM LT

Figura 5.12. AAUH de Modelos Predictivos en GSM para HT y LT.

Fuente: elaboración propia.



a. GSM HT



b. GSM LT

Figura 5.13. AAPH de modelos predictivos en GSM para HT y LT.

Fuente: elaboración propia.

Tabla 5.4. Valores relativos de las métricas para modelos predictivos en GSM con HT.

Métrica de Evaluación	<i>Logistic Regression</i>	<i>Naive Bayes</i>
AAH	89,93	100
AAFH	100	91,64
ABW	100	99,98
AAD	100	89,36
AAT	100	90,21
AAIH	68,12	100
AAUH	100	98,96
AAPH	100	89,05
<i>Score</i>	94,76	94,90

Fuente: elaboración propia.

Tabla 5.5. Valores relativos de las métricas para Modelos Predictivos en GSM con LT.

Métrica de Evaluación	<i>Logistic Regression</i>	<i>Naive Bayes</i>
AAH	98,77	100
AAFH	26,32	100
ABW	100	99,94
AAD	99,59	100
AAT	99,85	100
AAIH	18,6	100
AAUH	100	96,67
AAPH	100	95,4
<i>Score</i>	80,39	99,00

Fuente: elaboración propia.


5.3 Evaluación comparativa y selección de los modelos

A partir del análisis comparativo de las métricas obtenidas en la evaluación de los modelos no predictivos y predictivos se seleccionan los algoritmos para la evaluación del módulo colaborativo, el análisis se realiza para LT y HT.


De acuerdo con los resultados de los modelos no predictivos, para HT, se seleccionan las dos puntuaciones más altas, FFAHP con 97,56% y *Deep Learning* con 96,33%. Para LT se seleccionan las tres puntuaciones más altas, TOPSIS con 87,79%, VIKOR con 84,31% y SAW con 87,24%.

Según los resultados de los modelos predictivos, para HT y LT, se selecciona *Naive Bayes* por su desempeño en las métricas de QoS y de predicción.


5.4 Evaluación del nivel de colaboración de los modelos



a. Deep Learning en HT




b. FFAHP en HT




c. Naive Bayes en HT

Figura 5.14. AAH con 10%, 40%, 70% y 100% de colaboración para GSM con HT.


Fuente: elaboración propia.



a. SAW en LT




b. TOPSIS en LT




c. VIKOR en LT

Figura 5.15. AAH con 10%, 40%, 70% y 100% de colaboración para GSM con LT.


Fuente: elaboración propia.



a. Deep Learning en HT




b. FFAHP en HT




c. Naive Bayes en HT

Figura 5.16. AAFH con 10%, 40%, 70% y 100% de colaboración para GSM con HT.


Fuente: elaboración propia.



a. SAW en LT




b. TOPSIS en LT




c. VIKOR en LT

Figura 5.17. AAFH con 10%, 40%, 70% y 100% de colaboración para GSM con LT.


Fuente: elaboración propia.



a. Deep Learning en HT




b. FFAHP en HT




c. Naive Bayes en HT

Figura 5.18. ABW con 10%, 40%, 70% y 100% de colaboración para GSM con HT.


Fuente: elaboración propia.



a. SAW en LT




b. TOPSIS en LT




c. VIKOR en LT

Figura 5.19. ABW con 10%, 40%, 70% y 100% de colaboración para GSM con LT.


Fuente: elaboración propia.



a. Deep Learning en HT




b. FFAHP en HT




c. Naive Bayes en HT

Figura 5.20. AAD con 10%, 40%, 70% y 100% de colaboración para GSM con HT.


Fuente: elaboración propia.



a. SAW en LT




b. TOPSIS en LT




c. VIKOR en LT

Figura 5.21. AAD con 10%, 40%, 70% y 100% de colaboración para GSM con LT.


Fuente: elaboración propia



a. Deep Learning en HT




b. FFAHP en HT




c. Naive Bayes en HT

Figura 5.22. AAT con 10%, 40%, 70% y 100% de colaboración para GSM con HT.


Fuente: elaboración propia.



a. SAW en LT




b. TOPSIS en LT




c. VIKOR en LT

Figura 5.23. AAT con 10%, 40%, 70% y 100% de colaboración para GSM con LT.


Fuente: elaboración propia.



a. Handoffs con Interferencia en HT



b. Handoffs Anticipados en HT



c. Handoffs Perfectos en HT

Figura 5.24: AAIH, AAUH, AAPH con 10%, 40%, 70% y 100% de colaboración en GSM con HT.

Fuente: elaboración propia.

5.4.1 Evaluación comparativa de los niveles de colaboración

Las tablas 5.6 y la 5.7 presentan los porcentajes comparativos del desempeño de cada algoritmo por nivel de colaboración para cada métrica de evaluación. 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 que resulten más interesantes. Tener en cuenta que para las tablas anteriores la comparación solo se debe realizar verticalmente, no horizontal. La tabla 5.8 presenta los porcentajes comparativos globales del desempeño de cada algoritmo por métrica de evaluación para dos niveles de colaboración (10 % y 100 %). Tener en cuenta que para la tabla anterior la comparación se puede realizar horizontalmente, y no vertical.

Tabla 5.6. Evaluación comparativa por nivel de colaboración para HT.

Nivel de colaboración HT	AAH	AAFH	ABW	AAD	AAT	AAIH	AAUH	AAPH	Score
Deep L. 10 %	64,68	22,15	74,18	71,75	68	-	-	-	60,15
FFAHP 10%	91,71	33,37	91,17	95,27	94,1	-	-	-	81,12
Naive B. 10%	51,31	50,49	72,53	65,59	84,63	71,45	100	58,05	69,26
Deep L. 40 %	70,64	25,72	81,15	75,88	71,39	-	-	-	64,96
FFAHP 40%	94,67	34,67	91,41	97,24	94,4	-	-	-	82,48
Naive B. 40%	56,51	55,83	76,66	69,5	92,91	82,21	87,38	63,5	73,06
Deep L. 70 %	79,08	27,04	87,26	83,55	76,04	-	-	-	70,59
FFAHP 70%	96,14	35,62	92,35	98,07	95,45	-	-	-	83,53
Naive B. 70%	68,38	77,36	79,24	71,35	95,45	93,79	61,22	80,35	78,39
Deep L. 100%	100	36,98	95,34	100	92,31	-	-	-	84,93
FFAHP 100%	96,22	35,75	100	99,03	100	-	-	-	86,2
Naive B. 100%	80,05	100	81,8	76,18	97,46	100	59,21	100	86,84

Fuente: elaboración propia.

Tabla 5.7. Evaluación comparativa por nivel de colaboración para LT.

Nivel de colaboración HT	AAH	AAFH	ABW	AAD	AAT	Score
SAW 10 %	74,71	11,11	92,29	93,18	93,6	72,98
TOPSIS 10 %	67,71	14,29	92,49	86,08	93	70,71
VIKOR 10 %	70,65	11,11	92,95	90,16	92,81	71,54
SAW 40 %	81,25	18,18	92,71	95,13	92,52	75,96
TOPSIS 40 %	80,25	33,33	98,01	90,77	99,38	80,35
VIKOR 40 %	74,71	13,33	99,18	93,92	99,93	76,21
SAW 70 %	84,42	40	99,4	97,2	99,93	84,19
TOPSIS 70 %	83,33	40	98,54	98,91	99,86	84,13
VIKOR 70 %	79,27	20	99,46	95,13	99,88	78,75
SAW 100 %	100	100	99,56	100	100	99,91
TOPSIS 100 %	87,84	66,67	99,18	99,01	97,17	89,97
VIKOR 100 %	86,67	66,67	100	97,2	99,71	90,05

Fuente: elaboración propia.

Tabla 5.8. Evaluación comparativa global por métrica de evaluación.

Métrica de Evaluación	Deep 10 %	Deep 100 %	FEAHP 10 %	FEAHP 100 %	Naive 10 %	Naive 100 %	SAW 10 %	SAW 100 %	Topsis 10 %	Topsis 100 %	Vikor 10 %	Vikor 100 %
AAH HT	64,68	100	91,71	96,22	51,31	80,05	-	-	-	-	-	-
AAFH HT	22,15	36,98	33,37	35,75	50,49	100	-	-	-	-	-	-
ABW HT	74,18	95,34	91,17	100	72,53	81,8	-	-	-	-	-	-
AAD HT	71,75	100	95,27	99,03	65,59	76,18	-	-	-	-	-	-
AAT HT	68	92,31	94,1	100	84,63	97,46	-	-	-	-	-	-
AAIH HT	-	-	-	-	71,45	100	-	-	-	-	-	-


Métrica de Evaluación	Deep 10%	Deep 100%	FFAHP 10%	FFAHP 100%	Naive 10%	Naive 100%	SAW 10%	SAW 100%	Topsis 10%	Topsis 100%	Vikor 10%	Vikor 100%
AAUH HT	-	-	-	-	100	59,21	-	-	-	-	-	-
AAPH HT	-	-	-	-	58,05	100	-	-	-	-	-	-
AAH LT	-	-	-	-	-	-	74,71	100	67,71	87,84	70,65	86,67
AAFH LT	-	-	-	-	-	-	11,11	100	14,29	66,67	11,11	66,67
ABW LT	-	-	-	-	-	-	92,29	99,56	92,49	99,18	92,95	100
AAD LT	-	-	-	-	-	-	93,18	100	86,08	99,01	90,16	97,2
AAT LT	-	-	-	-	-	-	93,6	100	93	97,17	92,81	99,71
Score HT Global	60,15	84,93	81,12	86,20	69,26	86,84	-	-	-	-	-	-
Score LT Global	-	-	-	-	-	-	72,98	99,91	70,71	89,97	71,54	90,05

Fuente: elaboración propia.


5.5 Evaluación con enfoque multiusuario de los modelos

Para la evaluación del módulo multiusuario se utilizan los modelos no predictivos y predictivos de mayor puntuación para cada nivel de tráfico. Para el tráfico HT se utilizan el Módulo *Deep Learning*, el modelo predictivo *Naive Bayes* y las técnicas multicriterio FFAHP, SAW, TOPSIS, VIKOR. Se implementa en modo convencional y en el modo real para 1, 2, 4, 6, 8 y 10 usuarios, con una configuración de una sola aplicación al 100 % en un canal. Los resultados obtenidos se muestran desde la figura 5.25 hasta la 5.108.

