

Desarrollo de un algoritmo predictor de huecos espectrales para radio cognitiva

Anghye Roxanna Plata Gómez



UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO-MECÁNICAS
ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y DE
TELECOMUNICACIONES
BUCARAMANGA
2019

**Desarrollo de un algoritmo predictor de huecos espectrales para
radio cognitiva**

Anghye Roxanna Plata Gómez

Trabajo de grado para optar el título de ingeniero electrónico

Director:
David Eugenio Forero Martínez
MSc. en Ciencias de la información y las telecomunicaciones

Co-Director:
Homero Ortega Boada
PhD. en ingeniería electrónica

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO-MECÁNICAS
ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y DE
TELECOMUNICACIONES
BUCARAMANGA
2019

Agradecimientos

El autor expresa sus más sinceros agradecimientos a:

A la Universidad Industrial de Santander, principalmente a la escuela de ingeniería eléctrica, electrónica y telecomunicaciones (E3T), a todos sus docentes, personal administrativo y demás que fueron guías en esta etapa de formación académica.

Al grupo Radiogis, en cabeza de su director el profesor Homero Ortega Boada, y especialmente al profesor David Eugenio Forero Martínez director del proyecto por su colaboración y asesoría durante el desarrollo del trabajo de grado.

A los profesores Efrén Dario Acevedo Y Luis Fernando Pedraza, quien con sus conocimientos guiaron y apoyaron en este proyecto.

A todos mis compañeros, quienes me apoyaron y brindaron su más sincera amistad.

DEDICATORIA

A Dios, por brindarme sabiduría, salud y bienestar en los momentos que necesitaba.

A mi mamá, Lina quien fue mi mayor apoyo y motivación, gracias por su comprensión incondicional, su amor infinito y sus mejores deseos siempre, te amo mami.

A mi hermanos, Lina Marcela y David Steven que siempre estuvieron ahí incondicionalmente, y me brindaron su tiempo y espacio para llevar a cabo esta meta, gracias por nunca abandonarme y seguir siendo unidos a pesar de la distancia y las diferencias.

A mi novio, Andrés Fernando, por su amor, comprensión y ayuda en esta etapa, he crecido de manera positiva a tu lado y te agradezco por eso y por enseñarme que puedo ser cada día mejor.

A mi padrastro, David quien siempre ha estado para apoyar a mi mamá en cualquier momento de su vida.

A mi nona, Rosa, quien siempre fue mi ejemplo de superación y constancia, nona espero que siempre te sientas orgullosa de tu nieta que te recuerda con mucha nostalgia.

A mis amigos, quienes fueron un gran apoyo en esta última etapa de este proceso, gracias por los buenos momentos y por su más sincera amistad.

Y a todas las personas que pusieron una parte de su vida en hacer mejor la mía en el transcurso de mi carrera universitaria.

ANGHYE ROXANNA PLATA GÓMEZ

CONTENIDO

INTRODUCCIÓN	15
1 MARCO TEÓRICO	17
1.1 SERIES DE TIEMPO	17
1.1.1 Descomposiciones de series de tiempo.	17
1.1.1.1 Estimación de la tendencia.	18
1.1.1.2 Estimación de la estacionalidad.	19
1.2 MÉTODO DE BOX-JENKINS (ARIMA)	19
1.2.1 El operador de retardo B	20
1.2.2 Proceso autorregresivo (AR)	21
1.2.3 Proceso de promedio móvil (MA)	21
1.2.4 Proceso autorregresivo y promedio móvil (ARMA)	22
2 METODOLOGÍA	23
2.1 ANÁLISIS INICIAL DE LA SERIE	23
2.2 IDENTIFICACIÓN DEL MODELO	23
2.3 ESTIMACIÓN DE LOS PARÁMETROS DEL MODELO	24
2.4 VALIDACIÓN DEL MODELO	24
2.5 PREDICCIÓN	25
2.5.1 Error absoluto medio porcentual: (MAPE = mean absolute percentage error)	25
2.5.2 Raíz del error cuadrado medio (RMSE = root mean squared error)	25
2.5.3 Criterio de información de Akaike (AIC)	26
2.5.4 Criterio de información Bayesiana (BIC)	26
3 DESARROLLO DEL ALGORITMO	27
3.1 ADQUISICIÓN DE DATOS	27
3.1.1 Antena Monopolo	27
3.1.2 Analizador de espectro.	28

3.1.2.1	Software HMEexplorer	29
3.2	ANÁLISIS DE LA SERIE DE TIEMPO	33
3.2.1	Ciclo de trabajo	33
3.2.2	Antena	36
3.2.3	USRP NI 2920	38
3.2.4	GNU Radio	40
3.2.4.1	Montaje de transmisión	41
3.2.5	Montaje de recepción	45
3.2.6	ACF (Sample Autocorrelation Function)	49
3.2.7	PACF (Sample Partial Autocorrelation Function)	51
3.3	MODELO DE ESTIMACIÓN ARIMA	52
3.3.1	Selección del modelo verificando comportamiento de residuos	54
3.3.1.1	ARIMA(4,0,2)	54
3.3.1.2	ARIMA(4,0,3)	60
3.3.1.3	ARIMA(4,1,3)	66
3.4	CONFIGURACIÓN Y DESARROLLO DEL ALGORITMO	72
3.4.1	Matlab	73
3.4.1.1	Función ARIMA	73
3.4.1.2	Forecast	74
4	PRUEBAS Y RESULTADOS	77
4.1	CONJUNTOS DE ENTRENAMIENTO Y EVALUACIÓN	77
4.2	VALIDACIÓN DEL MODELO DE PREDICCIÓN	79
5	CONCLUSIONES	86
6	TRABAJOS FUTUROS	88
	BIBLIOGRAFÍA	89

