



ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL

Facultad de Ingeniería en Electricidad y Computación

“DISEÑO Y ANÁLISIS DE UN ALGORITMO PREDICTIVO PARA
EVALUAR LA DISPONIBILIDAD DE CANALES EN LA BANDA DE TV
PARA EL USO EN DISPOSITIVOS CON ACCESO OPORTUNISTA AL
ESPECTRO BASADO EN MÁQUINAS VECTORIALES DE SOPORTE”

INFORME DE PROYECTO INTEGRADOR

Previo a la obtención del Título de:

INGENIERO EN ELECTRÓNICA Y TELECOMUNICACIONES

EMILIO ALEJANDRO ZAMBRANO BONILLA

GUAYAQUIL – ECUADOR

AÑO: 2018

AGRADECIMIENTOS

Agradezco en primer lugar a Dios, pues sin él nada podemos hacer, él nos da la vida y lo necesario para lograr nuestras metas. A mis padres Fabricio y Mónica, por su determinación, entrega y humildad, porque siempre han estado conmigo en las buenas y en los momentos difíciles, educándome, ayudándome e impartiendo valores para conducirme en este largo camino. A mis hermanas Mónica y Mariangel por alentarme con su cariño y confianza en mis capacidades. A mis amigos y compañeros por ser fieles y sinceros a nuestra amistad y por darme siempre el apoyo y la lealtad que necesitaba en los momentos precisos. A mis profesores por ser mi guía, porque me enseñaron no solo la ciencia sino respeto, amistad, honestidad y a creer en mí para dar todo por ser el ser humano que ahora soy. Me faltarían palabras para expresar el regocijo que siento poder terminar mi carrera en donde profesores y compañeros dejan parte de su vida para dar vida a mis ilusiones de niño que hoy se hacen realidad.

Gracias infinitas a todos.

Emilio Alejandro Zambrano Bonilla

DEDICATORIA

A mis queridos padres Fabricio Zambrano Ormaza y Mónica Bonilla Demera.

Hoy, luego de un largo camino recorrido, de tener la satisfacción del deber cumplido. Me detengo a pensar, mi mente y mis recuerdos me llevan al día siguiente de la navidad del año 2011. Cuando las familias descansan, mis padres y yo estábamos viajando a empezar esta aventura, cargados de ilusiones y con mucha ansiedad por las pruebas de ingreso que justo ese día debía dar para tener el privilegio de entrar a la universidad en la que yo soñaba desde niño. En ese momento ellos se convirtieron en el motor que impulsó todo mi esfuerzo y es a ellos a quienes con respeto, gratitud y cariño dedico este trabajo de investigación con el cual habré culminado mi carrera como Ingeniero en Electrónica y Telecomunicaciones de la Escuela Superior Politécnica del Litoral.

Emilio Alejandro Zambrano Bonilla

TRIBUNAL DE EVALUACIÓN

MSc. Washington Medina Moreira

PROFESOR DE MATERIA
INTEGRADORA

PhD. Juan Carlos Avilés Castillo

TUTOR ACADÉMICO

DECLARACIÓN EXPRESA

"La responsabilidad y la autoría del contenido de este Trabajo de Titulación, me corresponde exclusivamente; y doy mi consentimiento para que la ESPOL realice la comunicación pública de la obra por cualquier medio con el fin de promover la consulta, difusión y uso público de la producción intelectual"

.....
Emilio Alejandro Zambrano Bonilla

RESUMEN

En la última década, el desarrollo de las telecomunicaciones a nivel global ha experimentado un crecimiento exponencial, permitiendo a la fecha contar con múltiples tecnologías de acceso al medio. La mayoría de estas tecnologías utilizan comunicación vía inalámbrica para ofrecer sus servicios. El desarrollo de las mismas, así como el crecimiento poblacional que han sufrido las ciudades, ha dado como resultado una saturación del espectro radioeléctrico.

El principal objetivo de esta investigación consistió en diseñar un algoritmo basado en el aprendizaje de máquina y utilizando máquinas vectoriales de soporte a través de su adaptación como regresión, lo que permitió predecir el comportamiento de la disponibilidad de un conjunto de canales en la banda asignada a la televisión analógica y su aplicación en dispositivos que trabajen con tecnología OSA.

Las máquinas vectoriales de soporte permiten elaborar un modelo de predicción, el cual puede ser ajustado a las condiciones del problema a resolver mediante una etapa de entrenamiento. Para este proyecto se utilizaron datos provenientes de investigaciones previas que contenían valores de potencia de canales pertenecientes al espectro asignado a la televisión analógica. Estos datos fueron utilizados para obtener un modelo que permitió predecir los niveles de potencia que tendrían estos canales, para luego poder evaluar la disponibilidad que podrían ofrecer de manera conjunta y así establecer mejores formas de asignación del espectro para el escenario de estudio.

En el capítulo 4 se puede observar el gran rendimiento que tienen las máquinas vectoriales de soporte al momento de elaborar modelos de predicción que se ajusten a un escenario en específico. En esta investigación el modelo aplicado tuvo un gran desempeño que permitió obtener datos muy cercanos a la realidad, lo cual da apertura para la elaboración de una nueva herramienta para la asignación dinámica del espectro.

ABSTRACT

In the last decade, the development of Telecoms worldwide has been experienced an exponential growth, allowing to the present day to have multiple technologies to access the medium. Most of this technologies use wireless communication systems to offer their services. The development of these technologies thus as well the population growth that has suffered by cities, has resulted in a depletion of the radio spectrum.

The main objective of this research was to design an algorithm based on machine learning and using the support vector machines through their adaptation as regression, this allowed predicting the behavior of the availability of a set of channels in the band assigned to analog television and its application in devices that work with OSA technology.

The support vector machines allow creating a prediction model that can be adjusted to the conditions given by the problem through a training stage. For this project were used a set of data coming from previous research that contained power values of channels that belong to the spectrum assigned to analogic television. This set of data was used to obtain a model that allowed to predict the new levels of power values of these channels to then evaluate the availability that they could offer in a joint way so better ways to assign the spectrum for this scenario could be established.

In the fourth chapter, you can see the great performance that support vector machines have when it comes to creating predicting models that adjust to a specific scenario. The predicting model obtained in this research had a great efficiency that allowed obtaining new data that was very close to the reality, this means a new open door to create better tools to the dynamic spectrum assignation.

ÍNDICE GENERAL

RESUMEN	I
ABSTRACT	II
ÍNDICE GENERAL	III
ÍNDICE DE FIGURAS	V
ÍNDICE DE TABLAS	VI
CAPÍTULO 1	1
1. PLANTEAMIENTO DEL PROBLEMA.....	1
1.1. Identificación del problema.	1
1.2. Justificación.	2
1.3. Objetivos.....	3
1.1.1 Objetivo generales.....	3
1.1.2 Objetivos específicos.....	3
1.4. Solución Propuesta.....	4
1.5. Metodología.	5
1.6. Alcance	6
CAPÍTULO 2	7
2. ESTADO DEL ARTE.....	7
2.1 Sistemas de Acceso Dinámico al Espectro.....	8
2.1.1 Modelo Dinámico de Uso Exclusivo.....	9
2.1.2 Modelo Abierto Compartido.....	10
2.1.3 Modelo de Acceso Jerárquico.....	10
2.2 Espacios en Blanco en Bandas de Televisión	12
2.3 Máquinas Vectoriales de Soporte	13
CAPÍTULO 3	17
3. MODELAMIENTO DEL ALGORITMO.....	17
3.1 Modelamiento Matemático	17
3.1.1 Support Vector Machines Regression: Formula.....	17
3.1.2 Kernels.....	18
3.2 Predicción para disponibilidad de canales conjuntos.....	19

3.3	Modelado del algoritmo predictivo usando SVR	20
3.4	Diagrama de flujo.....	23
CAPÍTULO 4		22
4.	ANÁLISIS DE RESULTADOS.....	22
4.1	Predicción de disponibilidad por canal	26
4.2	Predicción de n canales conjuntos por día.....	29
4.3	Disponibilidad temporal de Co-canales.....	33
4.4	Prediccion no supervisada	36
CONCLUSIONES Y RECOMENDACIONES		400
BIBLIOGRAFÍA		411
ANEXOS		44

ÍNDICE DE FIGURAS

Figura 2. 1 Modelo del Acceso Dinámico al Espectro [7].	.¡Error!	Marcador	no
definido.			
Figura 2. 2 Concurrencia del Espectro [7].¡Error!	Marcador no definido.
Figura 2. 3 Superposición del Espectro[7].¡Error!	Marcador no definido.
Figura 2. 4 Esquema básico de un Algoritmo SVR [38].	.¡Error!	Marcador	no
definido.			
Figura 2. 5 Plano formado por datos de entrenamiento [40].	.¡Error!	Marcador	no
definido.			
Figura 2. 6 Superficie formada entre las clases [40].	.¡Error!	Marcador no definido.	
Figura 3. 1 Optimización de una SVR y función de error [37].¡Error!
Marcador no definido.			
Figura 3. 2 Parametros optimos para nuestro modelo de predicción.	.¡Error! Marcador no definido.		
Figura 3. 3 Diagrama de flujo para predicción basado en SVR. 23		
Figura 4. 1 Comportamiento de la predicción de un canal con disponibilidad media26		
Figura 4. 2 Comportamiento de la predicción de un canal con disponibilidad baja 27		
Figura 4. 3 Comportamiento predicción de un canal con disponibilidad alta	..28		
Figura 4. 4 Disponibilidad Conjunta para primer grupo. 29		
Figura 4. 5 Disponibilidad conjunta para segundo grupo 30		
Figura 4. 6 Disponibilidad conjunta 4-co canales primer grupo. 31		
Figura 4. 7 Disponibilidad conjunta de 12-co canales segundo plano. 32		
Figura 4. 8 Disponibilidad temporal para 2 co-canales en el primer grupo.	... 33		

Figura 4. 9 Disponibilidad temporal para 3 co-canales en el primer grupo ¡Error!

Marcador no definido.4

Figura 4. 10 Disponibilidad temporal para 3 co-canales en el primer grupo ¡Error!

Marcador no definido.5

Figura 4. 11 Predicción parcial sin supervisión ¡Error! **Marcador no definido.6**

Figura 4. 12 Predicción parcial sin supervisión segundo caso ¡Error! **Marcador no definido.7**

Figura 4. 13 Predicción parcial sin supervisión tercer caso ¡Error! **Marcador no definido.8**

ÍNDICE DE TABLAS

Tabla 3.1 Matriz de Disponibilidad de n canales. ¡Error! **Marcador no definido.**

Tabla 2 Error de predicción para cada canal por día de medición.....47

Tabla 3 Grupos de Disponibilidad Conjunta de 3 canales. ¡Error! **Marcador no definido.8**

Tabla 4 Grupos de Disponibilidad Conjunta de 4 canales.....48

CAPÍTULO 1

1. PLANTEAMIENTO DEL PROBLEMA.

Este primer capítulo tiene como objetivo detallar la problemática que representa la escasez del espectro radioeléctrico debido al desarrollo acelerado que han experimentado las telecomunicaciones en los últimos años, especialmente los servicios que utilizan acceso inalámbrico. La falta de regularización de las nuevas tecnologías de acceso inalámbrico, el exceso de usuarios en bandas libres y el desarrollo urbano son las principales causas de esta problemática, la cual se pretende analizar en esta investigación.

1.1. Identificación del problema.

En los últimos años con el desarrollo de las TIC's y el constante aumento de dispositivos y servicios inalámbricos, particularmente aquellos que brindan acceso a servicios de internet, los cuales en su mayoría se concentran en las zonas urbanas densamente pobladas [1], ha llevado a que exista una saturación del espectro electromagnético.

Bajo la premisa que el espectro radioeléctrico es un recurso natural y limitado [2], la utilización ineficiente del mismo en conjunto con el despliegue indiscriminado de estas tecnologías está causando problemas de congestión en las redes, los cuales no solo afectan la calidad del servicio ofrecido sino también la experiencia de los usuarios, retrasando el despliegue de nuevas tecnologías más actuales.

Como sabemos el Ecuador está en proceso de llevar a cabo la evolución de la televisión analógica hacia la era digital [6], liberando una porción considerable del espectro en la banda UHF, dando una oportunidad para que distintas tecnologías sean desarrolladas aquí, entre ellas aquellas basadas en Acceso Oportunista al Espectro, es por ello que se pretende desarrollar un algoritmo predictivo basado en las máquinas vectoriales de soporte, que permita conocer las porciones del espectro que se encuentran parcialmente libres y la cantidad

de tiempo que pueden ser utilizadas, lo que implica el uso más eficiente del mismo y a su vez todos los potenciales beneficios que eso implica.

1.2. Justificación.

En la sociedad moderna con la aparición de las nuevas tecnologías de acceso inalámbrico, se ha llegado a pensar que el espectro electromagnético se está saturando, por esta razón se han introducido nuevos esquemas que permitan el uso eficiente del mismo, uno de ellos es el Acceso Oportunista al Espectro [7], el cual propone que los usuarios secundarios accedan a porciones del espectro que no están siendo utilizadas por usuarios primarios (usuarios de banda licenciada) bajo la premisa que no deben afectar el funcionamiento de los usuarios primarios [7].

La Radio Cognitiva [8] en conjunto con el Acceso Oportunista al espectro constituyen la tecnología que permite el uso dinámico del espectro, ya que gracias a esta los usuarios secundarios pueden compartir un canal inalámbrico de banda licenciada de manera oportunista.

Como se especifica en [9], en las redes de radio cognitiva es importante realizar un sensado del espectro radioeléctrico, con la finalidad de garantizar el acceso oportunista mediante la detección de los denominados Espacios en Blanco (*White Spaces*) [10], garantizando la protección del usuario primario y la capacidad de transmisión de información para el usuario secundario.

En el año 2014 la ITU realizó un taller [10], en el cual se discutió sobre las oportunidades para el Acceso Oportunista al Espectro que aprovechan los espacios en blancos de la banda de frecuencia asignada para la televisión, y la relevancia que significa para las economías emergentes como la nuestra. Debido a que eventualmente la evolución de la televisión analógica hacia la televisión digital será un hecho en nuestro país, una porción del espectro será liberada, y tal como se explica en [5], el estándar IEEE 802.22 trabaja en esta banda de frecuencia. Un análisis realizado en [11] sobre la implementación de sistemas basados en el estándar IEEE 802.22 en nuestro país, nos muestra

las posibles tasas de transmisión de datos obtenidas al implementar estos esquemas.

Pese a que existen algunos casos de análisis realizados en nuestro país [12], [13] y [14], la importancia del desarrollo de estudios que garanticen una disponibilidad del espectro de manera más confiable y precisa, para así poder utilizar sistemas basados en acceso oportunista al espectro, son de vital importancia para el desarrollo futuro de las telecomunicaciones, ya que la constante aparición de nuevas demandas de ancho de banda y dispositivos de acceso inalámbrico solo harán que se evidencie cada vez más la escasez del espectro radioeléctrico.