5.5.1 Evaluación multiusuario *Deep Learning*




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.25. *Deep Learning* con 1 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.26. *Deep Learning* con 1 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.27. *Deep Learning* con 2 SU en HT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.28. *Deep Learning* con 2 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.29. *Deep Learning* con 4 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.30. *Deep Learning* con 4 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.31. *Deep Learning* con 6 SU en HT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.32. *Deep Learning* con 6 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.33. *Deep Learning* con 8 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.34. Deep Learning con 8 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.35. Deep Learning con 10 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.



a. Modo Convencional en LT




b. Modo Real en LT


Figura 5.36. Deep Learning con 10 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.

5.5.2 Evaluación multiusuario FFAHP




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.37. FFAHP con 1 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.38. FFAHP con 1 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.39. FFAHP con 2 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.40. FFAHP con 2 SU en LT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.41. FFAHP con 4 SU en HT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.42. FFAHP con 4 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.



a. Modo Convencional en HT



b. Modo Real en HT

Figura 5.43. FFAHP con 6 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.







Figura 5.44. FFAHP con 6 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.45. FFAHP con 8 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.46. FFAHP con 8 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.47. FFAHP con 10 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.



a. Modo Convencional en LT




b. Modo Real en LT


Figura 5.48. FFAHP con 10 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.

5.5.3 Evaluación multiusuario *Naive Bayes*




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.49. AAH de *Naive Bayes* con 1 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.50. AAH de *Naive Bayes* con 1 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.51. AAH de *Naive Bayes* con 2 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.52. AAH de *Naive Bayes* con 2 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.



a. Modo Convencional en HT



b. Modo Real en HT

Figura 5.53. AAH de *Naive Bayes* con 4 SU en HT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.







Figura 5.54. AAH de *Naive Bayes* con 4 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.55. AAH de *Naive Bayes* con 6 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.56. AAH de *Naive Bayes* con 6 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.57. AAH de *Naive Bayes* con 8 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.58. AAH de *Naive Bayes* con 8 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.59. AAH de *Naive Bayes* con 10 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.60. AAH de *Naive Bayes* con 10 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.61. AAIH de *Naive Bayes* con 1 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.62. AAIH de *Naive Bayes* con 1 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.63. AAIH de *Naïve Bayes* con 2 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.64. AAIH de *Naive Bayes* con 2 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.65. AAIH de *Naive Bayes* con 4 SU en HT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.66. AAIH de *Naive Bayes* con 4 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.67. AAIH de *Naive Bayes* con 6 SU en HT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.68. AAIH de *Naive Bayes* con 6 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.69. AAIH de *Naive Bayes* con 8 SU en HT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.70. AAIH de *Naive Bayes* con 8 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.71. AAIH de Naive Bayes con 10 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.



a. Modo Convencional en LT




b. Modo Real en LT


Figura 5.72. AAIH de *Naive Bayes* con 10 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.

5.5.4 Evaluación multiusuario SAW




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.73. SAW con 1 SU en HT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.74. SAW con 1 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.75. SAW con 2 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.76. SAW con 2 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.77. SAW con 4 SU en HT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.78. SAW con 4 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.



a. Modo Convencional en HT



b. Modo Real en HT

Figura 5.79. SAW con 6 SU en HT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.







Figura 5.80. SAW con 6 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.81. SAW con 8 SU en HT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.82. SAW con 8 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.83. SAW con 10 SU en HT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.



a. Modo Convencional en LT




b. Modo Real en LT


Figura 5.84. SAW con 10 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.

5.5.5 Evaluación multiusuario TOPSIS




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.85. TOPSIS con 1 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.86. TOPSIS con 1 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.87. TOPSIS con 2 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.88. TOPSIS con 2 SU en LT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.



a. Modo Convencional en HT



b. Modo Real en HT

Figura 5.89. TOPSIS con 4 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.







Figura 5.90. TOPSIS con 4 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.91. TOPSIS con 6 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.92. TOPSIS con 6 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.93. TOPSIS con 8 SU en HT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.94. TOPSIS con 8 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.95. TOPSIS con 10 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.



a. Modo Convencional en LT




b. Modo Real en LT


Figura 5.96. TOPSIS con 10 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.

5.5.6 Evaluación multiusuario VIKOR




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.97. VIKOR con 1 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.98. VIKOR con 1 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.99. VIKOR con 2 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.100. VIKOR con 2 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.101. VIKOR con 4 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.102. VIKOR con 4 SU en LT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.103. VIKOR con 6 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.104. VIKOR con 6 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.105. VIKOR con 8 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.




a. Modo Convencional en LT




b. Modo Real en LT

Figura 5.106. VIKOR con 8 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.




a. Modo Convencional en HT




b. Modo Real en HT

Figura 5.107. VIKOR con 10 SU en HT con y sin SU aleatorios adicionales.
Fuente: elaboración propia.



a. Modo Convencional en LT



b. Modo Real en LT

Figura 5.108. VIKOR con 10 SU en LT con y sin SU aleatorios adicionales.

Fuente: elaboración propia.

5.5.7 Evaluación comparativa multiusuario

Las tablas 5.9, 5.10, 5.11 y 5.12 presentan los porcentajes comparativos del desempeño de cada algoritmo para el módulo multiusuario en modo convencional y el modo real para 1, 2, 4, 6, 8 y 10 usuarios, con el objetivo de analizar el nivel de los escenarios multiusuarios. Las tablas 5.9 y 5.10 presentan la evaluación comparativa por multiusuario para HT y LT en modo convencional y real. La tabla 5.11 exhibe la evaluación comparativa global por tipo de tráfico para HT y LT en modo convencional y real. Finalmente, la tabla 5.12 presenta la evaluación comparativa multiusuario para las métricas de predicción de *Naive Bayes*.

Tabla 5.9. Evaluación comparativa por multiusuario para HT.

Características Multiusuario	<i>Deep Learning</i>	FFAHP	<i>Naive Bayes</i>	SAW	TOPSIS	VIKOR
MSU1–Convencional	100	96,22	80,05	86,43	89,67	81,16
MSU2 – Convencional	100	89,9	97,42	89,6	93,03	84,57
MSU4 – Convencional	84,65	83,65	100	79,71	87,59	75,15
MSU6 – Convencional	77,6	78,26	100	76,59	79,25	68,98
MSU8 – Convencional	74,79	74,57	100	75,36	75,68	65,58
MSU10 – Convencional	71,87	72,22	100	72,61	73,29	63,34
Score Convencional	84,82	82,47	96,25	80,05	83,09	73,13
MSU1 – Real	85,29	100	83,2	89,82	93,19	84,35
MSU2 – Real	80,94	80,7	100	83,77	92,59	84,16
MSU4 – Real	78,3	75,12	100	75,64	83,05	74,19
MSU6 – Real	78,58	77,49	100	77,7	76,42	67,27
MSU8 – Real	71,94	71,41	100	73,33	74,45	61,96
MSU10 – Real	66,12	68,97	100	70,75	70,51	60,93
Score Real	76,86	78,95	97,2	78,5	81,7	72,14

Fuente: elaboración propia.

Tabla 5.10. Evaluación comparativa por multiusuario para LT.

Características Multiusuario	<i>Deep Learning</i>	FFAHP	<i>Naive Bayes</i>	SAW	TOPSIS	VIKOR
MSU1–Convencional	16,23	77,89	8,41	92,5	100	90,24
MSU2 – Convencional	18,36	74,45	10,89	100	99,03	97,14
MSU4 – Convencional	13,52	72,51	15,29	100	97,7	97,23
MSU6 – Convencional	13,12	77,2	18,56	100	93,4	96,5
MSU8 – Convencional	13,66	77,91	21,41	100	94,59	96,81
MSU10 – Convencional	14,4	79,43	23,83	100	96,41	97,25
Score Convencional	14,88	76,57	16,4	98,75	96,86	95,86
MSU1 – Real	17,54	84,21	9,1	100	62,5	97,56
MSU2 – Real	13,92	73,29	13,21	100	63,82	85,17
MSU4 – Real	12,24	54,26	15,37	100	90,13	86,69
MSU6 – Real	12,61	64,6	19,96	100	81,12	69,04
MSU8 – Real	13,77	63,87	21,39	74,52	100	88,93
MSU10 – Real	14,89	73,86	26,7	83,94	100	98,26
Score Real	14,16	69,02	17,62	93,08	82,93	87,61

Fuente: elaboración propia.

Tabla 5.11. Evaluación comparativa global por tipo de tráfico.

Escenario	<i>Deep Learning</i>	FFAHP	<i>Naive Bayes</i>	SAW	TOPSIS	VIKOR
AAH HT Convencional	84,82	82,47	96,25	80,05	83,09	73,13
AAH HT Real	76,86	78,95	97,2	78,5	81,7	72,14
AAH LT Convencional	14,88	76,57	16,4	98,75	96,86	95,86
AAH LT Real	14,16	69,02	17,62	93,08	82,93	87,61
Score HT Global	80,84	80,71	96,73	79,28	82,4	72,64
Score LT Global	14,52	72,8	17,01	95,92	89,9	91,74

Fuente: elaboración propia.

Tabla 5.12. Evaluación comparativa por multiusuario para interferencia en *Naive Bayes*.

Características Multiusuario	AAIH-HT	AAIH-LT	AAUH-HT	AAUH-LT	AAPH-HT	AAPH-LT	Score
MSU1–Convencional	52,6	75	100	100	100	44,67	78,71
MSU2 – Convencional	68,18	100	65,66	47,17	98,65	52,63	72,05
MSU4 – Convencional	86,89	82,76	52,01	26,77	91,26	79,57	69,88
MSU6 – Convencional	92,19	60	50,33	23,24	85,42	97,34	68,09
MSU8 – Convencional	95,65	50,51	47,08	22,34	82,89	100	66,41
MSU10 – Convencional	100	40,27	43,65	22,04	81,79	96,26	64
Score Convencional	82,59	68,09	59,79	40,26	90	78,41	69,86
MSU1 – Real	47,35	62,5	100	100	100	45,93	75,96
MSU2 – Real	79,89	100	49,67	40,98	97,51	58,41	71,08
MSU4 – Real	76,27	58,82	53,43	23,73	89,84	94,02	66,02
MSU6 – Real	80,54	50	49,06	23,27	83,49	100	64,39
MSU8 – Real	87,73	28,99	45,24	21,3	82,51	97,76	60,59
MSU10 – Real	100	31,65	37,35	21,26	81,01	94,98	61,04
Score Real	78,63	55,33	55,79	38,42	89,06	81,85	66,51
Score Global HT	80,61	NA	57,79	NA	89,53	NA	75,98
Score Global LT	NA	61,71	NA	39,34	NA	80,13	60,39

Fuente: elaboración propia.