LISTA DE FIGURAS

Figura 1	Diagrama de bloques del montaje utilizado.	27
Figura 2	Antena Monopolo.	28
Figura 3	Parámetro S11 para la antena monopolo.	28
Figura 4	Diagrama de flujo del script utilizado.	30
Figura 5	Análisis potencia vs frecuencia comprendido entre 0.85 – 1.9 GHz	31
Figura 6	Estampa de agua en la banda de 0.85 – 1 GHz.	32
Figura 7	Ciclo de trabajo promedio	34
Figura 8	Ciclo de trabajo durante 24 horas.	35
Figura 9	Montaje utilizado para las pruebas de transmisión y recepción . . .	36
Figura 10	Parámetro S11.	37
Figura 11	USRP NI 2920	39
Figura 12	Montaje de transmisión	42
Figura 13	Montaje de transmisión en GNU	42
Figura 14	Señal generada por GNU	45
Figura 15	Montaje de recepción.	46
Figura 16	Ciclo de trabajo de los 5 canales afectado por las transmisiones. .	46
Figura 17	Gráfica de serie de tiempo para los 3 canales	48
Figura 18	Función de autocorrelación simple (ACF o FAS)	50
Figura 19	Función de autocorrelación parcial (PACF o FAP)	51
Figura 20	Diagrama de flujo para la estimación ARIMA	53
Figura 21	Gráfica residuos para ARIMA(4,0,2) para la serie de tiempo de ocupación alta	55
Figura 22	Gráfica residuos para ARIMA(4,0,2) para la serie de tiempo de ocupación media	57
Figura 23	Gráfica residuos para ARIMA(4,0,2) para la serie de tiempo de ocupación baja	59
Figura 24	Gráfica residuos para ARIMA(4,0,3) para la serie de tiempo de ocupación alta	61

Figura 25	Gráfica residuos para ARIMA(4,0,3) para la serie de tiempo de ocupación media	63
Figura 26	Gráfica residuos para ARIMA(4,0,3) para la serie de tiempo de ocupación baja	65
Figura 27	Gráfica residuos para ARIMA(4,1,3) para la serie de tiempo de ocupación alta	67
Figura 28	Gráfica residuos para ARIMA(4,1,3) para la serie de tiempo de ocupación media	69
Figura 29	Gráfica residuos para ARIMA(4,1,3) para la serie de tiempo de ocupación baja	71
Figura 30	Diagrama de flujo que describe el algoritmo	76
Figura 31	Tiempo de observación vs Error RMSE.	78
Figura 32	Ciclo de trabajo real y predicho.	80
Figura 33	Tiempo de observación y predicho.	84
Figura 34	Comparación entre el tiempo real y el predicho.	85

LISTA DE TABLAS

Tabla 1	Factores típicos de la antena.	38
Tabla 2	Parámetros del USRP en transmisión.	40
Tabla 3	Parámetros del USRP en recepción.	40
Tabla 4	Configuración de parámetros de los bloques.	45
Tabla 5	Comparación de modelos	54
Tabla 6	Resultados estimación modelo ARIMA(4,0,2) para el serie de tiempo de ocupación alta	56
Tabla 7	Resultados estimación modelo ARIMA(4,0,2) para el serie de tiempo de ocupación media	58
Tabla 8	Resultados estimación modelo ARIMA(4,0,2) para el serie de tiempo de ocupación baja	60
Tabla 9	Resultados estimación modelo ARIMA(4,0,3) para el serie de tiempo de ocupación alta	62
Tabla 10	Resultados estimación modelo ARIMA(4,0,3) para el serie de tiempo de ocupación media	64
Tabla 11	Resultados estimación modelo ARIMA(4,0,3) para el serie de tiempo de ocupación baja	66
Tabla 12	Resultados estimación modelo ARIMA(4,1,3) para el serie de tiempo de ocupación alta	68
Tabla 13	Resultados estimación modelo ARIMA(4,1,3) para el serie de tiempo de ocupación media	70
Tabla 14	Resultados estimación modelo ARIMA(4,1,3) para el serie de tiempo de ocupación baja	72
Tabla 15	Error relativo porcentual para el ciclo de trabajo.	80
Tabla 16	Posibles huecos espectrales para el canal de ocupación alta.	81
Tabla 17	Posibles huecos espectrales para el canal de ocupación media.	82
Tabla 18	Posibles huecos espectrales para el canal de ocupación baja.	83

Tabla de Acrónimos.

Siglas	Significado
AR	Autoregressive model(Modelo autorregresivo)
MA	Moving-average model (Modelo de media móvil)
ARMA	Autoregressive–moving-average model (Modelo autorregresivo de media móvil)
ARIMA	Autoregressive integrated moving average model (Modelo autorregresivo integrado de promedio móvil)
MAPE	Mean absolute percentage error (Error porcentual absoluto medio)
RMSE	Root mean squared error (Error cuadrático medio)
AIC	Akaike information criterion (Criterio de información de Akaike)
BIC	Bayesian information criterion (Criterio de información Bayesiana)
USRP	Universal Software Radio Peripheral (Software Universal Radio Periférico)
CR	Cognitive radio (Radio cognitiva)
SARMA	Seasonal autoregressive model of moving average (Modelo autorregresivo estacional de media móvil)
SARIMA	Seasonal autoregressive integrated model of moving average (Modelo estacional autorregresivo integrado de promedio móvil)
DER	Desviación estándar residual
HF	High frequency (Altas frecuencias)
VHF	Very high frequency (Muy altas frecuencias)
UHF	Ultra high frequency (Ultra altas frecuencias)
CNABF	Cuadro Nacional de Atribución de Bandas de Frecuencia
ACF	Autocorrelation function
FAS	Función de autocorrelación simple
PACF	Partial autocorrelation function
FAP	Función de autocorrelación parcial
FFT	Fast Fourier transform(Transformada rápida de Fourier)

RESUMEN

Título: DESARROLLO DE UN ALGORITMO PREDICTOR DE HUECOS ESPECTRALES PARA RADIO COGNITIVA¹

Autor: Anghye Roxanna Plata Gómez²,

Palabras Clave: Hueco espectral, radio cognitiva, modelos ARIMA, series de tiempo, espectrograma.