Bajo esta premisa, en el presente trabajo se propone realizar el diseño de estudio que permita evaluar la disponibilidad de canales en la banda de Televisión, para su uso en dispositivos que soporten el Acceso Oportunista al Espectro. En particular, el estudio se desarrolla en una zona urbana densa de la ciudad de Guayaquil, correspondiente a la Universidad Politécnica Salesiana, al sur de la ciudad, ubicación en la cual se realizó previamente el sensado del espectro radioeléctrico.

1.3. Objetivos.

1.1.1 Objetivo generales

- Diseñar un algoritmo de predicción de disponibilidad espectral para canales conjuntos en el rango de frecuencias de Tv basado en Máquinas Vectoriales de Soporte para su aplicación en ambientes urbanos.

1.1.2 Objetivos específicos

- Investigar sobre las Máquinas Vectoriales de Soporte y sus aplicaciones en problemas de predicción.

- Establecer el mejor método de entrenamiento para la Máquina Vectorial de Soporte partiendo de los datos que se obtuvieron en investigaciones anteriores.
- Predecir el comportamiento de canales en la banda de Tv en las instalaciones ubicadas en el sector sur de la ciudad para la detección de los espacios blancos en diferentes intervalos de tiempo durante el día.
- Elaborar un análisis sobre los canales que deben ser objeto de estudio, tomando en consideración aquellos en donde exista mayor variación de la disponibilidad conjunta.
- Comprobar el algoritmo predictivo utilizando una simulación en el software de MATLAB, realizando comparaciones con bases de datos de estudios previos.
-

1.4. Solución Propuesta.

Como se pudo constatar en las secciones anteriores, la asignación fija de las frecuencias por partes de los entes reguladores, el uso ineficiente del espectro y el constante crecimiento de dispositivos y tecnologías de acceso inalámbrico, ha llevado a que exista actualmente una saturación del espectro.

Por tal motivo, se propone el diseño de un algoritmo predictivo para evaluar la disponibilidad de canales en la banda de frecuencia de TV dentro de una zona urbana densa, con la finalidad de poder identificar los espacios blancos en determinado tiempo, para su futura aplicación en el despliegue tecnologías que puedan hacer uso de los mismos de manera oportunista.

Este algoritmo está basado en máquinas vectoriales de soporte y utiliza la regresión como herramienta para la predicción de valores futuros de potencia para un canal en específico. Esto permite obtener una matriz de disponibilidad específica para cada canal, la cual puede ser modelada estadísticamente para su análisis de manera gráfica.

1.5. Metodología.

La metodología empleada en el desarrollo del presente proyecto comprende el diseño de un algoritmo de predicción que permita determinar la disponibilidad en el tiempo de canales en la banda de TV.

Para poder lograr esto, se procederá a utilizar un conjunto de datos que fueron obtenidos en investigaciones previas, estos datos corresponden al comportamiento espectral dentro de una edificación que se encuentra en una zona urbana densamente poblada en la ciudad de Guayaquil.

Se procederá a utilizar las Máquinas Vectoriales de Soporte en el caso particular de regresión para diseñar un algoritmo adaptativo que nos permita obtener una serie de tiempo para poder predecir el comportamiento del canal mediante el uso de los estándares establecidos por la ITU, respecto a los niveles de potencia en los cuales un canal puede ser considerado como libre u ocupado, se procederá a evaluar la disponibilidad de los espacios en blancos en dichas predicciones.

Para poder obtener estas predicciones se deben analizar los datos y así elegir la mejor forma de entrenar la Máquina Vectorial de Soporte, posterior a esto debemos establecer las condiciones de tolerancia para el modelo.

Este modelo se encarga de predecir los niveles de potencia de cada canal en específico para intervalos de tiempo que serán establecidos luego de analizar el comportamiento de la predicción frente a los datos, los cuales se irán acumulando hasta obtener la predicción de una semana entera. Posterior se procede a obtener una matriz de disponibilidad diaria para todos los canales que forman parte del estudio, para finalmente obtener la matriz de disponibilidad conjunta para n canales, en la cual se observará aquellos donde se presente la mayor variación de disponibilidad y serán aquellos en donde se realizará el análisis de la efectividad del algoritmo.

La herramienta de MATLAB será utilizada para desarrollar cada etapa de la predicción así como su posterior validación, se pretende elaborar gráficas que permitan observar la eficacia del mismo frente a los datos reales y así poder concluir que tan buenas son las máquinas vectoriales de soporte para este tipo de predicciones.

1.6. Alcance

El desarrollo de esta investigación tiene como finalidad establecer una nueva forma de uso del espectro radioeléctrico, partiendo como punto inicial en el despliegue de nuevas tecnologías de acceso oportunista al espectro en lugares donde la población urbana es densa.

En esta investigación se va a encontrar la disponibilidad conjunta y la presencia de agrupaciones de estos canales conjuntos dentro del espectro de manera eficiente y efectiva, lo cual establece una nueva forma de mitigar la necesidad de espectro en el país, ya que previamente se han desarrollado análisis en donde únicamente se analizaba la disponibilidad conjunta, sin tomar en consideración la presencia de grupos de canales conjuntos que se encuentren disponibles para instantes de tiempos iguales.

Así mismo, esta investigación puede ser el punto de partida para que más personas se interesen por desarrollar tecnologías de acceso oportunista al espectro en el país. Enfocándolo a otros sectores en donde algunas tecnologías de acceso inalámbrico aún no se desarrollan por completo debido a la dificultad de su implementación. Esto significa, poder disminuir esa brecha digital que aún persiste, permitiendo que más ecuatorianos tengan acceso a tecnologías de información y comunicación de una manera más eficiente, con mejores velocidades de conexión y ofrecer al usuario una calidad de servicio superior.

CAPÍTULO 2

2. ESTADO DEL ARTE

En la actualidad con el desarrollo constante que ha experimentado el área de las telecomunicaciones a nivel global, así como el desarrollo de nuevas tecnologías de acceso inalámbrico que necesitan cada vez de mayores porciones del espectro para cumplir con los requerimientos de los usuarios han llevado a la elaboración de estudios en donde se concluye que el espectro es insuficiente [20-22-23].

La llegada de estas nuevas tecnologías ha creado regiones del espectro que nunca son utilizadas, así encontramos las redes celulares que son las que mayor desarrollo han tenido en los últimos años [23]. Como consecuencia de su acelerado desarrollo actualmente encontramos sistemas que colapsan cuando un número grande de usuarios intenta acceder al mismo servicio de manera simultánea.

Un problema que presenta la regularización del espectro recae en las administraciones de cada país, impide la correcta administración del mismo para que organismos como la ITU se encarguen de regular esto.

Como consecuencia de la inminente saturación del espectro y el colapso que representaría en las telecomunicaciones, investigadores han encontrado la manera de darle un uso más eficiente mediante el uso de los Espacios en Blanco, lo que cambia completamente el esquema actual de asignación en donde ya no se lo haría de manera fija, sino que se trata de acceder a porciones del mismo de manera oportunista permitiendo que todos los usuarios hagan uso del espectro.

Sin embargo diferentes estudios presentados en [10], muestran que el espectro a nivel de disponibilidad no es homogénea y tampoco eficiente, debido a las tecnologías que ahora ocupan grandes porciones del mismo y a las cantidades de usuarios que acceden al mismo. Es por ello que la solución para este tipo de inconvenientes proviene de dos diferentes tecnologías, una de ellas es la Radio Cognitiva y la otra es el Acceso Oportunista al Espectro, en conjunto estas

tecnologías permitirían que los usuarios no licenciados obtengan acceso a porciones del espectro que se encuentren libre sin interferir con los usuarios licenciados [19].

2.1 Sistemas de Acceso Dinámico al Espectro.

Las redes inalámbricas actuales se caracterizan por el asignamiento fijo del espectro, de acuerdo a políticas que son reguladas por agencias gubernamentales, cuyo principal propósito es de evitar los problemas de interferencia mediante la asignación de licencias de operación [7], cabe recalcar que el espectro electromagnético se lo define como un recurso natural limitado, debido a esto y al uso ineficiente del espectro, el cumplimiento de la demanda que exigen las nuevas tecnologías al necesitar cada vez de mayores tasas de transmisión de datos[15] no son cumplidas como resultado del modelo deficiente que existe en cuanto a la asignación del espectro.

Esto ha llevado a que se realicen diversos métodos para la asignación del espectro de manera dinámica y oportunista, aprovechando la aparición de tecnologías de radio cognitiva cuyas características de reconfiguración y adaptación resultan muy atractivas [17].

En [18] encontramos un estudio presentado por la Comisión Federal de Comunicaciones de los Estados Unidos (FCC), en el cual se concluye sobre la necesidad del diseño de tecnologías que permitan un eficiente uso del espectro, debido a los bajos porcentajes de utilización del espectro.

Las primera vez que se introdujeron las ideas sobre el Acceso Dinámico al Espectro son explicadas en [19], en donde que las estrategias pueden ser categorizada bajo tres modelos tal y como se ilustra en la figura 2.1.

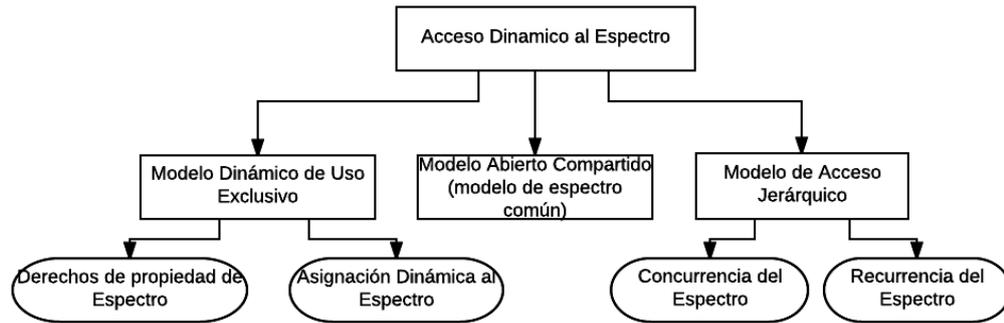


Figura 2.1 Modelo del Acceso Dinámico al Espectro [7].

2.1.1 Modelo Dinámico de Uso Exclusivo

La política actual de regulación del espectro se mantiene en este modelo, dicho de otra forma, las bandas licencias del espectro siguen siendo de uso exclusivo. Lo que se trata de introducir para el modelo mencionado es la flexibilidad del espectro para mejorar la eficiencia del mismo bajo dos tipos de enfoques los cuales son: Derechos de propiedad del Espectro [20] y Asignación Dinámica al Espectro [21].

Derechos de Propiedad del Espectro: Propone el escenario en el cual se toman en consideración parámetros como tiempo, área geográfica y la banda de frecuencia, para que los usuarios primarios (usuarios de banda licenciada) permitan la transmisión sobre la porción del espectro especificada a otros siempre y cuando se respeten los niveles de potencia establecidos en las fronteras geográficas [22], sin embargo debido al comportamiento impredecible del espectro y al desconocimiento del tipo de equipos que puedan utilizar, existen más inconvenientes por resolver que los beneficios que representa.

Asignación Dinámica al Espectro: Presentado inicialmente en [20] en el Proyecto Europeo DRiVE, se enfoca en la mejora de la eficiencia del espectro mediante la explotación temporal y parcial de estadísticas de tráfico, dicho de otra forma aprovecha las características que comparten los sistemas de comunicación, las cuales se relacionan de forma temporal y geográfica, permitiendo determinar los conocidos espacios blancos que existe si una porción del espectro se encuentra sub-

utilizada en diferentes intervalos de tiempo, conociendo estos intervalos se podría hablar de una utilización más eficiente de estos espacios mediante el uso de diferentes variaciones tal y como se describe en [23].

2.1.2 Modelo Abierto Compartido

Denominado también como Modelo Espectro Común, permite la compartición de manera abierta entre usuarios para generar un espacio espectral que es manejado por un coordinador central [7].

En este modelo podemos encontrar las tecnologías que operan en las bandas no licenciadas (p.ej. ISM), y debido al éxito rotundo que obtuvo el WiFi, existen muchos defensores que sostienen la existencia de un ambiente sin necesidad de ser regulado o licenciado [7].

2.1.3 Modelo de Acceso Jerárquico

Este modelo propone la apertura del espectro para los usuarios secundarios (usuarios de banda no licenciada) limitando los niveles de interferencia que pueden ser percibidos por los usuarios primarios (usuarios de banda licenciada), bajo una estructura de acceso jerárquica [7]. Para este modelo se toman en consideración dos enfoques: Concurrencia del Espectro y Recurrencia del Espectro.

Concurrencia del espectro: Se establecen restricciones en cuando a la potencia de transmisión permitida para los usuarios secundarios (usuarios de banda no licenciada), permitiendo la coexistencia de usuarios primarios y secundarios para una misma frecuencia de operación, pero se regula que los niveles de interferencias producidos sean menores a los preestablecidos [7].

Debido a las limitaciones de potencia, los usuarios secundarios deben utilizar tasas de datos relativamente bajas en un gran ancho de banda, el mejor ejemplo de esto se da en Ultra Wide Band (UWB), tal y como podemos observar en la Figura 2.2.

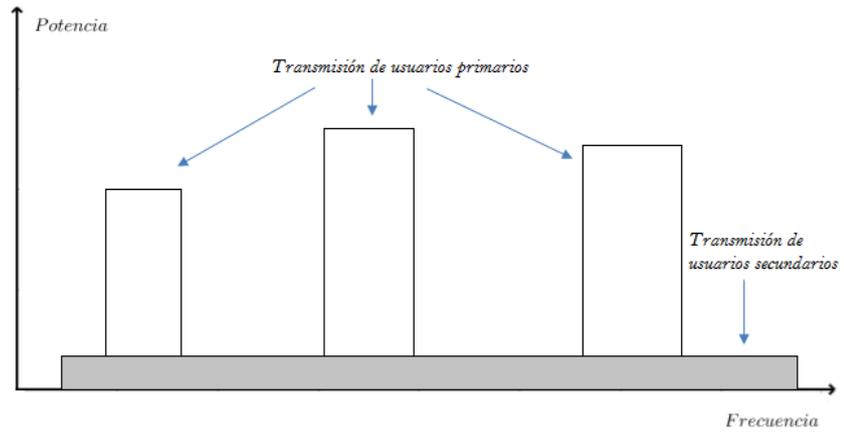


Figura 2.2 Concurrencia del Espectro [7].

Bajo este esquema de transmisión los usuarios primarios no detectarían las transmisiones realizadas por los usuarios secundarios o de ser detectadas serían captadas como ruido, permitiendo que la transmisión sea de manera simultánea.

El inconveniente con este sistema de transmisión radica en el corto alcance que se obtiene al limitar el nivel en la potencia que utilizan los usuarios secundarios al momento de realizar una transmisión.