6. Discusión

El modelo de asignación espectral multiusuario para redes de radio cognitiva descentralizadas desarrollado está conformado por los módulos colaborativo, multiusuario, predictivo y el *Deep Learning*. Para su evaluación y validación se implementaron ocho métricas de evaluación:

1. Retardo promedio acumulado (AAD)
2. *Handoff* fallidos promedio acumulado (AAFH)
3. *Handoff* promedio acumulado (AAH)
4. *Handoff* con interferencia promedio acumulado (AAIH)
5. *Handoff* perfecto promedio acumulado (AAPH)
6. *Throughput* promedio acumulado (AAT)
7. *Handoff* anticipado promedio acumulado (AAUH)
8. Ancho de banda promedio (ABW)

Las tablas 5.2 y 5.3 presentan la evaluación porcentual para los modelos no predictivos; las tablas 5.4 y 5.5 la evaluación porcentual para los modelos predictivos. Las tablas 5.6, .57 y 5.8 hacen lo mismo para el módulo colaborativo. Las tablas 5.9, 5.10, 5.11 y 5.12 exponen los porcentajes comparativos del desempeño de cada algoritmo para el módulo multiusuario en modo convencional y real para 1, 2, 4, 6, 8 y 10 usuarios. Las tablas 5.9 y 5.10 presentan la evaluación comparativa por multiusuario para HT y LT en modo convencional y real. La tabla 5.11 presenta la evaluación comparativa global por tipo de tráfico para HT y LT en modo convencional y real. Evidentemente, por mayor número de oportunidades espectrales, el

desempeño de las métricas presenta mejores resultados para LT. La tabla 5.12 presenta la evaluación comparativa por multiusuario para las métricas de predicción de *Naive Bayes*.

Para la evaluación de los modelos no predictivos se implementaron cuatro técnicas multicriterio (FFAHP, VIKOR, TOPSIS, SAW) y *Deep Learning*. Para el nivel de tráfico HT los resultados se presentan en la tabla 5.2. De acuerdo con los criterios de costo y beneficio de cada una de las métricas, *Deep Learning* obtiene el mejor desempeño respecto a las técnicas multicriterio con una puntuación de 96,33%; FFAHP obtiene el segundo mejor desempeño, TOPSIS, VIKOR y SAW el tercer, cuarto y quinto, respectivamente. Respecto a las métricas de evaluación individuales, para los dos modelos con las puntuaciones más altas (*Deep Learning* y FFAHP), la diferencia promedio entre métricas es de 3,38 %, exceptuando AAD, en donde el primero obtiene el rendimiento más deficiente —para esta métrica, la diferencia es 13,13 %—. Entre el modelo con la puntuación más alta (*Deep Learning*) y la más baja (VIKOR), la diferencia promedio entre métricas es 18,76 %, exceptuando AAD; para esta métrica, la diferencia es 5,52 %.

Para la evaluación de los modelos no predictivos se implementaron cuatro técnicas multicriterio (FFAHP, VIKOR, TOPSIS, SAW) y *Deep Learning*. Para el nivel de tráfico LT los resultados se presentan en la tabla 5.3. A diferencia de HT y de acuerdo con los criterios de costo y beneficio de cada una de las métricas, *Deep Learning* y FFAHP obtienen el menor desempeño respecto a TOPSIS, VIKOR y SAW. TOPSIS obtiene la mayor puntuación con 87,29 %, SAW la segunda con 87,24 %, finalmente VIKOR con 84,31 %. Respecto a las métricas de evaluación individuales, para los tres modelos con las puntuaciones más altas (TOPSIS, VIKOR y SAW), no es viable obtener una diferencia promedio entre métricas debido a que no se presentan variaciones sobre el mismo rango.

Para la evaluación de los modelos predictivos se implementaron dos técnicas: *Logistic Regression* y *Naive Bayes*. Para el nivel de tráfico HT los resultados se presentan en la tabla 5.4. Por ser técnicas de predicción, se incluyen tres métricas adicionales: AAPH, AAUH y AAIH. Para el análisis de puntuación *Naive Bayes* presenta la mayor puntuación: 94,9 % —con una diferencia por debajo de 1 %, respecto a *Logistic Regression*—. Para las métricas

asociadas a la predicción, *Logistic Regression* presenta los valores relativos más altos para *handoff* perfectos y anticipados, con una diferencia de 10,95 % y 1,04 % respecto a *Naive Bayes*. Para los *handoff* con interferencia *Naive Bayes* presenta los valores relativos más altos con una diferencia de 31,88 %. Para las demás métricas la diferencia promedio es 9,72 %, exceptuando AAD, en donde la diferencia es 0,02 %.

La evaluación de los modelos predictivos implementó dos técnicas: *Logistic Regression* y *Naive Bayes*. Para el nivel de tráfico LT los resultados se presentan en la tabla 5.5; por ser técnicas de predicción, se incluyen tres métricas adicionales: AAPH, AAUH y AAIH. Para el análisis de puntuación *Naive Bayes* presenta la mayor puntuación con 99,0 %, con una diferencia de 18,61 % respecto a *Logistic Regression*. De las métricas asociadas a la predicción, *Logistic Regression* presenta los valores relativos más altos para *handoff* perfectos y anticipados, con una diferencia de 3,33 % y 4,6 % respecto a *Naive Bayes*; para los *handoff* con interferencia *Naive Bayes* presenta los valores relativos más altos con una diferencia de 81,4 %. Para las demás métricas la diferencia promedio es 0,46 %, exceptuando AAFH, en donde la diferencia es 73,68 %.

Para la evaluación del módulo colaborativo se utilizan los modelos no predictivos y predictivos de mayor puntuación para cada nivel de tráfico. Para el tráfico HT se utiliza *Deep Learning*, FFAHP y *Naive Bayes*, para cuatro niveles de colaboración: 10 %, 40 %, 70 % y 100 %. Los resultados de la evaluación comparativa por nivel de colaboración se presentan en la tabla 5.6. De acuerdo con la puntuación, se evidencia una mejoría en el desempeño de cada algoritmo al aumentar el nivel de colaboración: el promedio de las diferencias con respecto al nivel colaboración anterior es 8,26 % para *Deep Learning*, 1,69 % para FFAHP y 5,86 % para *Naive Bayes*. En general, la mejoría obtenida es menor a 10 % para todos los modelos. Por tanto, un análisis interesante sería evaluar comparativamente cada modelo en todos los escenarios, teniendo en cuenta el nivel de mayor y menor colaboración, es decir, 10 % y 100 %.

Para la evaluación del módulo colaborativo se utilizan los modelos no predictivos y predictivos de mayor puntuación para cada nivel de tráfico. Para el tráfico LT se utilizan SAW, TOPSIS y VIKOR, para cuatro niveles

de colaboración: 10 %, 40 %, 70 % y 100 %. Los resultados de la evaluación comparativa por nivel de colaboración se presentan en la tabla 5.7. De acuerdo con la puntuación, se evidencia una mejoría en el desempeño de cada algoritmo al aumentar el nivel de colaboración; el promedio de las diferencias con respecto al nivel colaboración anterior es de 8,98 % para SAW, 6,42 % para TOPSIS y 6,17 % para VIKOR. En general, la mejoría obtenida es menor a 10 % para todos los modelos. Por tanto, un análisis interesante sería evaluar comparativamente cada modelo en todos los escenarios, teniendo en cuenta el nivel de mayor y menor colaboración, es decir, 10 % y 100 %.

Con respecto a AAH, en HT se observa que *Deep Learning* en 100 % tiene el mejor desempeño, sin embargo, esta característica solo está presente para este nivel de colaboración, para el resto de escenarios FFAHP presenta las mejores métricas; *Naive Bayes*, para los cuatro escenarios obtiene los niveles más bajos. En LT, SAW en 100 % tiene el mejor desempeño. Esta característica se presenta para los demás niveles de colaboración. TOPSIS obtiene las segundas mejores métricas excepto en el escenario del 10 %, en donde por una diferencia de 2,94 % gana VIKOR.

Con respecto a AAFH, en HT se observa que *Naive Bayes* en 100 % tiene el mejor desempeño. Esta característica se presenta para los demás niveles de colaboración. FFAHP obtiene las segundas mejores métricas excepto en el escenario del 100 %, en donde por una diferencia de 1,23 % gana *Deep Learning*. En LT, SAW en 100 % tiene el mejor desempeño, para este escenario TOPSIS y SAW obtienen resultados iguales: el comportamiento es equivalente para el nivel de colaboración de 70 %. Para el nivel de colaboración de 40 % y 19 % TOPSIS supera a SAW y VIKOR.

Con respecto a ABW, en HT se observa un comportamiento equivalente en los cuatro escenarios: FFAHP obtiene el mejor desempeño, seguido de *Deep Learning* y, finalmente, *Naive Bayes*. En LT, para los cuatro escenarios, VIKOR obtiene el mejor desempeño, seguido de SAW para 100 %, 70 %. Para el 40 % y 10 % —con una diferencia de 5,3 % y 0,2 % respectivamente—, TOPSIS presenta mejores resultados.

Con respecto a AAD, se observa que FFAHP domina en tres de los cuatro escenarios de HT —solo en el nivel de colaboración de 100 %, *Deep Learning*

con una diferencia de 0,97% presenta el mejor desempeño—; para el resto de niveles mantiene el segundo lugar y *Naive Bayes* ocupa el tercero. Para LT, SAW domina en tres de los cuatro escenarios —solo en el nivel de colaboración de 70% TOPSIS, con una diferencia de 1,71%, presenta el mejor desempeño—, para 10% y 40% de colaboración el comportamiento se mantiene; TOPSIS y VIKOR presentan el segundo y tercer desempeño.