DESCRIPCIÓN:

El presente proyecto de investigación establece el diseño de un algoritmo predictor de huecos espectrales para la implementación de un sistema de radio cognitiva, con el objetivo de predecir valores de frecuencia que no están siendo utilizados.

Para el diseño del algoritmo se analizó la banda de 850 a 1900 [MHz], con el fin de conocer el comportamiento y poder interpretar esta información en una serie de tiempo y utilizando la metodología Box-Jenkins poder determinar un modelo de predicción ARIMA que se ajuste a esta y así realizar un pronóstico de los valores futuros.

Para la implementación de dicho algoritmo se utilizaron las herramientas computacionales que Matlab provee, con el fin de realizar cálculos rápidos y sencillos; para esta implementación fue necesario realizar las pruebas para determinar los conjuntos de entrenamiento y evaluación con el fin de obtener errores de predicción aceptables comparados con investigaciones de este tipo.

Finalmente, el algoritmo predictor utiliza un conjunto de entrenamiento de 3 horas para ajustar los valores de los coeficientes del proceso AR y MA del modelo ARIMA; el conjunto de evaluación contiene 6 horas dividido en dos conjuntos, el de observación que determina el posible patrón que tiene la serie de tiempo y el de predicción que arroja el vector de datos predichos.

¹ Trabajo de Grado

² Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones. Director: David Eugenio Forero Martínez, MSc. Co-Director: Homero Ortega Boada, PhD.

ABSTRACT

Title: DEVELOPMENT OF A PREDICTOR OF WHITE SPACES ALGORITHM FOR COGNITIVE RADIO¹

Author: Anghye Roxanna Plata Gómez²

Keywords: White space, cognitive radio, ARIMA models, time series, spectrogram.

DESCRIPTION:

The present research project establishes the design of a predictive algorithm for spectral gaps for the implementation of a cognitive radio system, with the aim of predicting frequency values that are not being used.

For the design of the algorithm, the band was analyzed from 850 to 1900 [MHz], in order to know the behavior and to be able to interpret this information in a series of time and using the Box-Jenkins methodology to be able to determine an ARIMA prediction model that adjust to this and thus make a forecast of future values.

For the implementation of this algorithm, the computational tools that Matlab provides were used, in order to perform quick and simple calculations; for this implementation it was necessary to perform the tests to determine the training and evaluation sets in order to obtain acceptable prediction errors compared with investigations of this type.

Finally, the predictive algorithm uses a 3-hour training set to adjust the values of the AR and MA process coefficients of the ARIMA model; The evaluation set contains 6 hours divided into two sets, the observation that determines the possible pattern that has the series of time and the prediction that throws the vector of predicted data.

¹ Bachelor Thesis

² Faculty of Physics-Mechanics Engineering. School of Electric, Electronic and Telecommunications Engineering. Advisor: David Eugenio Forero Martínez, MSc. Co-Advisor: Homero Ortega Boada, PhD.

INTRODUCCIÓN

“La utilización y apropiación de tecnologías de la información y las comunicaciones (TIC) tiene un impacto positivo en la salvaguardia de la paz y el desarrollo social y económico de los Estados. Las radiocomunicaciones son parte esencial de las TIC y como tal representan un elemento indispensable para promover el desarrollo de las Naciones.”¹

Actualmente en nuestro país, la demanda de espectro para la consolidación de servicios inalámbricos como los sistemas de comunicaciones móviles, las redes de televisión digital terrestre o los diversos sistemas de acceso inalámbrico de banda ancha, es elevada. Sin embargo, hay que tomar en cuenta que no todas las bandas del mismo son aptas para cualquier servicio o sistema, sino que, por el contrario, determinadas zonas del espectro están especialmente indicadas para proporcionar servicios concretos.²

Según la NTIA,³ (National Telecommunications and Information Administration) Radio Cognitiva (CR) es un sistema que detecta su entorno electromagnético de operación y puede ajustar de forma dinámica y autónoma sus parámetros de operación para modificar el funcionamiento del mismo, pues con esto se puede maximizar el rendimiento, reducir la interferencia y facilitar la interpolaridad.

La radio cognitiva permite el acceso dinámico al espectro de forma que se pueda compartir y aprovechar el ancho de banda, lo que hace que opere en el mejor canal disponible. CR permite el uso del espectro no utilizado temporalmente conocido como huecos espectrales o espacios en blanco, estos son una banda de frecuencias donde el espectro electromagnético no está siendo utilizado; Además, si una de estas bandas es usada

¹ Cuadro Nacional de atribución de bandas de Frecuencias [en línea].[Consultado: 2 de octubre de 2018] Disponible en: www.cnabf.ane.gov.co.

² Ente Nacional de comunicaciones (ENACOM) [en línea]. [Consultado: 10 de octubre de 2018]. Disponible en: www.enacom.gob.ar.