Superposición del Espectro: Tal y como su nombre lo dice, en este esquema de transmisión lo que se aprovecha son los espacios de tiempos en los cuales los usuarios primarios no se encuentran transmitiendo, esto recibe otra denominación y es conocida como Acceso Oportunista al Espectro, tal y como se observa en la figura 2.3.

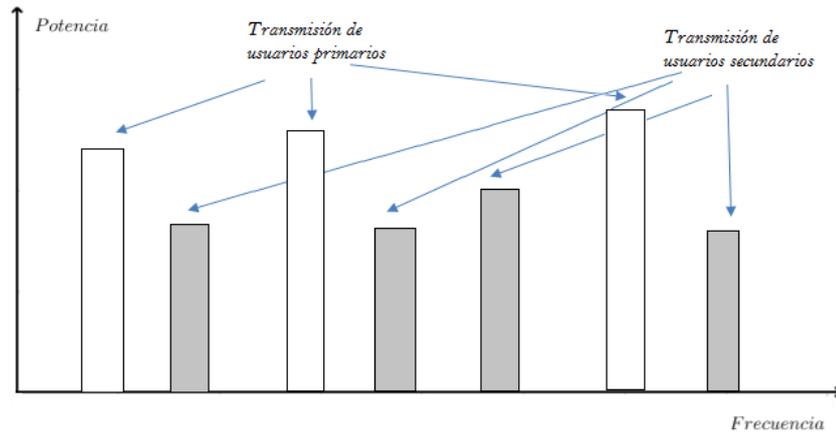


Figura 2.3 Superposición del Espectro [7].

Para que los usuarios secundarios puedan acceder a estas porciones del espectro que se encuentran en desuso, previamente debe haberse realizado un análisis del espectro con el objetivo de detectar el comportamiento de los usuarios primarios en la banda de frecuencia, sin embargo las condiciones para que un usuario secundario pueda acceder a estos espacios en blanco dependen también de otros factores como la probabilidad de que ambos transmitan de manera simultánea y exista una colisión entre ellos [24].

2.2 Espacios en Blanco en Bandas de Televisión

Un espacio en blanco hace referencia a los canales de televisión que no se encuentran activos o aquellas porciones de los mismos que se encuentran libre en intervalos de tiempo, correspondiente al espectro que va de VHF a UHF [10].

Originalmente estas porciones se las utilizaba como canales de guarda para evitar las interferencias en las transmisiones de televisión, no fue hasta que múltiples investigaciones comprobaron que estas porciones sin uso del espectro podían ser utilizadas para proveer servicio de acceso a internet de banda ancha, funcionando de manera paralela con los canales activos de televisión [37].

Cabe recalcar que las ventajas que posee el uso de los espacios blancos frente a tecnologías ya existentes como el WiFi es superior debido a múltiples factores como son la cobertura. Generalmente y en las mejores condiciones un punto de acceso WiFi ofrece hasta 100m de cobertura, mientras las coberturas que pueden ofrecer las tecnologías basadas en espacios en blancos van hasta un aproximado de 10km de diámetro [37]. Así mismo por el comportamiento de las ondas de televisión al usar ondas de baja frecuencia permiten acceder en zonas de mayor densidad o con mayores obstáculos, eliminando así la necesidad de una línea de vista entre los puntos del enlace.

2.3 Máquinas Vectoriales de Soporte

Desarrollada en la década de los 90 por Vladimir Vapnik y un grupo de AT&T, inicialmente se presentó como un método para la clasificación binaria [25], pero actualmente su aplicación se ha extendido a problemas de regresión y clasificación múltiple [26]. Se define como un algoritmo de aprendizaje de máquina que necesita ser previamente entrenado, para resolver problemas de predicción de diferentes clases como son: Predicción de clasificación binaria, predicción de clasificación multi-categoría y predicción de regresión lineal.

Con la llegada del aprendizaje de máquina [27], el uso de las máquinas vectoriales de soporte se ha extendido a múltiples disciplinas entre ellas las telecomunicaciones, en donde se realizan diferentes tipos de enfoques, ya sea para clasificar o predecir cosas.

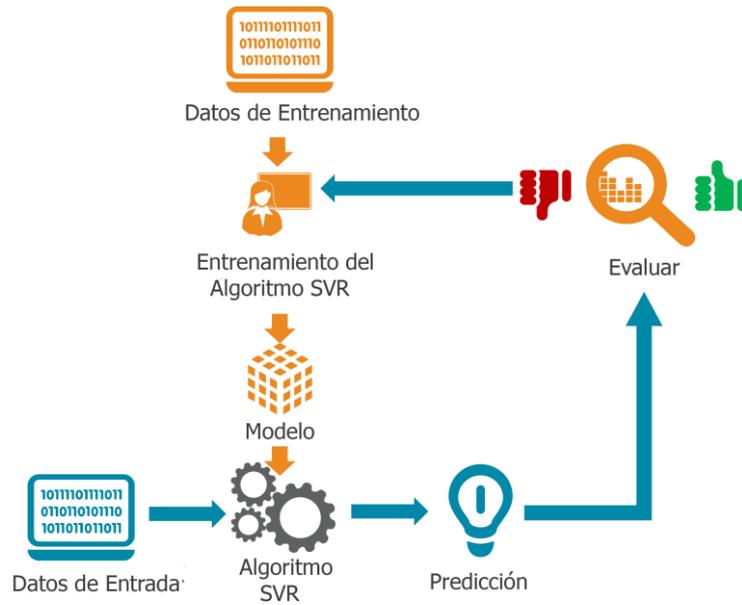


Figura 2.4. Esquema básico de un Algoritmo SVR [38].

En la figura 2.4 podemos observar el funcionamiento de las Máquinas Vectoriales de soporte. Para lograr comprender cómo trabajan imaginemos el siguiente escenario: Se dispone de un problema de predicción de tipo binario, en el cual los valores de los cuales podemos hacer uso son solo dos (estos serán los datos de entrenamiento), y necesitamos predecir si un paciente tiene cáncer o no. Inicialmente debemos mapear estos datos dentro de un plano cartesiano, en el cual cada eje corresponde a los valores presentes en el grupo de entrenamiento. Los puntos que serán colocados en el plano que corresponden a aquellos pacientes que tienen cáncer, serán representados por una circunferencia negra y para los que no tienen, como un rombo blanco.

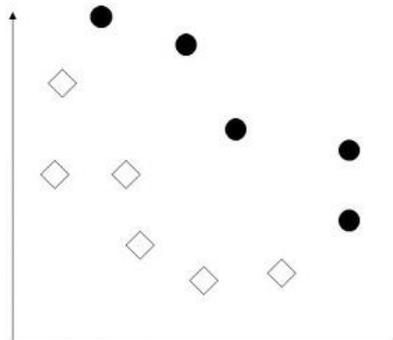


Figura 2.5 Plano formado por datos de entrenamiento [40].

Inmediatamente las máquinas vectoriales de soporte buscan una “superficie” que pueda separar las dos clases con la mayor distancia posible entre ellas. Para el caso de ejemplo, esta “superficie” corresponde a una línea, dependiendo de la dimensión del problema, la superficie será definida como hiper-superficie y tendrá tantas variables como dimensiones del grupo de entrenamiento.

Lo que hace especial a las máquinas vectoriales de soporte se debe a que el criterio utilizado para encontrar aquella superficie que pueda separar las clases con la mayor distancia posible, la cual fue definida por Vapnick como “margen”, debe cumplir el siguiente criterio: La superficie a ser elegida deberá encontrarse a la misma distancia para un punto perteneciente a cada una de las clases, es decir si tomamos un punto de la clase 1 y tomamos el punto de la clase 2 que esté más cercano a este, la superficie se encontrará en la mitad de la distancia entre ellos.

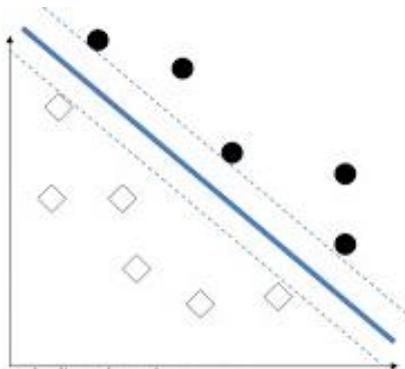


Figura 2.6 Superficie formada entre las clases [40].

Esta superficie tiene como objetivo minimizar el error al momento de clasificar los nuevos datos luego que el modelo haya sido entrenado. Los puntos que son seleccionados para este criterio reciben el nombre de vectores de soporte. Una vez que se ha entrenado a la máquina vectorial de soporte, la misma se convierte en una especie de “caja negra”, en la cual para un conjunto de datos de entrada, proporcionara una respuesta.

Un estudio realizado en [29] hace un análisis sobre el uso de las máquinas vectoriales de soporte para la detección de patrones de fraudes en las

telecomunicaciones, mediante la detección temprana de los escenarios de fraude en la telefonía pública.

De igual manera en 2015 se realizó otro estudio [28], en el cual se pretende establecer la selección de parámetros que permitan predecir la fuga de los clientes en las redes celulares utilizando la clasificación mediante las máquinas vectoriales de soporte.

Otro estudio que demuestra la gran utilidad de esta metodología para las telecomunicaciones lo encontramos en [30], en donde se establece un modelo de clasificación de señales moduladas digitalmente.

De igual manera en [31-32] encontramos diferentes aproximaciones sobre el uso de las máquinas vectoriales de soporte para la predicción de series temporales.

En este trabajo se pretende utilizar Maquinas Vectoriales de Soporte con su respectivo ajuste para poder predecir el comportamiento de la disponibilidad de canales adyacentes en canales de la banda de Televisión en el tiempo, esto permitirá la detección de los espacios en blancos en un área o posición geográfica determinada, los cuales podrán ser aprovechados para sistemas que utilicen Acceso Dinámico al Espectro, permitiendo un uso más eficiente del espectro y la posible introducción de sistemas que trabajen bajo el estándar IEEE 802.22, debido a las condiciones futuras del espectro radioeléctrico en el país.

CAPÍTULO 3

3. MODELAMIENTO DEL ALGORITMO.

Este capítulo comprende la explicación de la metodología usada, el diseño y modelamiento del algoritmo así como los parámetros utilizados para el desarrollo del modelo predictivo. En esta investigación se hará uso de las máquinas vectoriales de soporte como una herramienta de predicción, debido a que el algoritmo a desarrollar comprende diferentes etapas, de las cuales la predicción es la inicial, el conjunto de pasos y decisiones tomadas luego de haber realizado la predicción serán establecidos de acuerdo a criterios de diseño obtenidos por medio de la prueba y error.

El modelo predictivo se basa en el uso de las máquinas vectoriales de soporte en su caso especial de regresión, las cuales son algoritmos que se usan de manera extensa en situaciones de aprendizaje supervisado. En este tipo de aprendizaje se espera encontrar una función $h(x)$ encargada de obtener la información de un grupo de datos de entrenamiento $S = \{(x_i, z_i)\}_{i=1}^m$.

3.1 Modelamiento Matemático

3.1.1 Support Vector Machines Regression: Formula

Suponiendo que se tiene un conjunto de m datos $S = \{(x_i, z_i)\}_{i=1}^m$ para entrenamiento, en el cual cada elemento $z_i \in \mathbb{R}$ y cada x_i pertenece a un conjunto de muestras en \mathbb{R}^d . Se desea obtener la función lineal $h: \mathbb{R}^d \mapsto \mathbb{R}$

$$h(x) = \langle \mathbf{w}, \mathbf{x} \rangle + b \quad \mathbf{w} \in \mathbb{R}^d, b \in \mathbb{R} \quad (3.1)$$

La simbología $\langle ., . \rangle$ representa al producto punto realizado en \mathbb{R}^d . Las SVR tienen como objetivo encontrar a la función lineal que tenga la menor cantidad de error, a lo mucho ε con respecto a los datos de entrenamiento y de igual manera que su complejidad sea muy baja. Este error se lo puede definir como la menor distancia que debe haber entre los datos y la función obtenida.

Es probable que no exista la función h que tenga la capacidad de satisfacer estas restricciones y sea capaz de aproximar cada valor del conjunto de entrenamiento con un valor de ε mínimo. Una manera de mitigar este problema es la introducción de las variables de holgura ξ_i y ξ^*_i , al introducir estas variables la expresión queda de la siguiente manera:

$$h(x) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^m (\xi_i + \xi^*_i) \quad (3.2)$$

En esta expresión el valor de C corresponde al *box constraint*, el cual es un valor numérico encargado de controlar la penalización impuesta en las observaciones que se encuentran fuera del margen de épsilon (ε) al mismo tiempo que previene el sobreentrenamiento. Este valor determina la compensación entre la complejidad y la cantidad de errores que se comete.

La siguiente figura explica de mejor manera lo previamente establecido, en ella se puede apreciar que los valores que se encuentran fuera de la región sombreada ε son los que aportan en el error, de igual manera el comportamiento del error y su crecimiento tienen una forma lineal.

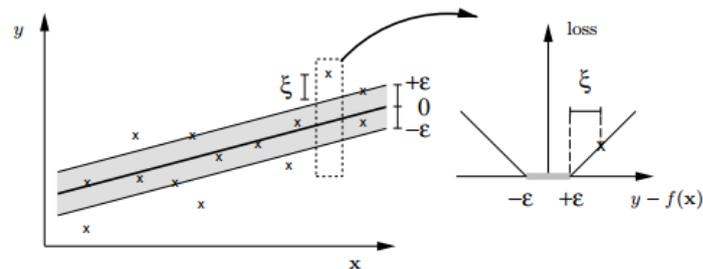


Figura. 3.1 Optimización de una SVR y función de error. [37]

3.1.2 Kernels

Algunos problemas de regresión no pueden ser descritos de manera adecuada utilizando un modelo lineal, para estos casos la formulación dual de Lagrange permite a la técnica previamente descrita ser extendida para funciones no lineales.