Con respecto a AAT, para los cuatro escenarios de HT, FFAHP obtiene el mejor desempeño, seguido de *Naive Bayes* y *Deep Learning*. Para LT, en 10% y 40% de colaboración VIKOR, TOPSIS y SAW presentan el primer, segundo y tercer desempeño, respectivamente. Para 100% y 10% SAW toma los mayores niveles; por una diferencia de 2,54% en la colaboración del 100% VIKOR sobrepasa a TOPSIS; finalmente, para 10% de colaboración, por un margen de 0,19% TOPSIS supera a VIKOR.

De acuerdo con la propuesta de evaluar comparativamente el nivel de mayor y menor colaboración, la tabla 5.8 presenta los porcentajes comparativos globales del desempeño por métrica de evaluación, para el nivel de colaboración de 10% y 100%. En este caso, la evaluación comparativa se realiza horizontalmente para poder comparar los modelos en los diferentes escenarios.

Respecto a la puntuación global de la tabla 5.8, para HT con un nivel de colaboración de 100%, el modelo con el mejor desempeño es el obtenido por el modelo predictivo *Naive Bayes*, con una puntuación de 86,84% si se incluyen las métricas de predicción; si se excluyen del análisis, la puntuación para este modelo sigue siendo superior con 87,84%. La segunda mejor puntuación la obtiene la técnica multicriterio FFAHP con 86,2%. Finalmente, *Deep Learning* se ubica en el tercer puesto con una puntuación de 84,93%, respecto a la primera puntuación; el segundo y tercer modelo están por debajo de 2%. Para LT con un nivel de colaboración de 10%, el modelo con mejor desempeño es el obtenido por la técnica multicriterio FFAHP con 81,2%; la segunda mejor puntuación la obtiene el modelo predictivo *Naive Bayes* con 69,26% y, finalmente, *Deep Learning* con 60,15%. Si se comparan los niveles de colaboración de 10% y 100%, se evidencia que *Deep Learning* y *Naive Bayes* mejoran considerablemente al aumentar el nivel de colaboración, con una diferencia en la puntuación de 24,78% para *Deep Learning* y 17,58% para *Naive Bayes*; para FFAHP la diferencia es 5,08%.

Respecto a la puntuación global de la tabla 5.8, para LT con un nivel de colaboración de 100%, el modelo con el mejor desempeño es el obtenido por SAW, con una puntuación de 99,91%; la segunda mejor puntuación la obtiene VIKOR con 89,97%. En el tercer puesto con una puntuación de 89,97% se ubica VIKOR —respecto a la primera puntuación, el segundo y tercer modelo están por debajo del 10%—. Para LT con un nivel de colaboración de 10%, el modelo con el mejor desempeño es el obtenido por SAW con 72,98%, la segunda mejor puntuación la obtiene VIKOR con 71,54% y, finalmente, TOPSIS con 70,71%. Si se comparan los niveles de colaboración de 10% y 100%, se evidencia que SAW, TOPSIS y VIKOR mejoran considerablemente al aumentar el nivel de colaboración, con una diferencia en la puntuación de 26,93% para SAW, 19,26% para TOPSIS y 18,51% para VIKOR.

Para la evaluación del módulo multiusuario se utilizan los modelos no predictivos y predictivos de mayor puntuación para cada nivel de tráfico. Para el tráfico HT se utiliza *Deep Learning*, el modelo predictivo *Naive Bayes* y las técnicas multicriterio FFAHP, SAW, TOPSIS, VIKOR. Se implementa en modo convencional y real para 1, 2, 4, 6, 8 y 10 usuarios. Como métrica de evaluación se utiliza: AAH. Los resultados de la evaluación comparativa de acuerdo con el tipo de simulación (real y convencional) y al número de usuarios es presentado en la tabla 5.9. Como se identifica, conforme aumenta el número de usuarios el desempeño de cada uno de los modelos disminuye; evidentemente, las oportunidades espectrales serán menores y más difíciles de ubicar.

Según la puntuación obtenida en la tabla 5.9 para HT, en modo convencional, el mejor desempeño es *Naive Bayes*, con una puntuación del 96,25% seguido de *Deep Learning*, TOPSIS, FFAHP, SAW y VIKOR. La diferencia promedio de cada modelo con respecto a *Naive Bayes* es de 13,65%, con excepción del modelo con el más bajo desempeño que es VIKOR, donde la diferencia es de 23,12%. Para el modo real *Naive Bayes* continúa siendo el modelo con mejor desempeño, sin embargo, se presenta variación respecto a la puntuación de las demás técnicas; *Deep Learning* baja y se ubica en la cuarta puntuación; TOPSIS, FFAHP, SAW aumentan de posición manteniendo el orden de clasificación, VIKOR permanece en la última posición. La

diferencia promedio de cada modelo con respecto a *Naive Bayes* es 17,48 %, con excepción de *Deep Learning* y VIKOR, donde la diferencia promedio es de 22,7 %.

De acuerdo con la puntuación obtenida en la tabla 5.9 para LT, en modo convencional, el mejor desempeño lo obtienen las técnicas multicriterio. A diferencia de HT, *Deep Learning* y el modelo predictivo *Naive Bayes* no se ubican en los primeros lugares, de igual forma. Respecto a las técnicas multicriterio, SAW, VIKOR y TOPSIS obtienen las mayores puntuaciones, mientras que FFAHP se ubica en la última posición de estas cuatro técnicas. El mejor desempeño es SAW, con una puntuación de 98,75 % seguido de TOPSIS y VIKOR con 96,86 % y 95,82 %, respectivamente; FFAHP con 76,57 %. Las puntuaciones más bajas son para *Naive Bayes* y *Deep Learning* por debajo de 17 %; la diferencia de cada modelo con respecto a SAW está por debajo de 3 % para TOPSIS y VIKOR; para FFAHP es de 22,18 %, para *Naive Bayes* de 75,46 % y para *Deep Learning* de 78,92 %. Para el modo real el comportamiento es proporcional, la única diferencia está en función de la segunda y tercera posición; para este caso, VIKOR adquiere el segundo mejor rendimiento y TOPSIS baja a la tercera posición, *Deep Learning* y *Naive Bayes* se mantienen en la quinta y sexta posición. El mejor desempeño es SAW, con una puntuación de 93,08 % seguido VIKOR y TOPSIS con 87,61 % y 82,93 %, respectivamente; FFAHP con 69,02 %. Las puntuaciones más bajas son para *Naive Bayes* y *Deep Learning* con puntuaciones debajo de 20 %; la diferencia de cada modelo con respecto a SAW está por debajo de 20 % para las técnicas multicriterio y de 75,46 % y 78,92 % para el modelo predictivo y *Deep Learning*, respectivamente.

La tabla 5.11 presenta la evaluación comparativa de acuerdo con el número de *handoff* para HT y el LT, en modo convencional y real. Para HT la mayor puntuación la tiene *Naive Bayes*. Adicionalmente, esta técnica de predicción tiene otra característica relevante frente a las demás: el desempeño aumenta para un modelo realista, como se espera de tal escenario, con usuarios que ingresan y salen en tiempo aleatorio; las métricas de beneficio deberían disminuir, sin embargo, aunque se presenta un incremento en el desempeño, es tan solo de 0,95 %, lo cual permite establecer que esta estrategia no se ve afectada por la incorporación de usuarios aleatorios. Para el

resto de estrategias, la variación del escenario realista respecto al convencional es inferior a 2 % para SAW y TOPSIS, para FFAHP es de 3,52 % y, finalmente, la mayor variación la tiene *Deep Learning* con 7,96 %. En LT las mejores puntuaciones son para las técnicas multicriterio SAW, VIKOR, TOPSIS y FFAHP con 95,92 %, 91,74 %, 89,9 % y 72,8 %, respectivamente. *Deep Learning* y *Naive Bayes* obtienen puntuaciones debajo de 20 % respecto a las variaciones del escenario realista frente al convencional; la mayor variación se presenta en las técnicas multicriterio: 13,93 % para TOPSIS, 8,25 % para VIKOR, 7,55 % para FFAHP y 5,67 % para SAW, las variaciones de *Deep Learning* y *Naive Bayes* están por debajo de 1 %, aunque al igual que en HT, *Naive Bayes* presenta un incremento en el desempeño.

De acuerdo con la métrica de costo acumulativa analizada para diferentes modelos de toma de decisiones —durante nueve minutos de transmisión, en modo convencional y real—, se presenta una disminución en el desempeño de la técnica multicriterio en términos de aumento del número de usuarios: el mejor desempeño con el menor número de *handoff* acumulados es para el escenario con 1 SU, y el desempeño más bajo con el mayor número de *handoff* acumulados es para el escenario con 10 SU. Para escenarios intermedios, durante los primeros tres minutos se presentan variaciones en el orden de desempeño, después del tercer minuto, los escenarios con el mayor incremento promedio del número de *handoff* son los rangos de 2 SU a 5 SU.

El desempeño en modo real es menor al modo convencional, la incorporación de usuarios aleatorios reduce las oportunidades espectrales y por tanto son más difíciles de ubicar. Respecto a los modelos multicriterio implementados para la toma de decisiones, se evidencia que conforme aumenta el número de usuarios el desempeño de las técnicas de toma de decisiones disminuye. En general, TOPSIS proporciona las mejores métricas con los niveles más bajos de *handoff* totales, el mejor indicador se obtiene para el escenario con 1 SU.

7. Conclusiones

7.1 Generales

La presente investigación desarrolla un modelo de asignación espectral multiusuario para redes de radio cognitiva descentralizadas. Para la asignación del espectro se implementan cuatro módulos: el módulo colaborativo, el módulo multiusuario, el módulo predictivo y el módulo *Deep Learning*. El módulo colaborativo es una estructura bidireccional de información; el módulo multiusuario gestiona el acceso de múltiples usuarios en dos tipos de modos: convencional y real; el módulo predictivo analiza aplicaciones con sensibilidad alta al retardo y, finalmente, el módulo *Deep Learning* extrae de una red neuronal convolucional las características de las oportunidades espectrales. El modelo propuesto, selecciona de forma dinámica e inteligente la oportunidad espectral con base en los criterios: AP del canal, tiempo estimado de disponibilidad del canal, SINR y BW. La validación del desempeño del modelo propuesto se realizó por medio de datos reales de ocupación espectral capturados en experimentos realizados en la banda 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.