³ National Telecommunications and Information Administration [en línea].[Consultado: 2 de octubre de 2018] Disponible en: www.ntia.doc.gov

por un usuario con licencia, CR hace que se mueva a otro hueco espectral o se quede en la misma banda alterando su nivel de potencia de transmisión o esquema de modulación para evitar la interferencia. En los últimos años se han investigado diferentes formas de implementar la CR, cada una de ellas proporciona ciertas ventajas frente a las otras, las implementaciones básicas están basadas en: medición de potencia, bases de geolocalización, algoritmos predictivos o en algunos casos combinación de estas. Vale la pena destacar los algoritmos predictivos que combinados con una base de datos de geolocalización permiten encontrar huecos espectrales con porcentajes de error bajos. Basados en investigaciones ya realizadas de este tipo, en este proyecto se implementó un algoritmo de predicción basado en el modelo ARIMA, con ayuda de herramientas computacionales como Matlab.

Teniendo en cuenta lo anterior se planteó el objetivo general del presente trabajo, el cual es: *"Desarrollar un algoritmo predictor de huecos espectrales para la implementación de radio cognitiva en bandas UHF."*. Así mismo, se plantearon los siguientes objetivos específicos:

- Recopilar información acerca de técnicas de implementación de radio cognitiva basado en algoritmos de predicción.
- Determinar posibles huecos espectrales mediante un barrido en el espectro de frecuencias de 0.85-1.9 [GHz].
- Implementar el algoritmo de predicción mediante una estructura computacional que permita detectar huecos espectrales mediante un modelo ARIMA.
- Diseñar un prototipo de validación utilizando radio definido por software.

Los resultados de este trabajo se encuentran organizados en este documento de la siguiente manera: en el primer capítulo se describe el marco teórico incluyendo conceptos de series de tiempo y método Box-Jenkins (ARIMA). En el segundo capítulo se encuentra una descripción de la metodología utilizada para la estimación del modelo ARIMA. Basados en esto, en el capítulo 3 se desarrolla el algoritmo; esto incluye el estudio de la serie de tiempo, la deducción del modelo ARIMA, además se define la estructura general del algoritmo y se implementa en Matlab. Por último en el capítulo 4 y 5 se presentan los resultados, conclusiones y posibles trabajos futuros.

Capítulo 1

MARCO TEÓRICO

1.1. SERIES DE TIEMPO

Una serie de tiempo es una secuencia cronológica de observaciones de una variable particular. Estas observaciones serán denotadas por:

$$y(t_1), y(t_2), \dots, y(t_n) = y(t) : t \in T \quad (1.1)$$

Con $y(t_i)$ como el valor de la variable en el instante t_i . Si $T = Z$ se dice que la serie de tiempo es discreta y si $T = R$ se dice que la serie de tiempo es continua.

Cuando $t_{i+1} - t_i = k$ para todo $i = 1, \dots, n - 1$, se dice que la serie es equiespaciada, en caso contrario será no equiespaciada⁴.

1.1.1 Descomposiciones de series de tiempo. El primer paso para analizar una serie de tiempo es graficarla, lo que permitirá descubrir patrones históricos y componentes, que puedan ser útiles en la predicción. Para identificar estos patrones es conveniente pensar que una serie de tiempo se compone de varios componentes⁵.

- ❖ **Tendencia ($T(t)$):** Es el componente de largo plazo que representa el crecimiento o disminución en la serie sobre un periodo amplio. También puede definirse como cambios en la media.
- ❖ **Ciclo ($C(t)$):** Se refiere a movimientos hacia arriba y abajo en forma de onda alrededor de la tendencia. Los patrones cíclicos tienden a repetirse en los datos

⁴ Fuente: BOX G.; JENKINS G. Y Reinsel G., "Time series analysis, forecasting and control.", 3ra Ed, New Jersey, USA: Prentice Hall, 1994.

⁵ Fuente: Ibid

aproximadamente cada dos, tres o más años.

- ❖ **Variación estacional ($S(t)$):** Se refiere al patrón periódico que ocurre y se repite cada determinado tiempo. En el caso de series mensuales, el componente estacional mide la variabilidad de las series cada enero, febrero, etc.
- ❖ **Componente irregular ($A(t)$):** Se refiere a la parte de la serie de tiempo que no sigue un patrón regular, ni reconocible. Tal componente representa “lo que queda” en una serie de tiempo después de que la tendencia, el ciclo y la variación estacional han sido explicadas. Existen tres modelos de series de tiempos, que generalmente se aceptan como buenas aproximaciones a las verdaderas relaciones, entre los componentes de los datos observados.

Estos son:

- ❖ **Aditivo:**

$$Y(t) = T(t) + C(t) + S(t) + A(t) : \quad (1.2)$$

- ❖ **Multiplicativo:**

$$Y(t) = Y(t) = T(t) * C(t) * S(t) * A(t) \quad (1.3)$$

- ❖ **Mixto:**

$$Y(t) = T(t) * C(t) * S(t) + A(t) \quad (1.4)$$

Donde:

$Y(t)$ es la serie observada.

$T(t)$ es la componente de tendencia.

$C(t)$ es el componente cíclico.

$S(t)$ es el componente estacional.

$A(t)$ es el componente aleatorio.

Una suposición usual es que $A(t)$ es un componente aleatorio o ruido blanco con media cero y varianza constante. Un modelo aditivo, es adecuado, cuando $C(t)$ o $S(t)$ no depende de otras componentes, como $T(t)$; si por el contrario el componente cíclico y estacional varían con la tendencia, el modelo más adecuado es un modelo multiplicativo.