El modelo se lo obtiene al reemplazar el producto punto con una transformación lineal $\Phi : \mathbb{R}^d \mapsto \chi'$ que tiene la siguiente forma:

$$h(x) = \langle \mathbf{w}, \Phi(x) \rangle_{\chi'} + b \quad \mathbf{w} \in \chi', b \in \mathbb{R} \quad (3.3)$$

El producto $\langle \cdot, \cdot \rangle_{\chi'}$ representa la transformación que mapea los valores de x a un espacio multidimensional. Aquí la formulación dual nos indica que debemos usar el par $\langle \Phi(x_i), \Phi(x_j) \rangle_{\chi'}$. El cálculo de este producto punto para este espacio se lo realiza mediante el uso de la función kernel $k: \mathbb{R}^d \times \mathbb{R}^d \mapsto \mathbb{R}$ descrita como:

$$k(x_i, x_j) = \langle \Phi(x_i), \Phi(x_j) \rangle_{\chi'} \quad (3.4)$$

Para el desarrollo de esta investigación la función de kernel a ser utilizada será uno de tipo lineal que sigue la siguiente fórmula:

$$k(x_i, x_j) = x_i' x_j \quad (3.5)$$

3.2 Predicción para disponibilidad de canales conjuntos

Para este caso particular la predicción se enfoca en los valores de potencia recibidos, los cuales serán puestos a evaluación sobre su disponibilidad de acuerdo a la ecuación (3.6) en la cual φ_i corresponde a la disponibilidad del canal para ese instante y Y_i corresponde a la potencia, el valor de umbral o threshold está representado por la variable λ .

$$\varphi_i = \begin{cases} 1 & \text{si } Y_i \leq \lambda \\ 0 & \text{si } Y_i > \lambda \end{cases} \quad (3.6)$$

Esta disponibilidad obtenida para cada canal en específico deberá ser trasladada a una matriz en la que se pueda evaluar la disponibilidad conjunta y así determinar la cantidad de canales libres que se obtienen en diferentes intervalos de tiempo para este escenario en particular, los cuales podrán ser utilizados en múltiples servicios de acuerdo a los requerimientos deseados por los usuarios.

3.3 Modelado del Algoritmo Predictivo usando SVR

El algoritmo que va a ser utilizado para predecir la disponibilidad de los canales conjuntos se basa en las máquinas vectoriales de soporte, en el caso especial de regresión. Este algoritmo se sirve de una base de datos proveniente de mediciones realizadas en una instalación al sur de la ciudad de Guayaquil, la cual está conformada por 31 canales en total.

Dentro del análisis inicial de los datos, se encontró con un total de 85370 mediciones para cada canal, las cuales corresponden a una semana entera de monitoreo. Para poder ajustar mejor los datos y establecer un intervalo entre mediciones equivalente a un minuto, se ha procedido a realizar un promedio entre muestras, luego de haber realizado los cálculos pertinentes y tomando en consideración la mayor cantidad de datos posibles, se ha fijado un valor de 8 mediciones por minuto. Adicional a esto, se procedió a realizar un sesgo de los datos restantes, esto se lo realizó luego de haber consultado en el impacto que podría ocasionar en el análisis no tomar en consideración a los mismos.

Para elaborar un modelo de predicción en el cual los valores de predicción contarán con el menor error ε posible, fueron tomados dos sub-conjuntos de datos de uno de los 31 canales, cada sub-conjunto estaba formado por 200 muestras. El primer sub-conjunto de 200 muestras corresponden a los valores de entrenamiento para el modelo, esto quiere decir los valores que serán utilizados para que el algoritmo pueda aproximarse a los valores esperados, los cuales corresponden al segundo sub-conjunto de muestras.

Para obtener las condiciones de tolerancia del modelo, es decir los valores que fueron mencionados previamente en (3.2), se ha procedido a utilizar una función dentro del software de MATLAB que nos permite probar diferentes combinaciones, haciendo variaciones del *kernel* empleado, así como del valor del *box constraint*, esta función utiliza a los dos sub-conjuntos que se seleccionaron y realiza diferentes iteraciones hasta encontrar las condiciones que se adapten mejor al modelo. En la figura 3.2 encontramos los valores que fueron obtenidos para el modelo predictivo luego de haber realizado 30 combinaciones de posibles modelos de predicción para los datos tomados.

```
Command Window
New to MATLAB? See resources for Getting Started.

Best estimated feasible point (according to models):
  BoxConstraint      KernelScale      Epsilon
  -----
  192.57            0.12687         0.1895

Estimated objective function value = 0.14064
```

Figura. 3.2 Parámetros óptimos para nuestro modelo de predicción.

Como podemos observar y como se explicó anteriormente, estos tres parámetros son los que establecen que tan bueno es el modelo con respecto a los datos de entrenamiento del primer sub-conjunto.

Una vez obtenidos estos parámetros, se procedió a elaborar una función que nos permitiera predecir el comportamiento de los valores de potencia de cada canal para toda la semana. Dentro de esta función se establece el modelo de predicción, y los parámetros encontrados previamente son configurados. Para realizar las predicciones se toman muestras equivalentes a dos horas de mediciones, este criterio fue establecido luego de haber hecho varias pruebas, en las cuales se pudo observar el comportamiento del algoritmo con cantidades inferiores y con cantidades superiores de muestras. Es decir este modelo de predicción nos arroja hasta dos horas con el menor error posible. Para el caso de cantidades inferiores, se observó que el algoritmo tendía a predecir valores sin mucha variación, teniendo una tendencia a los mismos valores pese al re-entrenamiento. Algo similar ocurre si se eligen cantidades superiores, aquí las predicciones tienen mayor diferencia con los valores reales, obteniendo picos que de manera progresiva aumentan en el error.

Debido al comportamiento estocástico de los valores de potencia fue necesario establecer una condición de re-entrenamiento cada dos horas, ya que este tipo de algoritmos no tiene un buen desempeño cuando los datos son de tipo estocástico. Las SVR tienden a ajustarse a los valores para los que son entrenados. La aparición de nuevos datos provoca que se alejen de este comportamiento y tiene como resultado el aumento del error de predicción debido a que estos datos varían demasiado respecto al grupo de entrenamiento inicial.

De manera inmediata una vez que la predicción termina y se han obtenido los datos de potencia de cada canal, estos datos son exportados a nuevas bases de datos con la finalidad de poder manipular desde un software externo los mismos y poder ver el comportamiento.

Debido a que es necesario estudiar la disponibilidad luego de predecir los valores de potencia para canal, estos valores deben ser llevados a una matriz binaria de disponibilidad, en donde el valor de 1 corresponde a “disponible” y el valor de 0 corresponde a “ocupado”, estos son obtenidos al aplicar el criterio establecido en (3.5).

En esta matriz binaria cada columna representa la disponibilidad de un canal para un día en específico. Así, tendremos un total de 7 matrices de disponibilidad, haciendo analogía a los 7 días de mediciones y un total de 31 columnas presentes en cada matriz, debido a los 31 canales en los que se realizaron las mediciones.

Tiempo	canal 1	canal 2	canal 3	canal 4	canal n-1	canal n
t1	1	0	1	1	1	0
t2	0	1	1	0	1	0
tn	0	0	1	1	0	1

Tabla 3.1. Matriz de Disponibilidad de n canales.

En esta investigación se quería hallar la disponibilidad conjunta que podían ofrecer estos canales para intervalos de tiempos iguales, es por ello que los datos debían estar categorizados por día, para lograr esto se seleccionaron los datos de cada canal que correspondían a un día específico de la semana y fueron trasladados a nuevas bases de datos obteniendo así matrices de disponibilidad diaria de todo el espectro de estudio.

El objetivo final es encontrar la matriz binaria de disponibilidad conjunta para cada día de medición, es decir evaluar hasta cuantos canales adyacentes se encuentran libres, así se obtendrán sub-matrices de 2, 3, 4 hasta n canales

conjuntos disponibles. Para obtener estas sub-matrices se procedió a utilizar el siguiente criterio: Si un canal y su vecino tienen el valor de 1, tendremos una disponibilidad conjunta de 2 canales, la cantidad total de canales conjuntos dependerá de cuántos de ellos se encuentren libres de manera simultánea.

3.4 Flujo grama del algoritmo predictivo

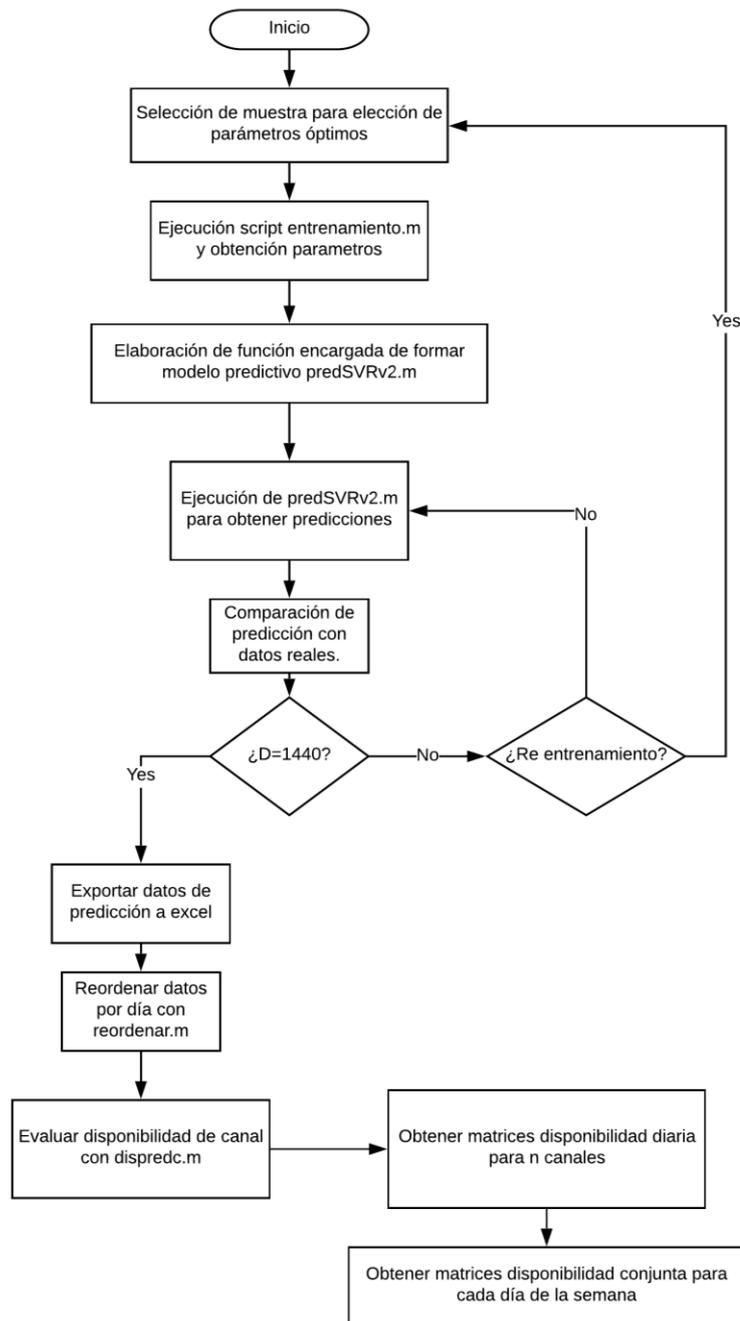


Figura 3.4 Diagrama de flujo para predicción basado en SVR.

En este flujo grama podemos observar que existen varias etapas dentro del algoritmo obtenido. Inicialmente se toman una muestra de datos para obtener los parámetros óptimos que permitan realizar predicciones con el menor error posible. Estos serán utilizados para elaborar el modelo de predicción. Una vez que se han obtenido estos parámetros es necesario realizar el entrenamiento del modelo, para ello se hizo un script llamado *entrenamiento.m*, que recibe estos parámetros y de manera simultánea toma los dos sub-conjuntos de datos como par *entrenamiento/valor esperado* para así crear el modelo de predicción. La función denominada *predSVRv2.m*, es la encargada de realizar todas las predicciones, aquí se establecieron parámetros de funcionamiento. Cuando esta función está en ejecución se encarga de obtener nuevos valores de potencia y va creando una base de datos con estos, esto debe realizarlo para cada uno de los 30 canales. Una vez que se obtienen los valores de predicción, el algoritmo se encarga de comparar estos con valores reales. Si como resultado de la comparativa se encuentra que los valores de predicción difieren demasiado de los valores reales, se procederá a realizar un re-entrenamiento. Para este re-entrenamiento se tomarán como datos para el nuevo modelo predictivo mediciones de las dos últimas horas. Una vez que se obtiene el nuevo de modelo de predicción se vuelve a realizar la predicción. Para encontrar la condición de finalización de predicción durante un día de medición, se debió hacer una conversión de unidades de acuerdo a los datos que maneja el algoritmo, como sabemos, las predicciones son realizadas por minuto y debido a que solo era necesario analizar un día de predicción, se obtuvo finalmente el valor de 1440. Luego de haber realizado las predicciones para cada canal y habiendo obtenido las nuevas bases de datos, el algoritmo se encarga de reordenarlas, separando la información de los 30 canales ahora por día de la semana. Lo siguiente a realizar es la evaluación de disponibilidad diaria de los canales y finalmente se obtienen las matrices de disponibilidad conjunta correspondiente a cada día de la semana.

CAPÍTULO 4

4. ANÁLISIS DE RESULTADOS.

En este capítulo se presentará de manera gráfica los resultados obtenidos luego de la simulación del algoritmo de predicción basado en máquinas vectoriales de soporte en el software de MATLAB.

Debido a la tendencia mostrada en el comportamiento de la disponibilidad de varios canales en esta investigación, se procedió a dividir el análisis en dos grupos de la siguiente manera:

- El primer grupo está conformado por los canales que van desde el 21 al 35. En este grupo se pudo observar que existía una gran variación de la disponibilidad temporal, este comportamiento se asemeja mucho más al que podríamos encontrar en un ambiente urbano densamente poblado.
- El segundo grupo está conformado por los canales que van desde el 36 al 51. La tendencia en este grupo de canales a presentar gran disponibilidad temporal a lo largo de todo el rango de medición, hace que este escenario sea considerado como un ambiente rural pese a que se encuentra en la ciudad, debido a la elevada probabilidad de encontrar hasta 11 canales conjuntos disponibles.

Un primer análisis realizado consiste en la evaluación del desempeño del algoritmo predictivo debido a que este se encarga de realizar la predicción de los valores de potencia para canal en específico, estos valores luego son llevados a su equivalente binario de disponibilidad, así se muestra a continuación la predicción de 3 canales cuyo criterio de elección se basó en mostrar el de mayor disponibilidad, disponibilidad media y disponibilidad baja.