De acuerdo con los resultados de los modelos no predictivos, *Deep Learning* presenta un alto desempeño (el segundo mejor, 1 % por debajo de FFAHP) para los niveles de tráfico alto y un bajo desempeño (el peor) para los niveles de tráfico bajo. Su desempeño en el módulo colaborativo es congruente para los niveles de tráfico alto, evidenciando un buen rendimiento —alrededor de 85 % a tan solo 1 % de FFAHP y 2 % de *Naive Bayes*—. Aunque era

lógico obtener los mejores resultados para niveles de colaboración completa (100%), dado que al tener mayor información se toman mejores decisiones, es significativo observar que con una reducción de 30% en el nivel de colaboración, los resultados en la toma de decisiones se reducen tan solo 9% para el caso de *Naive Bayes* y 15% para *Deep Learning*. Lo anterior permite ajustar el nivel de procesamiento sin sacrificar mucho rendimiento. Para los niveles de tráfico bajo, SAW logra un rendimiento excepcional de casi 100% con 100% de colaboración, reduciéndose en 15% al caer la colaboración a 70%; mientras que TOPSIS se mantiene más estable al pasar de 90% de rendimiento con 100% de colaboración a 85% con 70% de colaboración. Lo anterior permite inferir que a mayor número de oportunidades espectrales mejor desempeño por parte de los modelos de asignación espectral; este mayor número de oportunidades espectrales permite una mayor flexibilidad a la hora de balancear el rendimiento y costo computacional.

Con respecto al módulo multiusuario se pudo evidenciar que al aumentar el número de usuarios el desempeño de cada uno de los modelos disminuye. *Naive Bayes* responde muy bien al tráfico multiusuario, *Deep Learning* no se ve afectado por escenarios realistas y las técnicas multicriterio FFAHP, SAW, TOPSIS y VIKOR presentan buen rendimiento para escenarios con tráficos bajos. También es interesante observar como en los niveles de tráfico alto el rendimiento de las estrategias evaluadas se reduce alrededor de 25% al incorporar usuarios aleatorios, mientras que para tráfico bajo el rendimiento solo se ve afectado alrededor de 12% en el mismo escenario de usuarios aleatorios. Lo anterior evidencia la importancia de realizar simulaciones en entornos más próximos a la realidad, ya que los resultados se pueden ver afectados con magnitudes significativas. Ahora, teniendo solo en cuenta la cantidad de usuarios simultáneos se evidencia que, en efecto, a mayor número de usuarios menor nivel de desempeño; sin embargo, la reducción en este caso es mejor a la observada para el caso de usuarios aleatorios, para tráfico alto es tan solo de 10% y para tráfico bajo no se evidencia afectación alguna. En general, cada estrategia se desempeña de forma satisfactoria en determinados escenarios; para mejorar el rendimiento en el acceso multiusuarios, una propuesta interesante sería combinar las estrategias implementadas o desarrollar un multimodelo con un módulo adaptativo que seleccione la

mejor estrategia con base en el escenario y aplicación que se esté ejecutando en dicho momento.

Con respecto al nivel de interferencia para la estrategia *Naive Bayes* —la única predictiva— en los resultados presentados, se evidencia que a mayor número de usuarios simultáneos mayor nivel de interferencia, llegando a aumentar alrededor de 20 % para el caso de diez usuarios simultáneos. Lo anterior hace más relevante el tema de la interferencia a la hora de seleccionar una estrategia, sobre todo en aplicaciones sensibles al retardo y la calidad del canal como el caso de las comunicaciones de voz.

Con respecto al módulo *Deep Learning*, se utiliza como técnica de extracción de características para el volumen de datos obtenidos a partir de las mediciones realizadas. Los resultados de las múltiples simulaciones en los diferentes escenarios permiten afirmar que el modelo propuesto tiene un buen rendimiento en redes de alto tráfico, ubicándolo como la segunda mejor estrategia, con una diferencia de 1,23 % respecto al modelo con mejor comportamiento; para ambientes colaborativos se evidencia una mejoría de acuerdo con los niveles de colaboración establecidos. En promedio, las diferencias con respecto al nivel colaboración anterior obtenido fue de 8,26 %; finalmente, los escenarios multiusuarios no se ven afectados por la inclusión de usuarios aleatorios en tiempo aleatorios. Sin embargo, cada una de las métricas descritas previamente son tomadas de redes con tráfico alto; el módulo *Deep Learning* no es una buena estrategia para análisis de escenarios con tráficos bajos.

7.2 Contribuciones de la investigación

- Diseño y desarrollo de un modelo de asignación espectral multiusuario para mejorar el desempeño de las redes de radio cognitiva descentralizadas.
- Diseño y desarrollo de un módulo colaborativo para el intercambio de información entre SU con el objetivo de realizar una asignación espectral multiusuario inteligente.
- Diseño y desarrollo de un módulo multiusuario para el acceso simultáneo de varios SU a las oportunidades espectrales.

- Diseño y desarrollo de un módulo predictivo que reduce el nivel de interferencia entre los SU y los PU.
- 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 desarrollados, en una red GSM.
- Evaluación y validación de los algoritmos desarrollados, con dos niveles de tráfico de PU: alto y bajo.
- Evaluación y validación de los algoritmos desarrollados, en cuatro diferentes escenarios de evaluación: GSM-LT-Convencional, GSM-HT-Convencional, GSM-LT-Real, GSM-HT-Real.
- Evaluación y validación de los algoritmos desarrollados bajo ocho métricas de evaluación: AAH, AAFH, ABW, AAD, AAT, AAIH, AAUH y AAPH.
- Determinación de cuatro criterios de decisión, seleccionados cuidadosamente, para elegir la mejor oportunidad espectral. Todos los algoritmos desarrollados trabajaron con los mismos cuatro criterios. Cada uno es 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 asignación espectral multiusuario para DCRN, basada en datos de ocupación espectral reales. La herramienta permite modificar varios parámetros de interés para analizar el comportamiento del desempeño de cada algoritmo bajo diferentes situaciones, entre los que se destaca el nivel de colaboración y el número de SU simultáneos, denominada “MultiColl-DCRN”.

7.3 Investigación futura

De acuerdo con los resultados obtenidos en el modelo de asignación espectral concluimos que no hay un algoritmo que se desempeñe de forma excelente en todas las métricas de evaluación y para todos los escenarios de simulación (nivel de tráfico, tipo de aplicación, tipo de red). Cada algoritmo se puede desempeñar de forma satisfactoria en determinadas métricas de

evaluación y para ciertos escenarios, por lo que una propuesta interesante es incluir en el modelo desarrollado un módulo de adaptación que genere recomendaciones o modificaciones de acuerdo con los requerimientos de la aplicación que se esté desarrollando durante la comunicación del usuario secundario.

Como trabajo futuro se proponen tres directrices. La primera consiste en realizar un módulo adaptativo que seleccione el mejor modelo de selección espectral de acuerdo con los requerimientos de la aplicación en curso. La segunda consiste en una evaluación y validación de los algoritmos de aprendizaje autónomo más relevantes en la literatura actual, por ejemplo, el uso de SVM para realizar procesos de clasificación y aprendizaje por refuerzo para desarrollar la parte de adaptación. La tercera consiste en realizar una evaluación y validación con equipos de radio cognitiva que emulen una red de radio cognitiva en lugar de simulaciones, con datos de ocupación espectral reales.

Referencias

- 3GPP. (2011). *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, Issue July).
- Abass, A. A. A., Mandayam, N. B. y Gajic, Z. (2017). An evolutionary game model for threat revocation in ephemeral networks. *2017 51st Annual Conference on Information Sciences and Systems (CISS)*, 1-5. <https://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(2015), 174. <https://doi.org/10.1186/s13638-015-0381-7>
- 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 and Tutorials*, 16(2), 776-811. <https://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. <https://doi.org/10.1109/COMST.2014.2363082>
- Akter, L., Natarajan, B. y Scoglio, C. (2008). Modeling and forecasting secondary user activity in cognitive radio networks. *17th International Conference on Computer Communications and Networks*. <https://doi.org/10.1109/ICCCN.2008.ECP.50>
- Akyildiz, I. F. y Li, Y. (2006). OCRA: OFDM-based cognitive radio networks. En *Broadband and Wireless Networking Laboratory Technical Report*.

- Akyildiz, I. F., Lee, W.-Y. y Chowdhury, K. R. (2009). CRAHNs: Cognitive radio ad hoc networks. *Ad Hoc Networks*, 7(5), 810-836. <https://doi.org/10.1016/j.adhoc.2009.01.001>
- 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. <https://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. *Communications Magazine, IEEE*, 46(4), 40-48. <https://doi.org/10.1109/MCOM.2008.4481339>
- Akyildiz, I. F., Lo, B. F. y Balakrishnan, R. (2011). Cooperative spectrum sensing in cognitive radio networks: A survey. *Physical Communication*, 4(1), 40-62. <https://doi.org/10.1016/j.phycom.2010.12.003>
- Al-Amidie, M., Al-Asadi, A., Micheas, A. C. y Islam, N. E. (2019). Spectrum sensing based on Bayesian generalized likelihood ratio for cognitive radio systems with multiple antennas. *IET Communications*, 13(3), 305-311. <https://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 and Tutorials*, 19(2), 1277-1304. <https://doi.org/10.1109/COMST.2016.2631080>
- Alias, D. M. y Ragesh, G. K. (2016). Cognitive radio networks: A survey. *Proceedings of the 2016 IEEE International Conference on Wireless Communications, Signal Processing and Networking, WiSPNET 2016*, 1981-1986. <https://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. *IEEE Symposium on New Frontiers in Dynamic Spectrum*, 1-10. <https://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. <https://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. *Internatonal Conference on Computer Communications and Networks*, 1-6.
- 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. <https://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. <https://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. <https://doi.org/10.1109/SURV.2011.021111.00064>
- Baran, P. (1964). On distributed communications networks. *IEEE Transactions on Communications*, 12(1), 1-9. <https://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. <https://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 and Tutorials*. <https://doi.org/10.1109/SURV.2012.100412.00017>
- Bolstad, W. M. (2007). Introduction to Bayesian statistics. En *Book*. <https://doi.org/10.1080/10543406.2011.589638>
- Boorstin, J. (2016). An internet of things that will number ten billions. *CNBS*.
- Brik, V., Rozner, E., Banerjee, S. y Bahl, P. (2005). DSAP: A protocol for coordinated spectrum access. *2005 1st IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks, DySPAN 2005*, 611-614. <https://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), 1550147717738192. <https://doi.org/10.1177/1550147717738192>
- 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. <https://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 health-care industry. *Expert Systems with Applications*, 39(3), 2341-2354.
- Byun, S. S., Balasingham, I. y Liang, X. (2008). Dynamic spectrum allocation in wireless cognitive sensor networks: Improving fairness and energy efficiency. *IEEE Vehicular Technology Conference*. <https://doi.org/10.1109/VETECF.2008.299>
- Cao, L. y Zheng, H. (2005). Distributed spectrum allocation via local bargaining. *2005 Second Annual IEEE Communications Society Conference on Sensor and AdHoc Communications and Networks, SECON 2005, 2005*, 475-486. <https://doi.org/10.1109/SAHCN.2005.1557100>
- Cárdenas, M., Díaz, M., Pineda, U., Arce, A. y Stevens, E. (2016). On spectrum occupancy measurements at 2.4 GHz ISM band for cognitive radio applications. *International Conference on Electronics, Communications and Computers*, 25-31. <https://doi.org/10.1109/CONIELECOMP.2016.7438547>
- Chang, D.-Y. (1996). Applications of the extent analysis method on fuzzy AHP. *European Journal of Operational Research*, 95(3), 649-655. [https://doi.org/10.1016/0377-2217\(95\)00300-2](https://doi.org/10.1016/0377-2217(95)00300-2)
- Chen, Y. y Hee-Seok, O. (2016). A Survey of measurement-based spectrum occupancy modeling for cognitive radios. *IEEE Communications Surveys & Tutorials*, 18(1), 848-859. <https://doi.org/10.1109/COMST.2014.2364316>
- Chen, D., Zhang, Q. y Jia, W. (2008). Aggregation aware spectrum assignment in cognitive adhoc networks. *International Conference on Cognitive Radio Oriented Wireless Networks and Communications*. <https://doi.org/10.1109/CROWNCOM.2008.4562548>
- Chen, T., Zhang, H., Maggio, G. M. y Chlamtac, I. (2007). CogMesh: A cluster-based cognitive radio network. *IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks*, 168-178. <https://doi.org/10.1109/DYSPAN.2007.29>