1.1.1.1 Estimación de la tendencia. Una forma de visualizar la tendencia es mediante suavizamiento de la serie. La idea central es definir, a partir de la serie ob-

servada, una nueva serie que suaviza los efectos ajenos a la tendencia (estacionalidad, efectos aleatorios), de manera que podamos determinar la dirección de la tendencia.⁶

1.1.1.2 Estimación de la estacionalidad. La estimación de la estacionalidad no sólo se realiza con el fin de incorporarla al modelo para obtener predicciones, sino también con el fin de eliminarla de la serie para visualizar otras componentes como tendencia y componente irregular que se pueden confundir en las fluctuaciones estacionales.⁷ De acuerdo con los modelos clásicos, se asume el siguiente modelo para $T(t)$,

$Y(t) - T(t) = S(t) + C(t) + A(t)$ Aditivo

$\frac{Y(t)}{T(t)} = S(t) * C(t) + \frac{A(t)}{T(t)}$ Mixto

Si no hay tendencia, se espera:

$\forall t, T(t) = 0$ En modelos aditivos

$\forall t, T(t) = 1$ En modelos mixtos

1.2. MÉTODO DE BOX-JENKINS (ARIMA)

Existen dos metodologías desarrolladas por Box y Jenkins que permiten predecir valores futuros de una serie de tiempo basándose en valores pasados de una sola variable o dos variables entre las que existe una relación causal.⁸ Para el caso específico de solución al problema expuesto, se expondrá y desarrollará en el método de Box-Jenkins univariable.

Modelos univariantes de series temporales:

$$Y_t = f(Y_{t-1}, Y_{t-2}, \dots) + A_t \quad (1.5)$$

$$Y_t = y = \hat{Y}_t + A_t \quad (1.6)$$

Donde:

Y_t = Serie observada

$\hat{Y}_t$ = Componente predecible

A_t = Componente aleatorio (ruido blanco)

⁶ Fuente: BOX G.; JENKINS G. Y Reinsel G., "Time series analysis, forecasting and control.", 3ra Ed, New Jersey, USA: Prentice Hall, 1994.

⁷ Fuente: Ibid

⁸ Fuente: Ibid.

Existen dos enfoques básicos para obtener Y_t : postular $\hat{Y}_t$, u obtener A_t y la serie. Los métodos clásicos buscan $\hat{Y}_t$ y el enfoque Box-Jenkins se centra en A_t .

La metodología de Box y Jenkins requiere que la serie sea estacionaria. Si la serie no es estacionaria, en general se puede convertir en una serie estacionaria mediante el método de diferenciación.

Una serie de tiempo es estacionaria si su media, su varianza y su covarianza permanecen constantes sin importar el momento en el cual se midan. Para el tratamiento de la no estacionariedad en la media se propone la diferenciación sucesiva de la serie, aprovechando la propiedad de que gozan una gran parte de los procesos estocásticos, de convertirse en estacionarios al diferenciarlos cierto número de veces. Las primeras diferencias de los valores de la serie de tiempo $y_1, y_2, \dots, y_n$ son:

$$Z_t = y_t - y_{t-1} \quad (1.7)$$

Donde $t = 2, 3, \dots, n$

Las segundas diferencias son:

$$Z_t = (y_t - y_{t-1}) - (y_{t-1} - y_{t-2}) \quad (1.8)$$

La metodología de Box y Jenkins aplica métodos autorregresivos (AR), promedios móviles (MA), autorregresivos y de promedio móvil (ARMA) y, autorregresivo integrado de promedio móvil (ARIMA). A continuación, se explicarán brevemente cada uno de estos procesos suponiendo, de manera general, que las series de tiempo son estacionarias. Considérese $Y_t = y_t - \mu$, donde y_t son los valores originales de la serie de tiempo, μ es la media de todos los valores de las series, y Y_t es la desviación del proceso respecto a la media. A_t es una perturbación aleatoria o ruido blanco (con media cero, varianza constante y covarianza cero).⁹

1.2.1 El operador de retardo B Antes de describir los diferentes métodos incluidos en la metodología de Box y Jenkins, se mostrará un resumen de la notación utilizada, el operador de retardo B.

⁹ GERSCH, Will; Y BROTHERTON, Tom. "AR model prediction of time series with trends and seasonalities: A contrast with Box-Jenkins modeling". En: IEEE. Abril, 2007. p. 980-990.

Sobre la notación¹⁰:

$$Bz_t = z_{t-1}$$

$$B^2 z_t = z_{t-2}$$

$$B^p z_t = z_{t-p} \quad (1.9)$$

$$\forall Z_t = (1 - B)Z_t = Z_t - Z_{t-1} \quad (1.10)$$

$$(1 - \phi B)Z_t = a_t \Leftrightarrow (1 + \phi B + \phi^2 B^2 + \dots)a_t = a_t + \phi a_{t-1} + \phi a_{t-2} + \dots \quad (1.11)$$

1.2.2 Proceso autorregresivo (AR) Según el modelo definido en ¹¹:

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + A_t \quad (1.12)$$

donde p denota el número de términos autorregresivos y $\phi_1, \phi_2, \dots, \phi_p$ es un conjunto finito de parámetros. Se le denomina proceso autorregresivo de orden p o $AR(p)$. Esos coeficientes ϕ son multiplicados por los p valores previos de la serie. Equivalentemente, y haciendo uso del operador de retardo B , un proceso autorregresivo puede expresarse como:

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)Y_t = A_t \quad (1.13)$$

1.2.3 Proceso de promedio móvil (MA) Con la definición del modelo en ¹²:

$$Y_t = A_t - \theta_1 A_{t-1} - \theta_2 A_{t-2} - \dots - \theta_q A_{t-q} \quad (1.14)$$

Donde q , denota el número de términos de promedio móvil y $\theta_1, \theta_2, \dots, \theta_q$, son el conjunto finito de parámetros. A este modelo se le denomina proceso de promedio móvil de orden q , o $MA(q)$. Los términos θ son multiplicados por los q errores de predicción previos.