4.1 Predicción de disponibilidad por canal

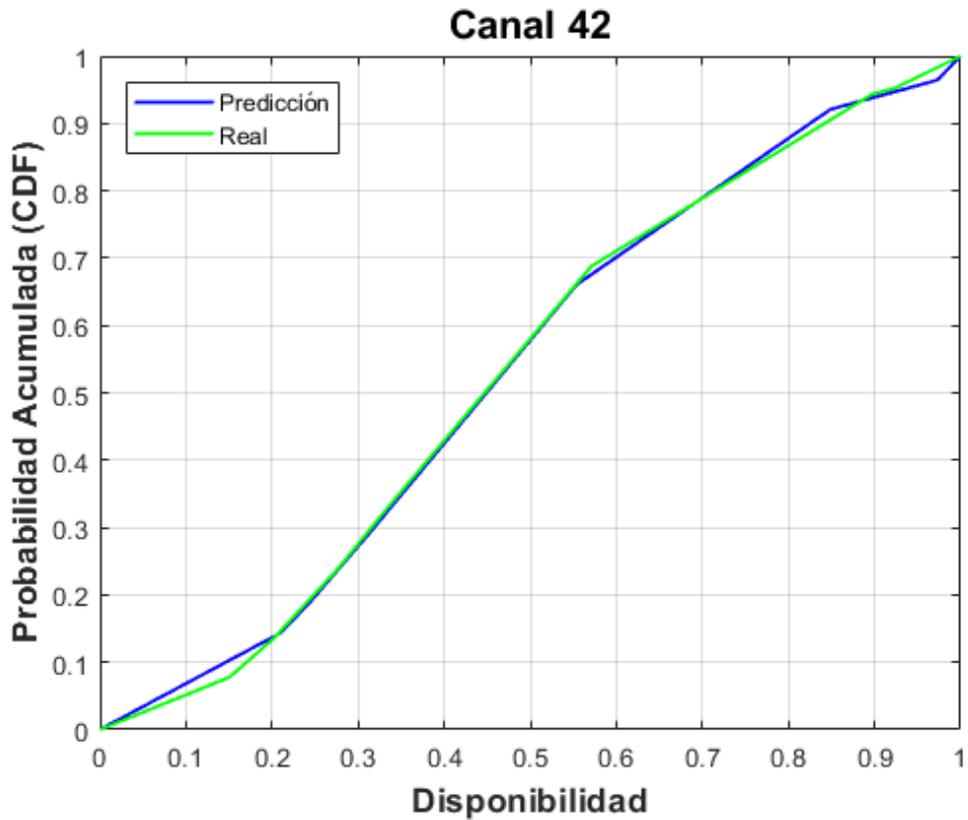


Figura 4. 1 Comportamiento de la predicción de un canal con disponibilidad media.

En la Figura 4.1 se muestra la disponibilidad que tiene el canal 42, cuya variabilidad lo hizo caracterizar como un canal con disponibilidad media. Podemos observar que la probabilidad de ocurrencia de una disponibilidad menor o igual al 50% del canal libre dentro del tiempo de medición es igual al 56%. Adicionalmente podemos observar la similitud entre los datos reales y los obtenidos del modelo predictivo.

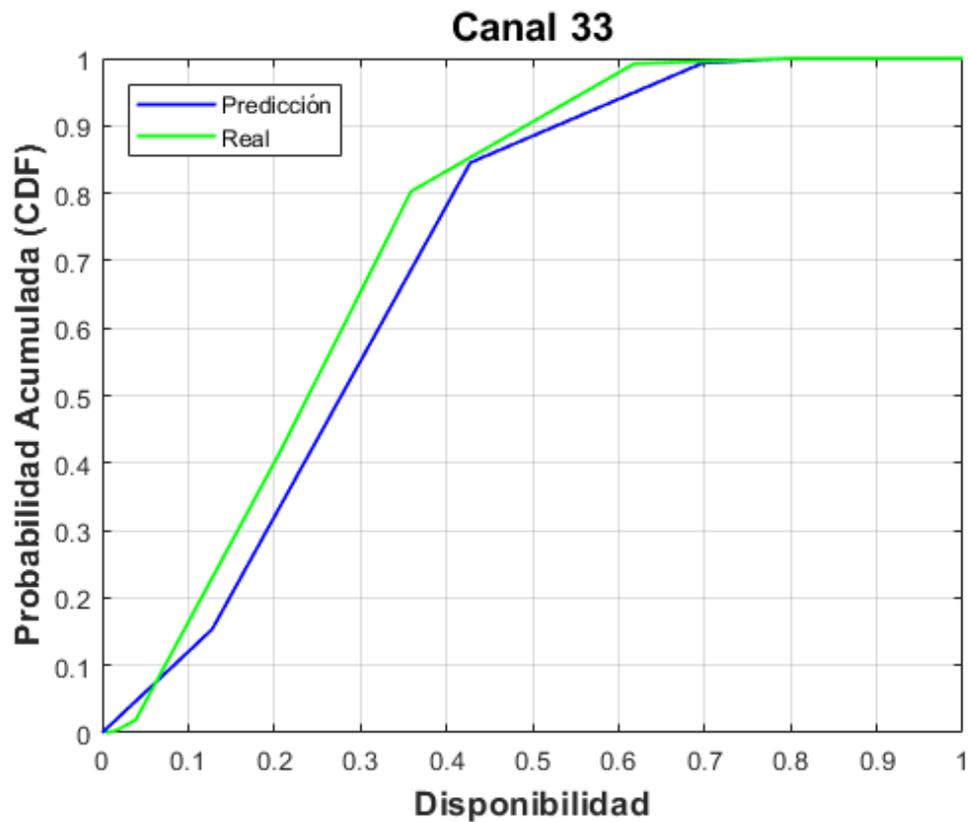


Figura 4. 2 Comportamiento de la predicción de un canal con disponibilidad baja.

En la Figura 4.2 se puede apreciar que la predicción para un canal con disponibilidad baja difiere de los datos reales, presentando un ligero incremento de la disponibilidad en el modelo real. Para este canal en particular se obtuvo que la probabilidad de tener una disponibilidad de hasta el 40% de canal libre dentro del intervalo de la medición es del 80% para el modelo predictivo frente al 84% que ofrece el modelo real.

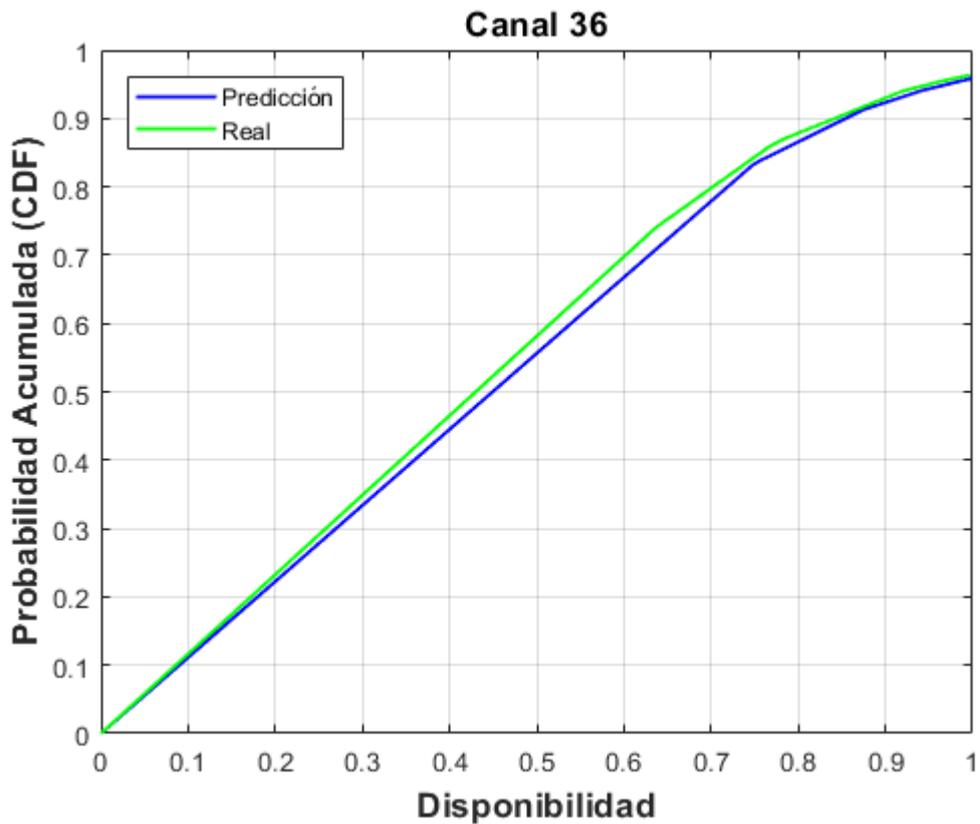


Figura 4. 3 Comportamiento de predicción de un canal con disponibilidad alta.

En la Figura 4.3 observamos que la predicción ofrece un pequeño porcentaje de disponibilidad extra frente a los datos reales. Esto quiere decir que para un canal con disponibilidad de ocurrencia alta como lo es el canal 36, la probabilidad de tener una disponibilidad dentro del intervalo de medición menor o igual al 70% es igual al 80% para los datos reales, frente al 77% que ofrece el modelo predictivo.

4.2 Predicción de n canales conjuntos por día

En esa sección se presentará el análisis por separado de los grupos de co-canales tal y como se describió al inicio de este capítulo, así tendremos en primer lugar un análisis para el primer grupo, en el cual se presenta la mayor variación de la disponibilidad.

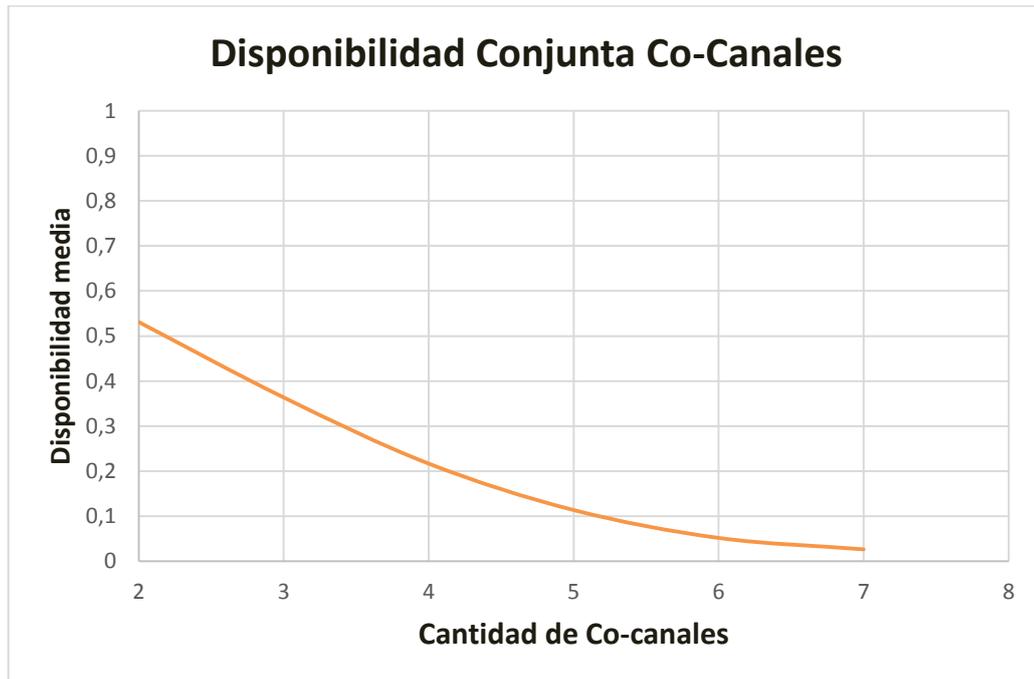


Figura 4.4 Disponibilidad Conjunta para primer grupo.

Como se puede apreciar en la figura 4.4 en el primer grupo la disponibilidad conjunta es bien limitada, debido a la variación que hay en este grupo de canales, se ofrece hasta 5 co-canales con un promedio de disponibilidad de 11% para un día completo, cabe recalcar que se tomó en consideración el día con la mayor disponibilidad conjunta para el análisis de los datos.

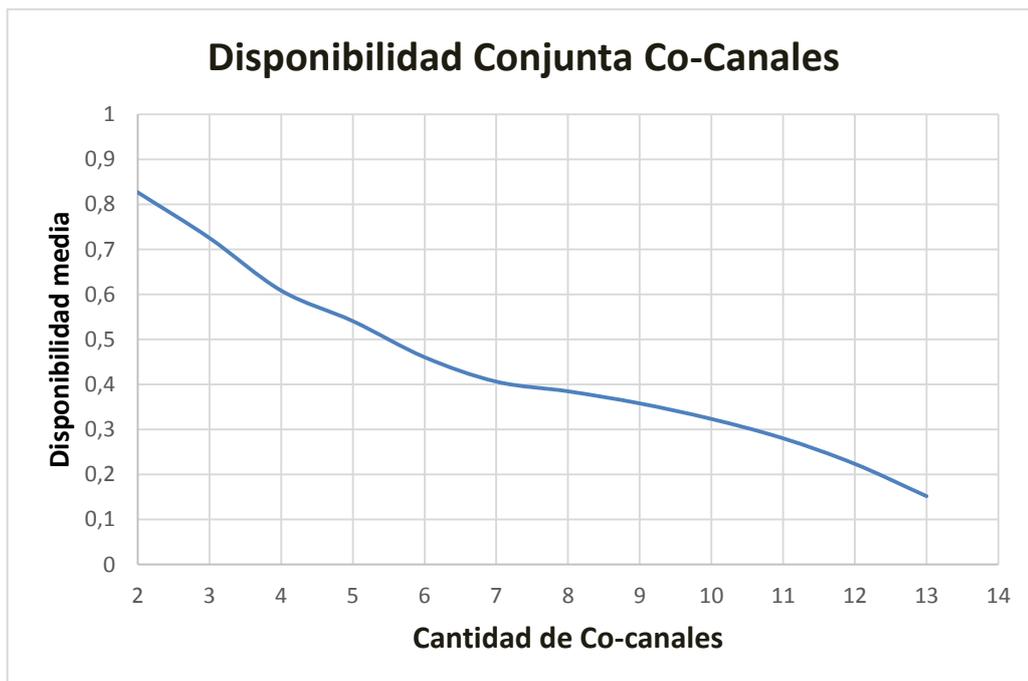


Figura 4.5 Disponibilidad conjunta para segundo grupo.

Tal y como podemos apreciar en la figura 4.5, para el segundo grupo el número de co-canales disponibles es mucho mayor con un estimado de hasta 12 co-canales con un promedio de 23% de disponibilidad para un día completo. Esto se debe a que este grupo presenta canales con alta disponibilidad temporal, lo cual en un escenario urbano denso no es probable que ocurra.