- Cheng, X. y Jiang, M. (2011). Cognitive radio spectrum assignment based on artificial bee colony algorithm. *IEEE International Conference on Communication Technology*, 161-164. <https://doi.org/10.1109/ICCT.2011.6157854>
- Cheng, Y. C., Wu, E. H. y Chen, G. H. (2016). A decentralized MAC protocol for unfairness problems in coexistent heterogeneous cognitive radio networks scenarios with collision-based primary users. *IEEE Systems Journal*, 10(1), 346-357. <https://doi.org/10.1109/JSYST.2015.2431715>
- 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.
- 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), 576-587. <https://doi.org/10.1109/JSAC.2007.070408>
- Choudhary, D. y Shankar, R. (2012). A STEEP-fuzzy AHP-TOPSIS framework for evaluation and selection of thermal power plant location: A case study from India. *Energy*, 42(1), 510-521.
- Christian, I., Moh, S., Chung, I. y Lee, J. (2012). Spectrum mobility in cognitive radio networks. *IEEE Communications Magazine*, 50(6), 114-121. <https://doi.org/10.1109/MCOM.2012.6211495>
- CISCO. (2021). Cisco Visual Networking Index: Global Mobile Data Traffic Forecast Update. In *CISCO*. <https://www.cisco.com/c/en/us/solutions/collateral/service-provider/visual-networking-index-vni/white-paper-c11-741490.html>
- 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* [Master's Dissertation, Universidad Nacional de Colombia].
- 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. *Specialist Meeting on Microwave Radiometry and Remote Sensing of the Environment (MicroRad)*, 1-5. <https://doi.org/10.1109/MICRORAD.2018.8430720>

- Csurgai-Horvath, L. y Bito, J. (2011). Primary and secondary user activity models for cognitive wireless network. *International Conference on Telecommunications*, 301-306.
- 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. <https://doi.org/10.1109/TVT.2015.2440412>
- Dadios, E. P. (2012). *Fuzzy logic: Algorithms, techniques and implementations*. TechOpen.
- 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. *2014 11th International Symposium on Wireless Communications Systems, ISWCS 2014—Proceedings*, 271-275. <https://doi.org/10.1109/ISWCS.2014.6933360>
- Darak, Sumit 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: A Review Journal*, 37(1), 13-23. <https://doi.org/10.1016/j.dsp.2014.12.001>
- Darak, Sumit 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. <https://doi.org/10.1016/j.dsp.2016.08.014>
- Del-Ser, J., Matinmikko, M., Gil-López, S. y Mustonen, M. (2010). A novel harmony search based spectrum allocation technique for cognitive radio networks. *International Symposium on Wireless Communication Systems*, 233-237. <https://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. <https://doi.org/10.1109/TLA.2016.7437200>
- 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). <https://doi.org/10.1002/dac.3726>
- Dhamodharavadhani, S. (2015). A survey on clustering based routing protocols in Mobile ad hoc networks. *2015 International Conference*

- on *Soft-Computing and Networks Security (ICSNS)*, 1-6. <https://doi.org/10.1109/ICSNS.2015.7292426>
- Digham, F. F., Alouini, M. y Simon, M. K. (2007). On the energy detection of unknown signals over fading channels. *IEEE Transactions on Communications*, 55(1), 21-24. <https://doi.org/10.1109/TCOMM.2006.887483>
- 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. <https://doi.org/10.1109/TVT.2010.2045403>
- 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. <https://doi.org/10.4316/aece.2011.03002>
- Federal Communications Commission. (2003). Notice of proposed rulemaking and order. *Mexico DF: Report ET Docket No. 03, 332*.
- Ferber, J. (1999). *Multi-agent systems: An introduction to distributed artificial intelligence*. Addison-Wesley.
- Fraser, A. M. (2008). *Hidden Markov models and dynamical systems*. SIAM.
- Fudenberg, D. y Tirole, J. (1991). *Game theory*. MIT Press.
- Gallardo, J. R., Pineda, U. y Stevens, E. (2009). VIKOR method for vertical handoff decision in beyond 3G wireless networks. *International Conference on Electrical Engineering, Computing Science and Automatic Control*. <https://doi.org/10.1109/ICEEE.2009.5393320>
- Gavrilovska, L., Atanasovski, V., Macaluso, I. y Dasilva, L. A. (2013). Learning and reasoning in cognitive radio networks. *IEEE Communications Surveys and Tutorials*, 15(4), 1761-1777. <https://doi.org/10.1109/SURV.2013.030713.00113>
- Ghanem, M., Sabaei, M. y Dehghan, M. (2017). A novel model for implicit cooperation between primary users and secondary users in cognitive radio-cooperative communication systems. *International Journal of Communication Systems*, e3524, 1-22. <https://doi.org/10.1002/dac.3524>
- Giupponi, L. y Pérez-Neira, A. I. (2008). Fuzzy-based spectrum handoff in cognitive radio networks. *International Conference on Cognitive Radio Oriented Wireless Networks and Communications*. <https://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. <https://doi.org/10.1023/A:1022602019183>
- Goswami, M. M. (2017). AODV based adaptive distributed hybrid multipath routing for mobile AdHoc network. *2017 International Conference on Inventive Communication and Computational Technologies (ICICCT)*, 410-414. <https://doi.org/10.1109/ICICCT.2017.7975230>
- Green, K. C., Armstrong, J. S. y Graefe, A. (2007). Methods to elicit forecasts from groups: Delphi and prediction markets compared. *Social Science Research Network*, (8), 17-20.
- Han, J., Kamber, M. y Pei, J. (2012). *Data mining: Concepts and techniques*. Elsevier.
- 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. <https://doi.org/10.1109/JPROC.2014.2306255>
- Haykin, S. (1998). *Neural networks: A comprehensive foundation* (2.^a ed.). Prentice Hall PTR.
- Haykin, S. (2005). Cognitive radio: Brain-empowered wireless communications. *IEEE Journal on Selected Areas in Communications*, 23(2), 201-220.
- 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. <https://doi.org/10.1109/TVT.2010.2043968>
- Hernández-Guillén, J., Rodríguez-Colina, E., Marcelín-Jiménez, R. y Pascoe-Chalke, M. (2012). CRUAM-MAC: A novel cognitive radio MAC protocol for dynamic spectrum access. *IEEE Latin-America Conference on Communications*, 1-6. <https://doi.org/10.1109/LATINCOM.2012.6505997>
- Hernández-Sampieri, R., Fernández-Collado, C. y Baptista, P. (2006). *Metodología de la investigación*. McGraw-Hill.
- Hernández, C., Giral, D. y Márquez, H. (2017). Evolutive algorithm for spectral handoff prediction in cognitive wireless networks. *HIKARI Ltd*, 10(14), 673-689. <https://doi.org/10.12988/ces.2017.7766>

- Hernández, C., Giral, D. y Páez, I. (2015a). Benchmarking of the performance of spectrum mobility models in cognitive radio networks. *IJAER*, 10(21), 42189-42197.
- 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.
- Hernández, C., Giral, D. y Salgado, C. (2020). Failed handoffs in collaborative Wi-Fi networks. *Telkommnika*, 18(2), 669-675.
- Hernández, C., Giral, D. y Santa, F. (2015c). MCDM Spectrum Handover Models for Cognitive Wireless Networks. *World Academy of Science, Engineering and Technology*, 9(10), 679-682.
- Hernández, C., Márquez, H. y Giral, D. (2017). Comparative evaluation of prediction models for forecasting spectral opportunities. *IJET*, 9(5), 3775-3782. <https://doi.org/10.21817/ijet/2017/v9i5/170905055>
- Hernández, C., Pedraza, L. F. y Martínez, F. H. (2016a). Algoritmos para asignación de espectro en redes de radio cognitiva. *Tecnura*, 20(48), 69-88. <https://doi.org/10.14483/udistrital.jour.tecnura.2016.2.a05>
- Hernández, C., Pedraza, L. F., Páez, I. y Rodríguez, E. (2015d). Análisis de la movilidad espectral en redes de radio cognitiva. *Información Tecnológica*, 26(6), 169-186.
- Hernández, C., Pedraza, L. F. y Rodríguez, E. (2016b). Fuzzy feedback algorithm for the spectral handoff in cognitive radio networks. *Revista Facultad de Ingeniería de la Universidad de Antioquia*.
- 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.
- Hernández, C., Salgado, C., López, H. y Rodríguez, E. (2015e). Multivariable algorithm for dynamic channel selection in cognitive radio networks. *EURASIP Journal on Wireless Communications and Networking*, 2015(1), 216. <https://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 Universidad de Antioquia*, 67, 52-62. <https://doi.org/http://doi.org/10.1186/s13638-015-0445-8>