¹⁰García C. and Sanchez M., "Series temporales Univariantes". Universidad Politécnica de Madrid.

¹¹Hanke E. and Reitsch G. "Pronósticos en los Negocios", 5ta Ed, Prentice-Hall, 1996.

¹²Fuente: J. Antari, A.; El Khadimi y A. Zeroual., "Identification parameters of MA model and non-minimum phase channel using adaptive method". En: IEEE. Octubre, 2012.

1.2.4 Proceso autorregresivo y promedio móvil (ARMA) Además de los modelos AR y MA, ambos pueden combinarse en un tercer tipo de modelo denominado ARMA.

Definición del modelo:

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + A_t - \theta_1 A_{t-1} - \theta_2 A_{t-2} - \dots - \theta_q A_{t-q} \quad (1.15)$$

Los modelos $ARMA(p, q)$ utilizan las combinaciones de errores anteriores y valores anteriores y ofrecen un potencial para ajustar modelos que no pudieron ajustarse de forma adecuada mediante los modelos AR y MA por sí solos.¹³

Si se debe diferenciar una serie de tiempo d veces para hacerla estacionaria y luego aplicar a ésta el modelo $ARMA(p, q)$, se dice que la serie de tiempo original sigue un proceso autorregresivo integrado de promedio móvil o $ARIMA(p, d, q)$, donde p denota el número de términos autorregresivos, d el número de veces que la serie debe ser diferenciada para hacerse estacionaria y q el número de términos de promedio móvil.¹⁴

El modelo $ARIMA(p, d, q)$ puede ser escrito como:

$$\phi_p(B)(1 - B)^d Y_t = \theta_q(B) A_t \quad (1.16)$$

Los modelos estacionales se denotan anteponiéndoles la letra S, y el orden de sus parámetros se escribe con mayúsculas, como sigue: $SARMA(P, Q)$. Los modelos SARMA son análogos al proceso ARMA pero considerando los retardos del ruido blanco.¹⁵

¹³Fuente: Qi Wang; Li-xin Wang and Qiang Shen., "Modeling strategy of high order ARMA model". En IEEE. Enero, 2017. p. 2001-2005

¹⁴Fuente: Gujarati D., "Econometría", 3ra Ed., Santa Fé de Bogotá, Colombia: McGrawHill. 1997.

¹⁵Fuente: HANKE E. and REITSCH G, "Pronósticos en los Negocios", 5ta Ed, Prentice-Hall, 1996

Capítulo 2

METODOLOGÍA

El número de términos en la parte AR y MA del modelo final no son escogidos arbitrariamente. Para esto, Box y Jenkins proporcionan un método estructurado que determina cual modelo ajusta mejor a la serie en cuestión y recomiendan que el modelo se mantenga tan simple como sea posible. En general no hay más de tres términos AR o MA. Para la construcción de un modelo ARIMA que recoja suficientemente bien las características de la serie, se hace uso de la metodología de Box y Jenkins que puede ser estructurada en cinco etapas¹⁶.

2.1. ANÁLISIS INICIAL DE LA SERIE

Consiste en un primer análisis, mediante gráficos y pruebas estadísticas, para obtener estacionariedad (media y varianza constante).

Se grafica la serie a través del tiempo, de manera de observar a priori sus componentes: tendencia, estacionalidad y ciclos. Podría notarse la necesidad de aplicar diferencias, en la parte no estacional o regular, para hacer que la media sea constante.

2.2. IDENTIFICACIÓN DEL MODELO

En esta etapa se debe sugerir un conjunto reducido de posibles modelos.

- ❖ Selección del conjunto de estimación: conjunto de datos que se usará para la estimación y adecuación del modelo; y del conjunto de predicción: conjunto de datos que se guardará para evaluar las predicciones.

¹⁶Fuente: Wedding II y Cios., "Time series forecasting by combining RBF network, certainty factor, and the Box-Jenkins model". Neurocomputing, 1996. p. 149-168.

- ❖ Determinación de los correlogramas o funciones de autocorrelación simple y parcial para establecer, conjuntamente con lo observado en la primera etapa, el número de diferencias que se aplicarán y que convertirán el proceso en estacionario. Una serie no estacionaria es estacionaria en la parte regular si en el correlograma simple se observa que los valores decrecen lentamente en los retardos 1,2,3...
- ❖ Determinación de los órdenes del componente autorregresivo (p) y promedio móvil (q) del modelo ARMA(p,q), haciendo uso de los patrones que se observan en los correlogramas simple y parcial.
- ❖ Especificación del modelo ARIMA identificado y sugerencias de otros modelos posibles para la verificación en la elección del modelo más adecuado para el pronóstico de la serie de tiempo.

2.3. ESTIMACIÓN DE LOS PARÁMETROS DEL MODELO

Una vez identificado el modelo $ARIMA(p, d, q)$, se realizan la estimaciones, generalmente estas se hacen con la ayuda de herramientas computacionales.