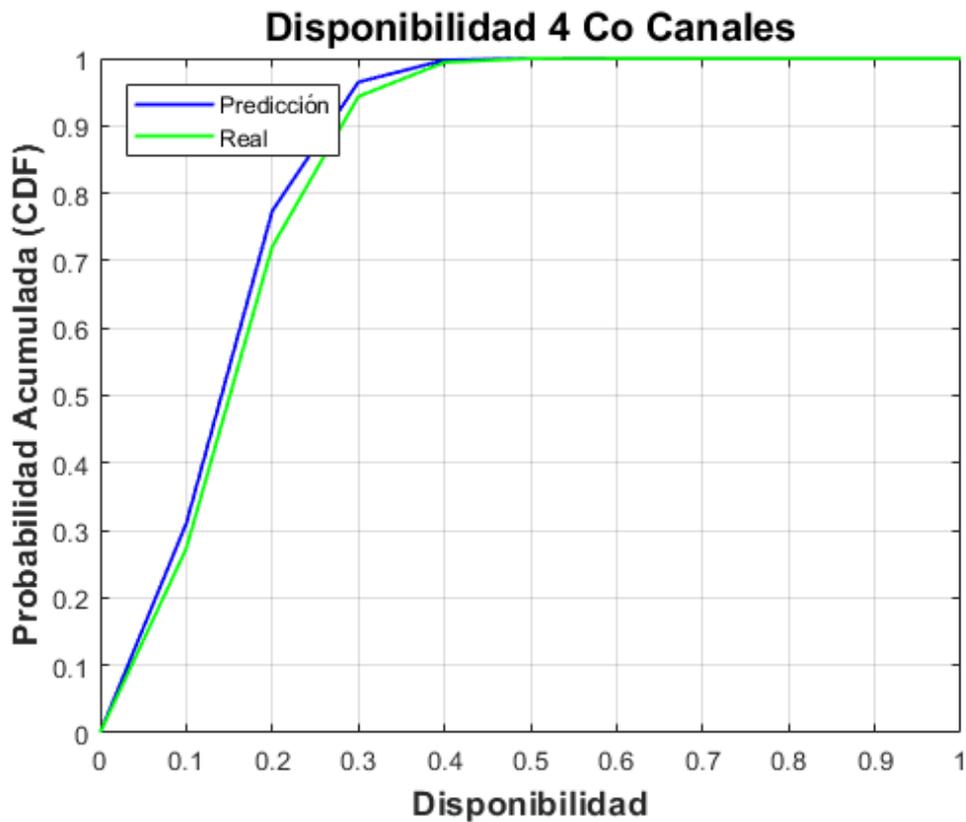


Figura 4.6 Disponibilidad Conjunta 4-Co canales primer grupo.

Como podemos apreciar en la figura 4.6 la probabilidad de tener grupos de disponibilidad formada por 4 canales conjuntos de manera simultánea con un promedio de tener hasta un 30% del día entero libre es: del 85% para los datos reales frente al 88% del modelo predictivo. Pese a que la disponibilidad es relativamente baja, la existencia de grupos con más de 3 canales conjuntos disponibles, permite que los anchos de banda que serán asignados a los usuarios secundarios sean mayores, permitiendo el acceso de mejores tecnologías inalámbricas.

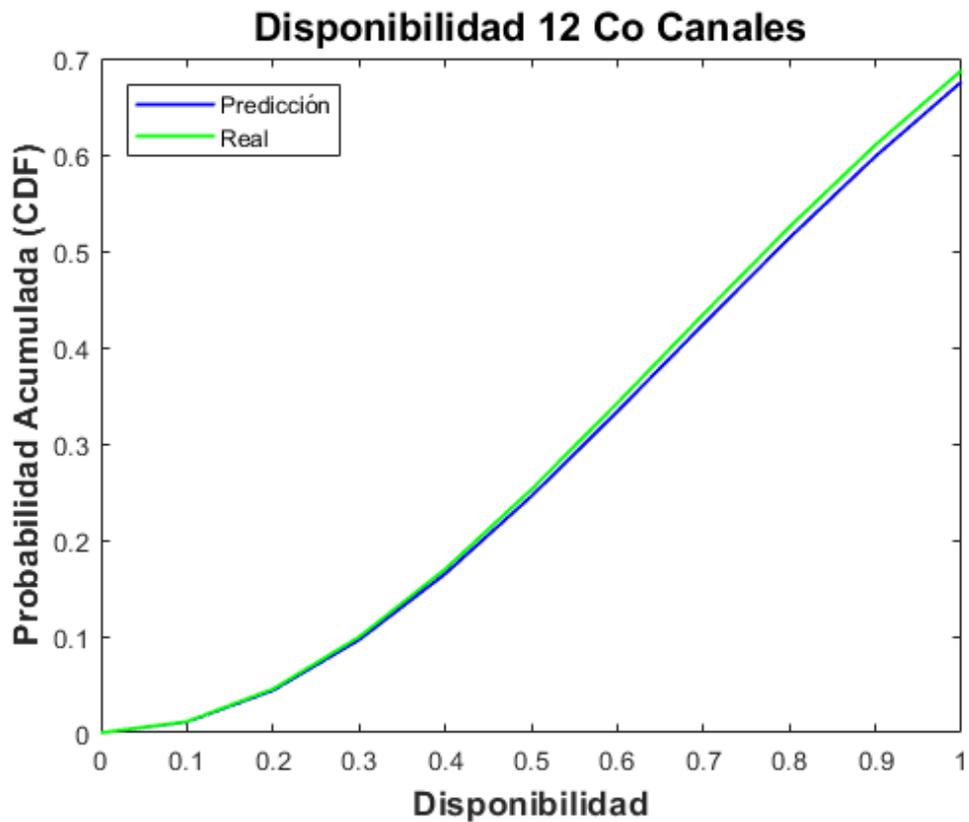


Figura 4.7 Disponibilidad Conjunta 12- Co canales segundo grupo.

Como habíamos mencionado al principio del análisis este grupo presenta una alta disponibilidad de co-canales. Tal y como se aprecia en la figura 4.7 se tiene hasta un promedio de 80% de disponibilidad de un grupo de 12 canales conjuntos con una probabilidad de ocurrencia del 50%. Para este grupo de estudio se pudo apreciar que la mayoría de canales se encontraban libre en más del 70% del tiempo de medición, es por ello que se cuenta con hasta 12 co-canales.

4.3 Disponibilidad Temporal de Co-canales

El objetivo de esta investigación comprende además, el análisis de la existencia de grupos de estos canales conjuntos que se encuentren libres en un mismo instante de tiempo. Así, el caso más sencillo será cuando para el mismo tiempo de medición/predicción, encontremos dos de estos canales conjuntos libres, los diferentes grupos de canales conjuntos que se formarán dependerá únicamente de cuantos de los mismos se encuentren libres en ese instante de tiempo. A continuación se muestra el análisis realizado para 2, 3 y 4 co-canales conjuntos y los grupos de los mismos que fueron encontrados.

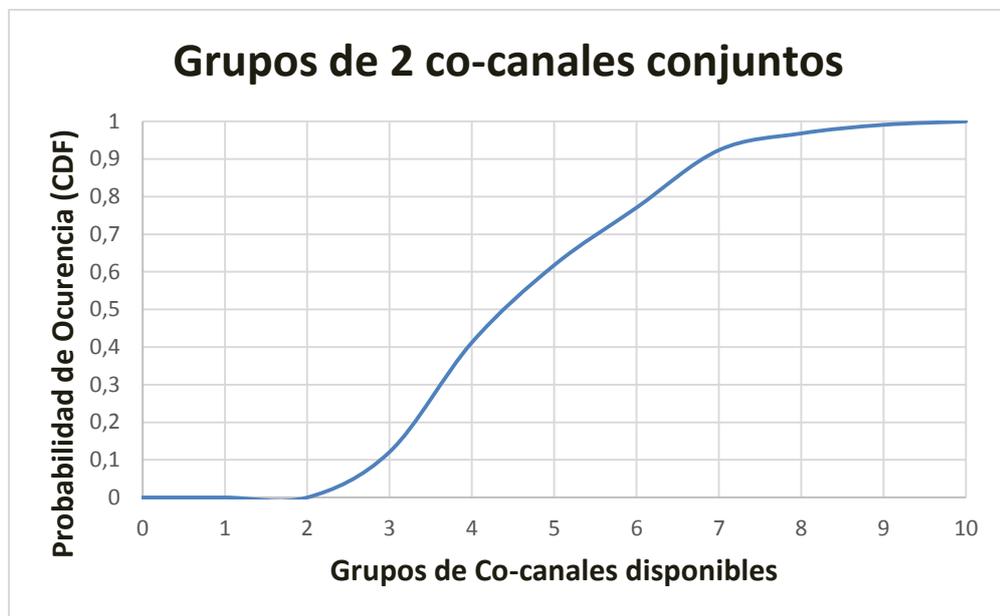


Figura 4.8 Disponibilidad temporal para grupos de 2 co-canales en el primer grupo.

En la figura 4.8 podemos observar la disponibilidad conjunta analizando el tiempo disponible que podremos encontrar durante todo un día de predicción para 2 co-canales, y la cantidad de grupos de estos que puedan existir. Así, para un total de 1099 minutos de disponibilidad entre todos los co-canales existentes, se puede concluir que la probabilidad de encontrar agrupaciones de co-canales con un número menor o igual a 7 grupos es igual al 92%.

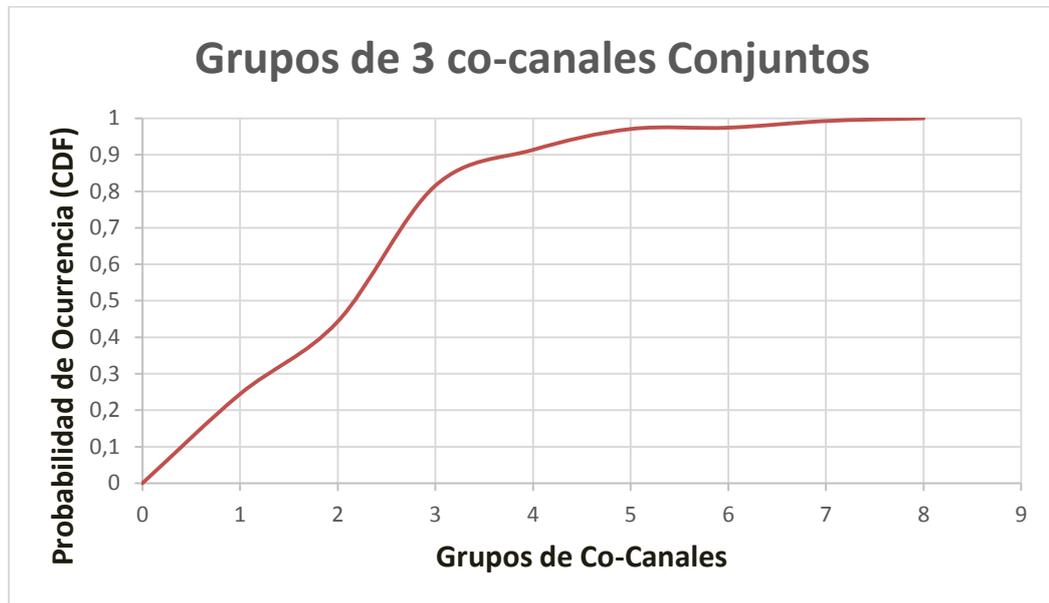


Figura 4.9 Disponibilidad temporal para grupos de 3 co-canales en el primer grupo.

Como se puede apreciar en la figura 4.9 al considerar la disponibilidad conjunta en función del tiempo que se encuentra libre durante todo un día de predicción, para grupos de 3 co-canales conjuntos, se obtiene un total de 1366 minutos de disponibilidad, de los cuales se puede concluir, que la probabilidad de encontrar agrupaciones de estos co-canales con un número menor o igual a 4 es igual al 90%.

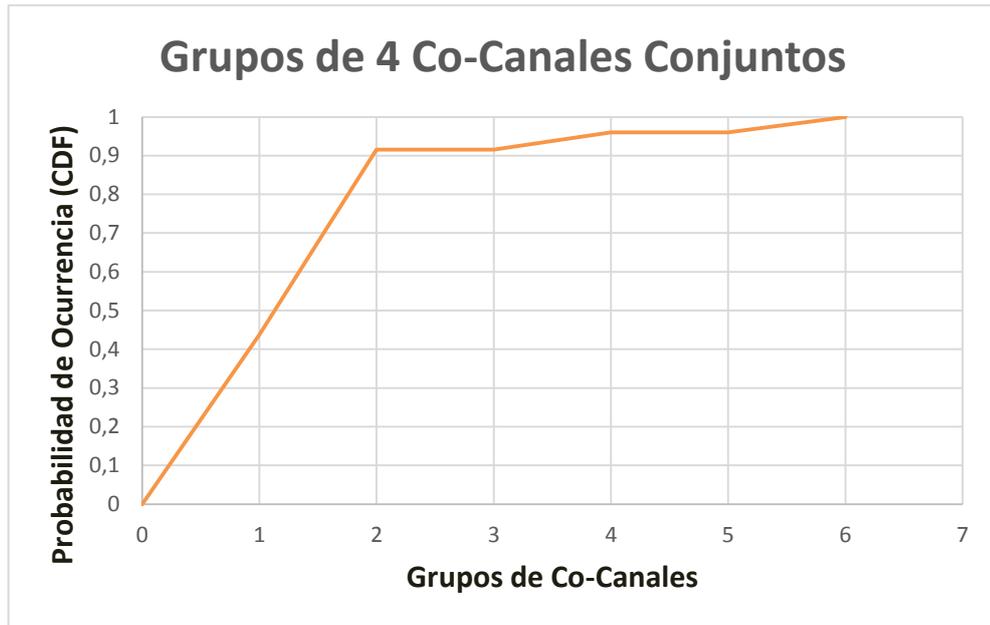


Figura 4.10 Disponibilidad temporal para grupos de 4 co-canales en el primer grupo.

En la figura 4.10 podemos observar la disponibilidad conjunta en función del tiempo disponible que podríamos encontrar durante un día de medición para grupos de 4 co-canales conjuntos. De los 876 minutos libres encontrados en total, se puede afirmar que con un 91.5% de probabilidad de ocurrencia se podrán encontrar agrupaciones de estos co-canales con un número menor o igual a 2.

4.4 Predicción no supervisada

La utilización de estos algoritmos tiene una fuerte implicación de carácter económico, con la finalidad de disminuir el consumo eléctrico y de recursos propios de los equipos. Para esto se procedió a evaluar el rendimiento del algoritmo sin que este sea reentrenado, y sin que el equipo realice mediciones de manera constante en determinados intervalos de tiempo. Los resultados obtenidos de las predicciones se muestran a continuación en diferentes escenarios.