- Hernández, C., Vásquez, H. y Páez, I. (2015f). Proactive spectrum handoff model with time series prediction. *International Journal of Applied Engineering Research (IJAER)*, 10(21), 42259-42264.
- Hoven, N., Tandra, R. y Sahai, A. (2005). Some fundamental limits on cognitive radio. *Wireless Foundations EECS, Univ. of California, Berkeley*.
- 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. In *Research Report VTT-R-02219-08*.
- Hu, F., Chen, B., Zhai, X. y Zhu, C. (2016). Channel selection policy in Multi-SU and Multi-PU cognitive radio networks with energy harvesting for internet of everything. *Mobile Information Systems*, 2016, 6024928. <https://doi.org/10.1155/2016/6024928>
- Huang, X., Han, T. y Ansari, N. (2014). On green energy powered cognitive radio networks. *CoRR*, abs/1405.5. <http://arxiv.org/abs/1405.5747>
- Hübner, R. (2007). *Strategic supply chain management in process industries: An application to specialty chemicals production network design* (vol. 594). Springer Science & Business Media.
- IEEE. (2008). IEEE standard definitions and concepts for dynamic spectrum access: terminology relating to emerging wireless networks, system functionality, and spectrum management. En *IEEE Std 1900.1-2008* (pp. 1-62). <https://doi.org/10.1109/IEEESTD.2008.4633734>
- IEEE. (2008) Standards Coordinating Committee 41 on Dynamic Spectrum. IEEE standard definitions and concepts for dynamic spectrum access: terminology relating to emerging wireless networks, system functionality, and spectrum management. En *IEEE Standard 1900.1-2008*. <https://doi.org/10.1109/IEEESTD.2008.4633734>
- 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>
- 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. <https://doi.org/10.1109/MCOM.2009.5183473>
- Jayaweera, S. y Christodoulou, C. (2011). *Radiobots: Architecture*,

algorithms and realtime reconfigurable antenna designs for autonomous, self-learning future cognitive radios.

- 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. <https://doi.org/10.1109/MCOM.2007.358854>
- Jiang, C, Chen, Y. y Liu, K. J. R. (2014a). Multi-channel sensing and access game: Bayesian social learning with negative network externality. *IEEE Transactions on Wireless Communications*, 13(4), 2176-2188. <https://doi.org/10.1109/TWC.2014.022014.131209>
- Jiang, C, Chen, Y. y Liu, K. J. R. (2014b). Sequential multi-channel access game in distributed cognitive radio networks. *2014 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, 1247-1251. <https://doi.org/10.1109/GlobalSIP.2014.7032322>
- 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. <https://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. <https://doi.org/10.1109/TCOMM.2015.2480846>
- Kanodia, V., Sabharwal, A. y Knightly, E. (2004). MOAR: A multi-channel opportunistic auto-rate media access protocol for ad hoc networks. *International Conference on Broadband Networks*, 600-610.
- Kaur, A., Kaur, A. y Sharma, S. (2018a). Cognitive decision engine design for CR based IoTs using differential evolution and bat algorithm. *2018 5th International Conference on Signal Processing and Integrated Networks (SPIN)*, 130-135. <https://doi.org/10.1109/SPIN.2018.8474273>
- Kaur, A., Kaur, A. y Sharma, S. (2018b). PSO based multiobjective optimization for parameter adaptation in CR based IoTs. *2018 4th International Conference on Computational Intelligence & Communication Technology (CICT)*, 1-7. <https://doi.org/10.1109/CICT.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.

- Kibria, M. R., Jamalipour, A. y Mirchandani, V. (2005). A location aware three-step vertical handoff scheme for 4G/B3G networks. *Global Telecommunications Conference*, 5, 2752-2756. <https://doi.org/10.1109/GLOCOM.2005.1578260>
- 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. <https://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. *IFIP Wireless Days*. <https://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. *IEEE Military Communications Conference*. <https://doi.org/10.1109/MILCOM.2008.4753398>
- Kongsiriwattana, W. y Gardner-Stephen, P. (2017). *Eliminating the high standby energy consumption of adhoc Wi-Fi*. 2017-Janua, 1-7. <https://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. *Proceedings-IEEE Military Communications Conference MILCOM*, 2005. <https://doi.org/10.1109/MILCOM.2005.1605725>
- Krizhevsky, A., Sutskever, I. y Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 1097-1105.
- 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(Supplement C), 161-188. <https://doi.org/https://doi.org/10.1016/j.jnca.2015.10.008>
- Lahby, M., Leghris, C. y Adib, A. (2011). A hybrid approach for network selection in heterogeneous multi-access environments. *International Conference on New Technologies, Mobility and Security*, 1-5. <https://doi.org/10.1109/NTMS.2011.5720658>

- Lee, W., y Akyildiz, I. F. (2008). Optimal spectrum sensing framework for cognitive radio networks. *IEEE Transactions on Wireless Communications*, 7(10), 3845-3857. <https://doi.org/10.1109/T-WC.2008.070391>
- Lee, W. y Akyildiz, I. F. (2011). A spectrum decision framework for cognitive radio networks. *IEEE Transactions on Mobile Computing*, 10(2). 161-174 <https://doi: 10.1109/TMC.2010.147>.
- Lehtomaki, J. J., Juntti, M., Saarnisaari, H. y Koivu, S. (2005). Threshold setting strategies for a quantized total power radiometer. *IEEE Signal Processing Letters*, 12(11), 796-799. <https://doi.org/10.1109/LSP.2005.855521>
- Lertsinsrubtavee, A. y Malouch, N. (2016). Hybrid spectrum sharing through adaptive spectrum handoff and selection. *IEEE Transactions on Mobile Computing*, 15(11), 2781-2793.
- Li, X. y Zekavat, S. A. (2008). Traffic pattern prediction and performance investigation for cognitive radio systems. *IEEE Wireless Communications and Networking Conference*, 894-899. <https://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. *International Conference on Signal Processing (ICSP)*, 1146-1151. <https://doi.org/10.1109/ICSP.2016.7878007>
- López, D. A., Trujillo, E. R. y Gualdrón, O. E. (2015). Elementos fundamentales que componen la radio cognitiva y asignación de bandas espectrales. *Información Tecnológica*, 26(1), 23-40. <https://doi.org/10.4067/S0718-07642015000100004>
- López, D. L. (2017). *Implementación de un modelo predictor para la toma de decisiones en redes inalámbricas de radio cognitiva* [Universidad Distrital Francisco José de Caldas]. <http://doctoradoingenieria.udistrital.edu.co/index.php/es/investigacion/publicaciones>
- Ma, L., Shen, C. C. y Ryu, B. (2007). Single-radio adaptive channel algorithm for spectrum agile wireless ad hoc networks. *IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks*, 547-558. <https://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. <https://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*. *HIKARI Ltd*, 10(12), 593-605. <https://doi.org/10.12988/ces.2017.7758>
- Martins, L. R. y Andrade, L. H. (2018). Analysis of machine learning algorithms for spectrum decision in cognitive radios. *2018 15th International Symposium on Wireless Communication Systems (ISWCS)*, 1-6. <https://doi.org/10.1109/ISWCS.2018.8491060>
- 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. <https://doi.org/10.1109/SURV.2012.111412.00160>
- 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. <https://doi.org/10.1109/JSAC.2013.131117>
- Matlab. (2015). *Matlab getting started guide*. Matlab.
- Mehbodniya, A., Kaleem, F., Yen, K. K. y Adachi, F. (2012). A fuzzy MADM ranking approach for vertical mobility in next generation hybrid networks. *International Congress on Ultra-Modern Telecommunications and Control Systems and Workshops*, 262-267. <https://doi.org/10.1109/ICUMT.2012.6459676>
- Mir, U., Merghem-Boulahia, L., Esseghir, M. y Gaïti, D. (2011). Dynamic spectrum sharing for cognitive radio networks using multiagent system. *IEEE Conference on Consumer Communications and Networking*, 658-663.
- Miranda, E. (2001). Improving subjective estimates using paired comparisons. *IEEE Software*, 18(1), 87-91. <https://doi.org/10.1109/52.903173>
- Mitola, J. y Maguire, G. Q. (1999). Cognitive radio: making software radios more personal. *IEEE Personal Communications*, 6(4), 13-18. <https://doi.org/10.1109/98.788210>
- Nisan, N., Roughgarden, T., Tardos, E. y Vazirani, V. V. (2007). *Algorithmic game theory* (vol. 1). Cambridge University Press Cambridge.
- Ormond, O., Murphy, J. y Muntean, G. (2006). Utility-based intelligent network selection in beyond 3G systems. *IEEE International*

- Conference on Communications*, 4, 1831-1836. <https://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. <https://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. <https://doi.org/10.1109/LCOMM.2015.2504103>
- Páez, I., Giral, D. y Hernández, C. (2015). Modelo AHP-VIKOR para handoff espectral en redes de radio cognitiva. *Tecnura*, 19(45), 29-39.
- Páez, I., Hernández, C. y Giral, D. (2017). *Modelo adaptativo multivariable de handoff espectral para incrementar el desempeño en redes móviles de radio cognitiva* (1.ª ed.). Editorial UD.
- Pankratev, D. A., Samsonov, A. A. y Stotckaia, A. D. (2019). Wireless data transfer technologies in a decentralized system. *2019 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus)*, 620-623. <https://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. <https://doi.org/10.1016/j.eswa.2013.07.093>
- 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.
- Pedraza, L. F., Hernández, C., Galeano, K., Rodríguez, E. y Páez, I. (2016). *Ocupación espectral y modelo de radio cognitiva para Bogotá* (1.ª ed.). Universidad Distrital Francisco José de Caldas.
- Petrova, M., Mahonen, P. y Osuna, A. (2010). Multi-class classification of analog and digital signals in cognitive radios using Support Vector Machines. *International Symposium on Wireless Communication Systems*, 986-990. <https://doi.org/10.1109/ISWCS.2010.5624500>
- Pham, C., Tran, N. H., Do, C. T., Moon, S. Il y Hong, C. S. (2014). Spectrum handoff model based on hidden Markov model in cognitive radio networks. *International Conference on Information Networking*, 406-411.