2.4. VALIDACIÓN DEL MODELO

Inicialmente la adecuación del modelo se logra graficando la serie original y la ajustada por el modelo ARIMA, de manera que se puedan observar sus similitudes y diferencias. Finalmente se considera un modelo ARIMA adecuado para representar el comportamiento de una serie si se cumple lo siguiente:

- ❖ Los residuos, diferencias entre el valor original de la serie y el valor estimado por el modelo, se aproximan al comportamiento de un ruido blanco (media cero, σ^2 y $\sigma > 0$). Al observar los correlogramas no deberán observarse valores significativamente diferentes de cero, como indicativo de ausencia de correlación serial, así como tampoco patrones (tendencia, ciclos) que indicarían que el modelo no extrajo toda la información posible.
- ❖ Los parámetros del modelo ARIMA seleccionado son significativamente diferentes de cero.
- ❖ Los parámetros del modelo están poco relacionados entre sí.

- ❖ El grado de ajuste es elevado en comparación al de otros modelos alternativos. La bondad de ajuste puede evaluarse con el criterio de información de Akaike (AIC), y con el criterio Bayesiana (BIC), entre otros¹⁷.

2.5. PREDICCIÓN

La predicción se realiza sobre el modelo ARIMA seleccionado. Se predicen “m” periodos correspondientes a los tamaños del conjunto de predicción, con sus intervalos de confianza. Se calculan los errores de predicción. Es importante juzgar la adecuación del modelo en función de qué tan bien se pronostican los datos no empleados para la estimación del modelo. Para evaluar la predicción, se utilizarán los siguientes parámetros.

2.5.1 Error absoluto medio porcentual: (MAPE = mean absolute percentage error) Según¹⁸, el error absoluto medio porcentual se define como:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \quad (2.1)$$

Donde Y_i son los valores reales de la serie que pertenecen al conjunto de predicción $Y(t)$ y $\hat{Y}_i$ son los valores pronosticados por el modelo ARIMA.

2.5.2 Raíz del error cuadrado medio (RMSE = root mean squared error) Según¹⁹, el error absoluto medio porcentual se define como:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (2.2)$$

Donde Y_i son los valores reales de la serie que pertenecen al conjunto de predicción $Y(t)$ y $\hat{Y}_i$ son los valores pronosticados por el modelo ARIMA.

¹⁷Fuente: CHATFIELD C., "The analysis of time series: theory and practice", Londres: Chapman and Hall, 1978.

¹⁸Fuente: ZHANG, G. Peter, Neural Networks in Business Forecasting. Georgia State University, USA: Idea group publishing. p-285

¹⁹Fuente: CONGALTON, Russell G y GREEN, Kass. Assessing the accuracy of remotely sensed data: Principles and Practices. Second Edition. New York: Taylor& Francis Group. p-193

Otra forma de evaluar la predicción es a través de la correlación entre los valores observados y los pronosticados por el modelo. Valores altos de esta correlación indican una buena adecuación del modelo. Si la serie pareciera cambiar en el tiempo, pudiera ser necesario recalcular los parámetros, o desarrollar un nuevo modelo.

2.5.3 Criterio de información de Akaike (AIC) El criterio de información de Akaike (AIC) es una medida de la calidad relativa de un modelo estadístico, para un conjunto dado de datos, está dado por²⁰:

$$AIC = T \ln \frac{S}{T} + 2r \quad (2.3)$$

Este criterio permite seleccionar un modelo, se prefiere el modelo que tenga el menor valor de AIC.

2.5.4 Criterio de información Bayesiana (BIC) Es un criterio de evaluación de modelos en términos de sus probabilidades posteriores, dado por la siguiente ecuación²¹:

$$BIC = T \ln \frac{S}{T} + r \ln T \quad (2.4)$$

Este criterio es un método para la selección de un modelo, se prefiere el modelo que tenga el mínimo valor del estadístico. En comparación con el AIC, el BIC penaliza los parámetros adicionales más severamente, conduciendo a modelos más simples.

²⁰Fuente: IV SIMPOSIO DE METODOLOGÍA DE LAS CIENCIAS DEL COMPORTAMIENTO. Abril 1995: Murcia. Modelos multivariantes. Universidad de Murcia. p-277

²¹Fuente: HANKE, Jhon E y WINCHERN, Dean W. Pronósticos en los negocios. Octava edición. Pearson:2006. p-413


Capítulo 3

DESARROLLO DEL ALGORITMO

3.1. ADQUISICIÓN DE DATOS

La adquisición de datos se llevó a cabo siguiendo rigurosamente el diagrama de bloques de la figura 1; para obtener el comportamiento del espectro se tomaron datos en cuatro franjas durante el día, de lunes a viernes durante 7 días. Las horas en las que se hicieron la toma de datos fueron 6 a.m, 10 a.m, 2 p.m y 6 p.m, en cada una de estas franjas se obtuvieron 8 archivos cada uno de 1000 muestras, por tanto en total se obtuvieron 224.000 muestras.

Figura 1: **Diagrama de bloques del montaje utilizado.**



Para tal recopilación fue necesario el uso de un analizador de espectro MHS-X, una antena monopolo y la unidad de almacenamiento.


3.1.1 Antena Monopolo Esta antena solo presenta un cable, irradia las ondas electromagnéticas en posición vertical sobre la tierra y van conectadas en su base a un generador, la otra parte de la alimentación está conectada a tierra.

Generalmente la longitud de esta antena tiene un largo de cuarto de onda. La ventaja de estas antenas es su construcción más simple, lo que hace que sean utilizadas en torres

de transmisión, emisoras de radio, televisión o celulares.²²


Los monopolos sobre un plano de tierra constituyen el tipo de antena utilizada en bandas de radiodifusión de 540-1650 MHz y con frecuencias en sistemas de comunicaciones en las bandas de HF, VHF y UHF.²³

Figura 2: **Antena Monopolo.**



Para conocer el comportamiento de la antena en el espectro utilizado se usó el software CST, con los siguientes resultados para el parámetro S11 (Ver figura 3).