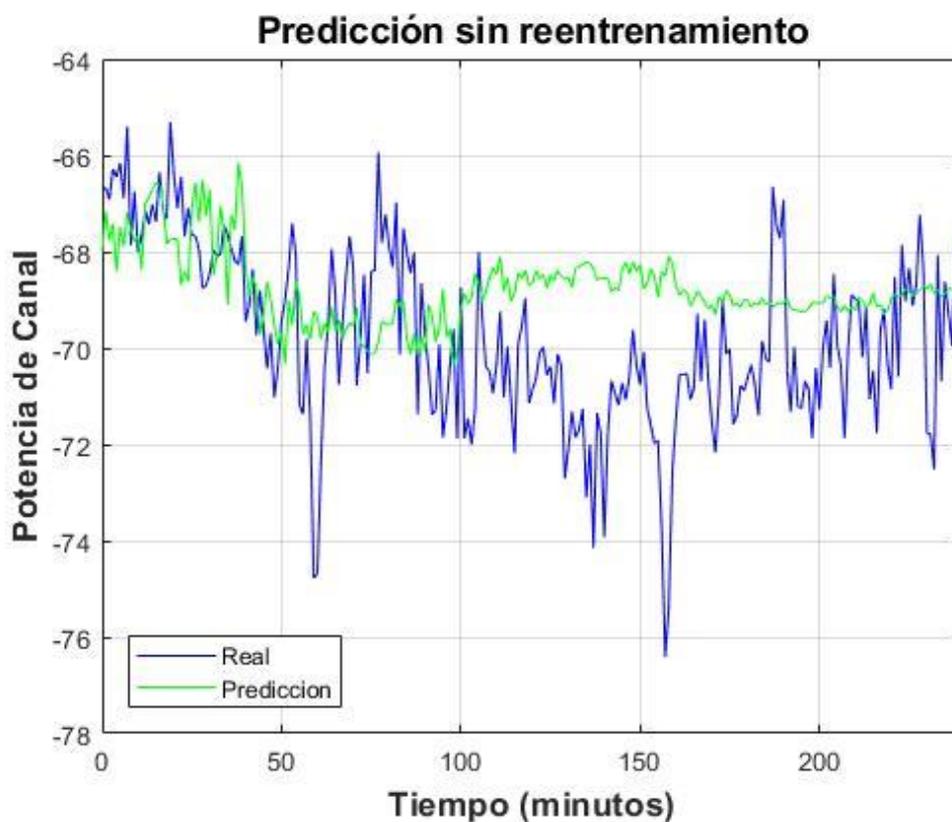


Figura 4.11 Predicción Parcial sin supervisión.

Para el caso de la figura 4.11 se procedió a entrenar el algoritmo con datos correspondientes a una hora de medición, se elaboró el modelo predictivo y se realizó la predicción de la siguiente hora. Luego de esto, no se volvió a utilizar los datos provenientes de las mediciones para que el algoritmo siga prediciendo, en su lugar, estos datos fueron reemplazados por los valores que eran obtenidos del modelo de predicción. Como podemos observar, el modelo sin necesidad de que sea re-entrenado y utilizando solo los datos de predicción puede arrojar valores

de potencia cercanos a la realidad hasta los 70 minutos aproximadamente. Luego de esto la predicción tendería a arrojar valores con una tendencia lineal, algo que en la vida real no sucede. Si estos valores de potencia son llevados a su equivalente en disponibilidad, tendríamos como resultado una reducción en la disponibilidad debido a los valores obtenidos sin que haya existido un reentrenamiento que asegure que el modelo se adapte a los nuevos datos.

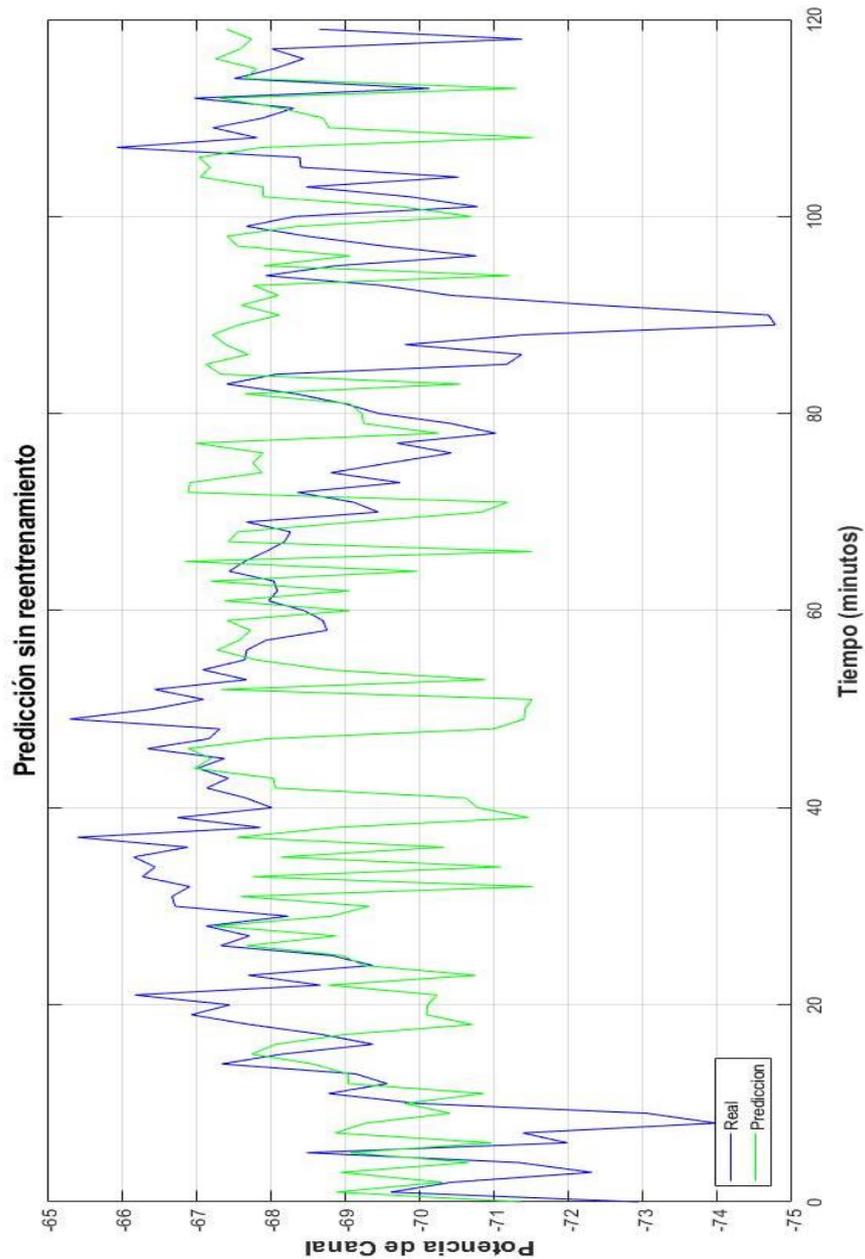


Figura 4.12 Predicción Parcial sin supervisión segundo caso

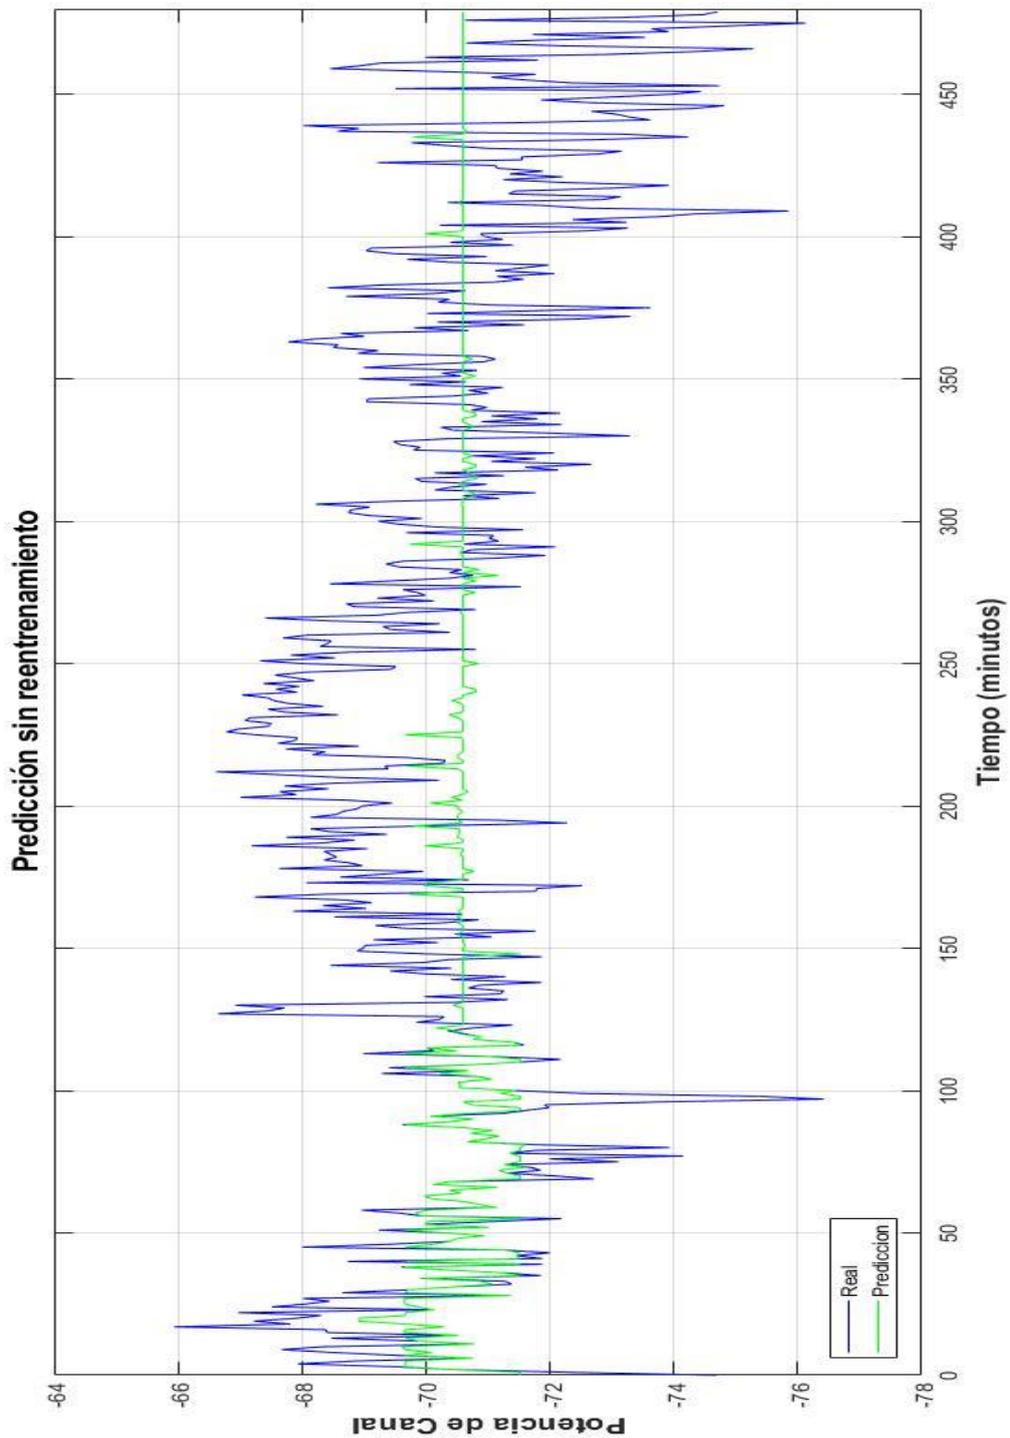


Figura 4.13 Predicción Parcial sin Supervisión tercer caso.

Para el caso de la figura 4.12 se procedió a utilizar 30 minutos de medición de los datos para el entrenamiento del algoritmo y para la primera predicción. Así mismo vemos como el algoritmo falla al intentar predecir con datos que no son reales. Se realizó una estimación de 30 minutos para comprobar que el uso de menos datos

tiende a que el algoritmo realice predicciones sin variación alguna, y además al no volver a re-entrenarse los valores de predicción son los mismos en cada iteración del mismo.

En la figura 4.13 se utilizó el equivalente a 120 minutos de medición para los datos de entrenamiento y de predicción, como se observa la predicción inicial es la que mejor se ajusta a los datos originales de los tres casos mencionados. Sin embargo, al no contar con el re-entrenamiento necesario y al utilizar solo los valores obtenidos del modelo para continuar con la predicción, el algoritmo falla a partir de la segunda predicción. Esto se debe a que la cantidad de datos que utiliza es mayor y si el modelo no se ajusta a los nuevos datos y utiliza valores antiguos para continuar prediciendo, no podrá predecir el comportamiento del canal porque no toma en consideración ninguna variación que ocurre en el mismo. Este algoritmo no puede modelarse como si los datos fueran estacionarios cuando el comportamiento de los mismos tiende a tener un comportamiento estocástico, es por ello que el re-entrenamiento es necesario, así como el uso de valores reales para poder ajustar a las condiciones del medio.

CONCLUSIONES Y RECOMENDACIONES

CONCLUSIONES

Las predicciones obtenidas demuestran la eficacia de las SVR para la predicción de valores basados en series de tiempo, sin embargo sin los reajustes necesarios, debido a que las señales de potencia son de tipo estocástico, no resulta viable utilizar este tipo de acercamiento para la resolución del problema, ya que implica mayor gasto de recursos de procesamiento para los equipos.

Se comprobó la importancia al momento de seleccionar la cantidad de datos necesarios que utilizará el algoritmo para su entrenamiento, debido a la variación que presentan los mismos. Los resultados obtenidos cuando se tomaba una mayor cantidad de datos de muestra implica entre otras cosas un mayor consumo de recurso por parte de los equipos así como errores en las predicciones.

Se logró analizar la existencia de grupos de co-canales que pueden ser utilizados para un mismo instante de tiempo en todo el espectro de análisis. La presencia de grupos de canales conjuntos libres para intervalos de tiempos iguales supone una re-asignación más eficiente del espectro dependiendo de las necesidades del usuario.

RECOMENDACIONES

Este tipo de algoritmo funciona de manera óptima cuando los datos son estacionarios, es decir que tienen un comportamiento que no varía en el tiempo, debido a que el algoritmo va perdiendo efectividad si los datos nuevos no siguen al modelo inicial. Queda como recomendación para el lector o para futuras investigaciones la implementación de algoritmos adaptivos que permitan aprender de los datos sin necesidad de la intervención humana.

Debido a la cantidad de recursos que implica el uso de este tipo de algoritmos para la predicción en tiempo real de series de tiempo no estacionarias, se recomienda considerar el tipo de tecnología a ser empleada antes de proponer a las SVR como una solución a cualquier tipo de problema a resolver.