- Pla, V., Vidal, J. R., Martínez-Bauset, J. y Guijarro, L. (2010). Modeling and characterization of spectrum white spaces for underlay cognitive radio networks. *IEEE International Conference on Communications*. <https://doi.org/10.1109/ICC.2010.5501788>
- Rahimian, N., Georgiades, 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. <https://doi.org/10.1109/TWC.2013.120213.130658>
- Ramírez, C. y Ramos, V. M. (2013). On the Effectiveness of Multi-criteria Decision Mechanisms for Vertical Handoff. *International Conference on Advanced Information Networking and Applications*, 1157-1164. <https://doi.org/10.1109/AINA.2013.114>
- Ramírez, C. y Ramos, V. M. (2010). Handover vertical: un problema de toma de decisión múltiple. *Congreso Internacional sobre Innovación y Desarrollo Tecnológico*.
- 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(Supplement C), 106-131. <https://doi.org/https://doi.org/10.1016/j.pmcj.2017.07.010>
- 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. <https://doi.org/10.1109/TCDS.2018.2840971>
- Rodríguez, E., Ramírez, P., Carrillo, A. y Ernesto, C. (2011). Multiple attribute dynamic spectrum decision making for cognitive radio networks. *International Conference on Wireless and Optical Communications Networks*, 1-5. <https://doi.org/10.1109/WOCN.2011.5872960>
- Rodríguez, A. B., Ramírez, L. J. y Chahuan, J. (2015). Nueva generación de heurísticas para redes de fibra óptica WDM (Wavelength División Multiplexing) bajo tráfico dinámico. *Información Tecnológica*, 26(5), 135-142.
- 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. <https://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. [https://doi.org/10.1016/0377-2217\(90\)90057-I](https://doi.org/10.1016/0377-2217(90)90057-I)
- 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. <https://doi.org/10.1109/21.97458>
- Salgado, C., Márquez, H. y Gómez, V. (2016a). Técnicas inteligentes en la asignación de espectro dinámica para redes inalámbricas cognitivas. *Revista Tecnura*, 20(49), 133-151. <https://doi.org/10.14483/udistrital.jour.tecnura.2016.3.a09>
- Salgado, C., Mora, S. y Giral, D. (2016b). Collaborative algorithm for the spectrum allocation in distributed cognitive networks. *IJET*, 8(5), 2288-2299. <https://doi.org/10.21817/ijet/2016/v8i5/160805091>
- Song, Q. y Jamalipour, A. (2005). A network selection mechanism for next generation networks. *IEEE International Conference on Communications*, 2, 1418-1422. <https://doi.org/10.1109/ICC.2005.1494578>
- 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. <https://doi.org/10.1109/JSAC.1986.1146402>
- Stevens, E., Martínez, J. D. y Pineda, 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.
- Stevens, E., Gallardo, R., Pineda, U. y Acosta, J. (2012). Application of MADM method VIKOR for vertical handoff in heterogeneous wireless networks. *IEICE Transactions on Communications*, 95(2), 599-602. <https://doi.org/10.1587/transcom.E95.B.599>
- Stevens, 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. <https://doi.org/10.1109/TVT.2007.907072>

- Stevens, E. y Wong, V. W. S. (2006). Comparison between vertical handoff decision algorithms for heterogeneous wireless networks. *IEEE Vehicular Technology Conference*, 2, 947-951. <https://doi.org/10.1109/VETECS.2004.1388970>
- Sutton, R. S. y Barto, A. G. (1998). Reinforcement learning: An introduction. *IEEE Transactions on Neural Networks*, 9(5), 1054. <https://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. *2012 IEEE Symposium on Wireless Technology and Applications (ISWTA)*, 177-181. <https://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(Supplement C), 139-148. <https://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 modeling. *Wireless Conference Sustainable Wireless Technologies*, 1-6.
- Tanino, T., Tanaka, T. e Inuiguchi, M. (2003). *Multi-objective programming and goal programming: Theory and applications* (vol. 21). Springer Science & Business Media.
- Thakur, P., Kumar, A., Pandit, S., Singh, G. y Satashia, S. N. (2017). Spectrum mobility in cognitive radio network using spectrum prediction and monitoring techniques. *Physical Communication*, (24), 1-8. <https://doi.org/10.1016/j.phycom.2017.04.005>
- Tragos, E., Zeadally, S., Fragkiadakis, A. y Siris, V. (2013). Spectrum assignment in cognitive radio networks: A comprehensive survey. *IEEE Communications Surveys and Tutorials*, 15(3), 1108-1135. <https://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. *International Conference on New Technologies, Mobility and Security*, 1-5. <https://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. <https://doi.org/10.1007/s11277-018-6075-9>
- Tsiropoulos, G., Dobre, O., Ahmed, M. y Baddour, K. (2016). Radio resource allocation techniques for efficient spectrum access in cognitive radio networks. *IEEE Communications Surveys & Tutorials*, 18(1), 824-847. <https://doi.org/10.1109/COMST.2014.2362796>
- Valenta, V., Maršálek, R., Baudoin, G., Villegas, M., Suárez, M. y Robert, F. (2010). Survey on spectrum utilization in Europe: Measurements, analyses and observations. *International Conference on Cognitive Radio Oriented Wireless Networks*, 230126, 2-6. <https://doi.org/10.4108/ICST.CROWNCOM2010.9220>
- 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. <https://doi.org/https://doi.org/10.1016/j.jnca.2018.07.006>
- 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. <https://doi.org/10.1109/JSTSP.2010.2093210>
- Wang, C., Chen, Y. y Liu, K. J. R. (2017). Hidden Chinese restaurant game: Grand information extraction for stochastic network learning. *IEEE Transactions on Signal and Information Processing over Networks*, 3(2), 330-345. <https://doi.org/10.1109/TSIPN.2017.2682799>
- Wang, J., Ghosh, M. y Challapali, K. (2011). Emerging cognitive radio applications: A survey. *IEEE Communications Magazine*. <https://doi.org/10.1109/MCOM.2011.5723803>
- 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(Supplement C), 22-36. <https://doi.org/https://doi.org/10.1016/j.comcom.2015.09.016>
- Wang, X., Wong, A. y Ho, P.-H. (2010). Dynamically optimized spatiotemporal prioritization for spectrum sensing in cooperative cognitive radio. *Wireless Networks*, 16(4), 889-901. <https://doi.org/10.1007/s11276-009-0175-0>

- 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. <https://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. *International Conference on Natural Computation*, 5, 197-201. <https://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. *IEEE Symposium on New Frontiers in Dynamic Spectrum Access Networks*, 401-411. <https://doi.org/10.1109/DYSPAN.2008.48>
- Woods, W. A. (1986). Important issues in knowledge representation. *Proceedings of the IEEE*, 74(10), 1322-1334.
- Wooldridge, M. (2009). *An introduction to multiagent systems*. John Wiley & Sons.
- Wu, Y., Yang, Q., Liu, X. y Kwak, K. (2016). Delay-Constrained optimal transmission with proactive spectrum handoff in cognitive radio networks. *IEEE Transactions on Communications*. <https://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>
- Xu, G. y Lu, Y. (2006). Channel and modulation selection based on support vector machines for cognitive radio. *International Conference on Wireless Communications, Networking and Mobile Computing*, 4-7. <https://doi.org/10.1109/WiCOM.2006.181>
- Yang, S. F. y Wu, J. S. (2008). A IEEE 802.21 handover design with QoS provision across WLAN and WMAN. *International Conference on Communications, Circuits and Systems Proceedings*, 548-552. <https://doi.org/10.1109/ICCCAS.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. <https://doi.org/10.1016/j.comcom.2013.06.005>

- 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. <https://doi.org/10.1109/CC.2013.6723882>
- Yonghui, C. (2010). Study of the bayesian networks. *International Conference on E-Health Networking, Digital Ecosystems and Technologies*, 1, 172-174.
- Yoon, K. P. y Hwang, C.-L. (1995). *Multiple attribute decision making: An introduction* (vol. 104). Sage publications.
- Youssef, M. E., Nasim, S., Wasi, S., Khisal, U. y Khan, A. (2018). Efficient cooperative spectrum detection in cognitive radio systems using wavelet fusion. *International Conference on Computing, Electronic and Electrical Engineering*. <https://doi.org/10.1109/ICECUBE.2018.8610981>
- Yu, X. y Xue, W. (2018). *Joint Spectrum Allocation and Power Control for Cognitive Radio Networks Based on Potential Game* BT–2018 International Symposium on Networks, Computers and Communications, ISNCC 2018, June 19, 2018–June 21, 2018. dbw Communication; iDirect; Nextant Applications a. <https://doi.org/10.1109/ISNCC.2018.8530881>
- Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3), 338-353. [https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://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.
- Zhang, B., Chen, Y., Wang, C. y Liu, K. J. R. (2012). Learning and decision making with negative externality for opportunistic spectrum access. *2012 IEEE Global Communications Conference (GLOBECOM)*, 1404-1409. <https://doi.org/10.1109/GLOCOM.2012.6503310>
- 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. <https://doi.org/10.1109/TWC.2016.2628821>
- Zhang, W. (2004). Handover decision using fuzzy MADM in heterogeneous networks. *IEEE Wireless Communications and Networking Conference*, 2, 653-658. <https://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. *IEEE International Conference on Acoustics, Speech and Signal Processing*, 3661-3665.
- 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. <https://doi.org/10.1109/JPROC.2009.2013017>
- Zheng, H. y Cao, L. (2005). Device-centric spectrum management. *IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks*, 56-65. <https://doi.org/10.1109/DYSPAN.2005.1542617>

Autores

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, 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.

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.

Lizet Camila Salgado Franco

Ingeniera electrónica y de telecomunicaciones de la Universidad Cooperativa de Colombia, magíster en Ciencias de la Información y las Comunicaciones de la Universidad Distrital Francisco José de Caldas. Investigadora 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 en revistas indexadas de categoría nacional e internacional.

Este libro se terminó de
editar en diciembre de
2021 en la Editorial UD
Bogotá, Colombia