BIBLIOGRAFÍA

- [1] *Cisco Visual Networking Index: Forecast and Methodology, 2016-2021*. CISCO, 2017.
- [2] A. Ecuador, "Agencia de Regulación y Control de las Telecomunicaciones | Ecuador » Espectro Radioeléctrico", *Agencia de Regulación y Control de las Telecomunicaciones | Ecuador*, 2017. [Online]. Available: <http://www.arcotel.gob.ec/espectro-radioelectrico/>.
- [3] *Aspectos Económicos y Financieros de la Asignación del Espectro*. Brasil: ITU, 2016.
- [4] R. López and S. Montejo Sánchez, "La Radio Cognitiva y su Impacto en el Uso Eficiente del Espectro de Radio", *Scielo.sld.cu*, 2015. [Online]. Available: http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1815-59282015000100004.
- [5] C. Cordeiro, K. Challapali, D. Birru and S. Shankar N, "IEEE 802.22: An Introduction to the First Wireless Standard based on Cognitive Radios", *Journal of Communications*, vol. 1, no. 1, 2006
- [6] "MINTEL reprograma el cronograma de evolución a la televisión digital terrestre", *TDT - Televisión Digital Terrestre*, 2016. [Online]. Available: <https://tdtecuador.mintel.gob.ec/que-es-tdt/>
- [7] Q. Zhao and A. Swami, "A Survey of Dynamic Spectrum Access: Signal Processing and Networking Perspectives", *2007 IEEE International Conference on Acoustics, Speech and Signal Processing - ICASSP '07*, 2007.
- [8] Y. Liang, K. Chen, G. Li and P. Mahonen, "Cognitive radio networking and communications: an overview", *IEEE Transactions on Vehicular Technology*, vol. 60, no. 7, pp. 3386-3407, 2011.
- [9] D. Xu and X. Liu, "Opportunistic spectrum access in cognitive radio networks: When to turn off the spectrum sensors," in *Proceedings of ACM of WICON*, 2010
- [10] "White spaces and dynamic spectrum access", *Itunews.itu.int*, 2015. [Online]. Available: <https://itunews.itu.int/en/5526-White-spaces-and-dynamic-spectrum-access-note.aspx>.
- [11] M. Coronel, L. Artieda and F. Novillo, "Análisis de Implementación en Ecuador de Sistemas Basados en el Estándar IEEE 802.22", ESPOL, Guayaquil, 2016.
- [12] M. Paguay and J. Abad, "Medición, Modelamiento y Análisis de Disponibilidad de Canales en la banda de 800 MHz, para el posible uso de Dispositivos de Acceso Óptimo al Espectro dentro de un Edificio ubicado en el sector norte de la ciudad de Guayaquil", ESPOL, Guayaquil, 2016.
- [13] J. Avilés Zavala and M. Ramírez Prado, "Medición Espectral y Análisis de la disponibilidad de canales en la banda FM(88.3-107.3 MHz) y modelamiento estadístico

para el posible uso de dispositivos con acceso oportunista al espectro en un edificio en el centro de la ciudad de Guayaquil.", ESPOL, Guayaquil, 2015.

[14] J. Gómez Ponce, "Modelado de la Disponibilidad de canales de la banda UHF-TV para el uso potencial de Sistemas con Acceso Oportunista al Espectro (OSA) en una zona urbana", ESPOL, Guayaquil, 2015.

[15] M. Kottkamp, A. Roessler and J. Schilenz, "LTE-Advanced Technology Introduction", Rohde&Schwarz, 2012.

[16] "TV White Spaces: Approach to Coexistence", Ofcom, 2013.

[17] I. Akyildiz, Won-Yeol Lee, M. Vuran and S. Mohanty, "A survey on spectrum management in cognitive radio networks", *IEEE Communications Magazine*, vol. 46, no. 4, pp. 40-48, 2008.

[18] "FCC Spectrum Policy Task Force: Report of the spectrum efficiency working group," November 2002.

[19] "Proceedings of the first IEEE Symposium on New Frontiers in Dynamic Spectrum Access Networks," November 2005.

[20] D. Hatfield and P. Weiser, "Property rights in spectrum: taking the next step," in Proc. of the first IEEE Symposium on New Frontiers in Dynamic Spectrum Access Networks, November 2005.

[21] L. Xu, R. Tonjes, T. Paila, W. Hansmann, M. Frank, and M. Albrecht, "DRiVE-ing to the Internet: Dynamic Radio for IP services in Vehicular Environments," in Proc. of 25th Annual IEEE Conference on Local Computer Networks, pp. 281 – 289, Nov. 2000.

[22] L. White, "Propertyizing the Electromagnetic Spectrum: Why It Is Important, and How to Begin," *Media Law and Policy*, vol. 19, pp. 29–30, 2000.

[23] B. Aazhang, J. Lilleberg, and G. Middleton, "Spectrum sharing in a cellular system," in Proc. of IEEE Eighth International Symposium on Spread Spectrum Techniques and Applications, pp. 355 –359, Aug. - Sept. 2004.

[24] T. Yucek and H. Arslan, "A survey of spectrum sensing algorithms for cognitive radio applications", *IEEE Communications Surveys & Tutorials*, vol. 11, no. 1, pp. 116-130, 2009.

[25] V. Vapnik. *Statistical Learning Theory*. John Wiley and Sons, 1998.

[26] Ben-Hur, Asa, Horn, David, Siegelmann, Hava, and Vapnik, Vladimir; "Support vector clustering" (2001) *Journal of Machine Learning Research*, 2: 125–137.

[27] "Machine Learning: What it is and why it matters", *Sas.com*, 2016. [Online]. Available: https://www.sas.com/en_us/insights/analytics/machine-learning.html.

[28] Á. Flores, S. Mladonado and R. Weber, "Selección de Atributos y Support Vector Machines adaptado al problema de fuga de Clientes", Universidad de los Andes, Santiago, 2015.

- [29] A. Montero, E. González, F. Garijo, F. Martín, V. Gómez, J. Arenas, Á. Navia and A. Figueiras, "Aplicaciones de aprendizaje no supervisado para la detección de patrones de fraude en telecomunicaciones", *Comunicaciones de Telefónica I+D*, no. 34, 2004.
- [30] Xin Z, Ying W, Bin Y: Signal classification method based on support vector machine and high-order cumulants. *Wirel. Sensor Netw.* 2010, 2(1):48-52.
- [31] N. Sapankevych and R. Sankar, "Time Series Prediction Using Support Vector Machines: A Survey", *IEEE Computational Intelligence Magazine*, vol. 4, no. 2, pp. 24-38, 2009.
- [32] Qiong Li, Yuchen Fu, Xiaoke Zhou and Yunlong Xu, "A Hybrid Support Vector Regression for Time Series Prediction", *2010 Third International Conference on Knowledge Discovery and Data Mining*, 2010.
- [33] MITOLA, J. AND G. Q. MAGUIRE Cognitive Radio: Making Software Radios More Personal. *IEEE Personal Comm.*, 1999, 6(4), 13-18.
- [34] I. Manjarrez Alva, "Radio Cognitiva", UNAM, México D.F, 2010.
- [35] J. Aguilar and A. Cadavid, "Radio Cognitiva - Estado del Arte", *Revista Sistemas y Telemática*, no. 9, pp. 31-50, 2011.
- [36] J. Arellanos, "Radios Cognitivos: Conectividad en zonas rurales utilizando espacios blancos de TV", Tecnológico de Monterrey, Monterrey, 2014.
- [37] B. Scholkopf and A. Smola, "Learning with Kernels", The MIT Press, London, 2001.
- [38] P. Alvarado, "Building the Machine Learning Infrastructure - Data Points", *Blogs.teradata.com*, 2016. [Online]. Available: <http://blogs.teradata.com/data-points/building-machine-learning-infrastructure-2/>.
- [39] E. Garcia, P. Rugel and F. Lozano, "Adaptive Support Vector Machines para predicción de series de tiempo.", Cali, 2006.
- [40] O. Manzanilla, "¿Qué son las SVM?", *Optimachine.blogspot.com*, 2008. [Online]. Available: <http://optimachine.blogspot.com/2008/03/qu-son-las-svm.html>.

ANEXOS

ABREVIATURAS

OSA:	Acceso Oportunista al Espectro.
CR:	Radio Cognitiva.
WS:	White Spaces.
DSA:	Acceso Dinámico al Espectro.
IEEE:	Instituto de Ingeniería Eléctrica y Electrónica.
3G	third generation (3ra generación de tecnología móvil).
4G	fourth generation(4ta generación de tecnología móvil).
WIFI:	Wireless Fidelity.
ITU:	Unión Internacional de Telecomunicaciones.
ARCOTEL:	Agencia de Regulación y Control de las Telecomunicaciones.
λ :	Umbral mínimo de recepción.
CDF:	Cumulative distribution function.
SVR:	Support Vector Regression
UHF:	Ultra High Frequency
VHF:	Very High Frequency

Códigos de Matlab

predSVRv2.m

```
function [pred]=predSVRv2(nombreHoja,dia)
%los parametros de entrada son el nombre de la hoja con los datos
%y la columna correspondiente al dia
%se asume que se tomaron 508 datos por hora
F=1;
B=120;
C=121;
D=240;
sim=':';
d_p= [];%variable usada para almacenar los datos de prediccion para que puedan ser
exportados.
i=1;
while(D<1440)
%se convierten en caracteres para poder colocar rango de aperturas de celdas
f_s=int2str(F);
b_s=int2str(B);
c_s=int2str(C);
d_s=int2str(D);
%el formato que se espera dar aqui es asi 'A1:A508
rango1=strcat(dia,f_s,sim,dia,b_s);
rango2=strcat(dia,c_s,sim,dia,d_s);
%entrenamiento inicial
if i==1
%Inicialmente se debe partir de datos existentes, para el entrenamiento
%inicial la variable hora2 es la funcion objetivo o los datos que queremos
%predecir mientras los datos de hora1 seran utilizados para el
%entrenamiento
hora1=xlsread(nombreHoja,3,rango1);
hora2=xlsread(nombreHoja,3,rango2);
rng default;
Mdl =
fitcsvm(hora1,hora2,'Solver','SMO','BoxConstraint',192.57,'KernelScale',0.12687,'Epsilon',0.1
895,'KernelFunction','linear','Standardize',true);
%la prediccion inicial se la realiza para evaluar la calidad de la
%prediccion con respecto a los datos de hora2
Prd1=predict(Mdl,hora1);
%actualiza el rango de los datos;
d_p=[hora1;Prd1];
%%si ya se han hecho mas de dos predicciones y pasan 2 horas entre
%%predicciones se reentrena para que se ajuste a los nuevos datos
elseif i~=2 && (rem(i,2)==0)
%reentrenamiento cada dos horas
horay=xlsread(nombreHoja,3,rango2);
%este nuevo modelo se reentrena tomando los datos actuales como funcion objetivo
%la finalidad de esto es que se ajuste a los nuevos datos si llegan a variar
rng default;
Mdl =
fitcsvm(horax,horay,'Solver','SMO','BoxConstraint',192.57,'KernelScale',0.12687,'Epsilon',0.1
895,'KernelFunction','linear','Standardize',true);
Prdy=predict(Mdl,horax);
d_p=[d_p;Prdy];
```

```

%actualiza el rango de los datos;
C=D+1;
D=D+120;
else
%predicción normal se la realiza cada vez que se ha vuelto a reentrenar en
%las horas impares
horax=xlsread(nombreHoja,3,rango2);
Prdx=predict(Mdl,horax);
d_p=[d_p;Prdx];
%actualiza el rango de los datos;
C=D+1;
D=D+120;
end
i=i+1;
end
%al final para este ejemplo se realiza una concatenación vertical de los
%datos de predicción correspondientes a todo el día
pred=d_p;
end

```

reordenar.m

```

clc;
for i=29:30
nam='C:\Users\hp\Desktop\Codigo1Prueba\PrediccionvC';
num=int2str(i);
ext='.xlsx';
var= strcat(nam,num,ext);
nombre=strcat(nam,num,ext);
archivo=xlsread(var,'A1:A1440');
xlswrite(nombre,archivo,2,'A1');
archivo2=xlsread(var,'A1441:A2880');
xlswrite(nombre,archivo2,2,'B1');
a2=xlsread(var,'A2881:A4320');
xlswrite(nombre,a2,2,'C1');
a3=xlsread(var,'A4321:A5760');
xlswrite(nombre,a3,2,'D1');
a4=xlsread(var,'A5761:A7200');
xlswrite(nombre,a4,2,'E1');
a5=xlsread(var,'A7201:A8640');
xlswrite(nombre,a5,2,'F1');
a6=xlsread(var,'A8641:A10080');
xlswrite(nombre,a6,2,'G1');
end

```

Error de Predicción	Lunes	Martes	Miércoles	Jueves	Viernes	Sábado	Domingo
Canal 21	0	0.0014	0.0028	0	0	0	0
Canal 22	0	0.0021	0.0014	0	0	0	0
Canal 23	0.3743	0.2403	0.0424	0.1632	0.3	0.2521	0.0111
Canal 24	0.3347	0.0278	0.0181	0.0986	0.0556	0.0514	0.1354
Canal 25	0.2937	0.4389	0.4701	0.4313	0.3389	0.3667	0.2368
Canal 26	0.3618	0.3771	0.375	0.3292	0.2472	0.2701	0.4299
Canal 27	0	0.0076	0.0556	0.2847	0.0486	0	0
Canal 28	0.3118	0.1306	0.1896	0.1903	0.2354	0.309	0.0007
Canal 29	0	0	0.0354	0.375	0.1875	0.2097	0.0278
Canal 30	0.0819	0.1111	0.0132	0.1764	0.0146	0.2937	0.0563
Canal 31	0	0	0	0	0	0	0
Canal 32	0.2514	0.2368	0.3132	0.1451	0.3639	0.1847	0.1701
Canal 33	0.3451	0.4368	0.2722	0.0389	0.0375	0.0042	0.0174
Canal 34	0	0	0	0	0	0	0
Canal 35	0.0083	0.0938	0.2215	0.1569	0.0632	0.0174	0.1528
Canal 36	0.034	0.0069	0.0417	0.4035	0.291	0.0028	0.4125
Canal 37	0	0	0	0	0	0	0
Canal 38	0	0.0028	0.0014	0.0062	0.0167	0.0396	0.0292
Canal 39	0	0	0	0	0	0	0
Canal 40	0	0	0	0	0	0	0
Canal 41	0	0	0	0	0	0	0
Canal 42	0.1208	0.2972	0.3479	0.4583	0.3549	0.4722	0.2312
Canal 43	0	0	0	0	0	0	0
Canal 44	0	0	0	0	0	0	0
Canal 45	0.0972	0	0	0	0	0.0833	0
Canal 46	0.0167	0.0083	0.0111	0.0049	0.0486	0.0083	0.0049
Canal 47	0	0	0	0	0	0	0
Canal 48	0.1951	0.1958	0.2736	0.3611	0.3368	0.3014	0.4208
Canal 49	0	0	0	0	0	0	0
Canal 50	0	0	0	0	0	0	0
Canal 51	0	0	0	0	0	0	0

Tabla 2. Error de predicción para cada canal por día de medición.

Grupos Disponibilidad	Cantidad
0	0
1	0
2	0
3	133
4	320
5	226
6	168
7	168
8	49
9	25
10	10
TOTAL	1099

Tabla 3. Grupos de Disponibilidad Conjunta de 2 canales.

Grupos Disponibilidad	Cantidad
0	0
1	334
2	271
3	509
4	134
5	78
6	5
7	25
8	10
TOTAL	1366

Tabla 3. Grupos de Disponibilidad Conjunta de 3 canales.

Grupos Disponibilidad	Cantidad
0	0
1	383
2	419
3	0
4	39
5	0
6	35
TOTAL	876

Tabla 4. Grupos de Disponibilidad Conjunta de 4 canales.