Figura 3: **Parámetro S11 para la antena monopolo.**



Basados en la anterior figura el ancho de banda de la antena es de aproximadamente 21.1 [MHz].

3.1.2 Analizador de espectro. El analizador utilizado en la toma de datos fue el ROHDE & SCHWARZ HMS-X el cual consta de un rango de frecuencia de 100 [KHz]

²²Fuente:Antenas, polarización y diagramas de radiación. Universidad de Chile. Facultad de ciencias físicas y matemáticas. (Octubre de 2012)

²³Fuente:Ibid

a 1.6 [GHz] un barrido de 20 [ms] a 1000 [s] y una resolución de ancho de banda de 10 [KHz] a 1 [MHz], entre otras características que pueden ser detalladas en el manual de especificaciones del equipo²⁴.


Para la toma de datos se utilizó el software del instrumento, utilizando la opción de script, a continuación se describe la estructura de este.

3.1.2.1 Software HMExplorer El software HMExplorer permite conectar diferentes instrumentos, entre estos el analizador de espectro HMS-X, habilitando opciones diferentes para cada uno de los instrumentos; en este caso una de las opciones habilitadas permite enviar comandos por medio de un script al instrumento.

El script utilizado para realizar la captura se puede visualizar en el anexo C, el siguiente diagrama de flujo describe la estructura general (Ver figura 4):

²⁴Fuente: ROHDE& SCHWARZ. HMS-X Spectrum Analyzer. [en línea]. (Recuperado: 22 de agosto de 2018). Disponible: www.rohde-schwarz.com

Figura 4: **Diagrama de flujo del script utilizado.**




La estructura de estos comandos se encuentra en el manual de usuario del software HMEexplorer.²⁴

Con los datos recopilados se analizó el comportamiento del espectro, para obtener un estimado de la variaciones de este, mediante la herramienta de software MATLAB, en la figura 5 se muestra el comportamiento promedio del espectro durante la toma de datos.

²⁴ROHDE& SCHWARZ. HMEexplorer Software User Manual. 2016

Figura 5: **Análisis potencia vs frecuencia comprendido entre 0.85 – 1.9 [GHz].**




De manera general se puede decir que la franja del espectro que estamos trabajando según el CNABF (Cuadro nacional de atribución de bandas de frecuencia) ²⁵ se encuentra distribuida de la siguiente manera:

- ❖ 850 [MHz]-953[MHz], 1.4[GHz]-1.52[GHz] y de 1.71[GHz]-1.9[GHz] se encuentran los servicios fijos, es decir, servicio de radiocomunicación entre puntos fijos determinados. También para servicios de radiocomunicación entre estaciones móviles y estaciones terrestres o entre estaciones móviles (CV), y radiolocalización.
- ❖ 960[MHz]-1.4[GHz] se encuentran asignadas en esta franja los servicios de radionavegación aeronáutica, destinado a las aeronaves y su explotación en condiciones de seguridad, radiolocalización, exploración de la tierra por satélite y radionavegación por satélite para fines de radionavegación. También pueden considerarse incluidos en este servicio los enlaces de conexión necesarios para su explotación.
- ❖ 1.53[GHz]-1.66[GHz] se encuentran asignados los servicios de móvil por satélite, radionavegación aeronáutica y radiodeterminación por satélite.
- ❖ 1.67[GHz]-1.7[GHz] se encuentran asignados los servicios de meteorología y ayudas a la meteorología principalmente y fijo.

²⁵Fuente:Cuadro Nacional de atribución de bandas de Frecuencias [en línea]. Disponible en internet: <http://cnabf.ane.gov.co>.

Debido a que el equipo utilizado para la toma de datos no registró variaciones significativas, es decir variaciones que superen el piso de ruido, en el espectro, se optó por analizar sólo la franja de 850[MHz]-1[GHz].(Véase figura 6).

Figura 6: **Estampa de agua en la banda de 0.85 – 1 [GHz].**



La transformada de Fourier nos dice que cualquier señal puede descomponerse en una serie funciones periódicas cada una con una frecuencia y amplitud distintas. Si representamos la frecuencia y amplitud obtenemos el espectro que nos dice cuáles son las frecuencias dominantes de esa señal²⁶. Con lo cual, el espectrograma nos permite co-

nocer cómo evolucionan las frecuencias que dominan una señal.

La estampa de agua, también llamada espectrograma, es una forma visual de representar la fuerza de una señal (intensidad) a lo largo del tiempo en varias frecuencias presentes en una forma de onda particular. Además, para su correcta lectura se debe saber que los espectrogramas son básicamente gráficos bidimensionales, con una tercera dimensión representada por colores. El tiempo corre de la parte inferior (más antigua) a la parte superior (la más reciente) a lo largo del eje vertical, su eje horizontal es la frecuencia [Hz] y con los respectivos colores se muestra la potencia [dBm], siendo el color azul la representación de aquellas señales con un valor más bajo y el amarillo como el valor más alto.²⁷

3.2. ANÁLISIS DE LA SERIE DE TIEMPO

Para obtener la serie de tiempo se organizaron los datos obtenidos por canales que fueron tomados de la CNABF y así obtener el ciclo de trabajo que nos permita conocer las bandas con mayor ocupación y así mismo las de menor ocupación.

3.2.1 Ciclo de trabajo Para cada frecuencia, esta métrica representa la fracción de tiempo durante la cual el canal permanece ocupado.²⁸

$$C = \frac{N_{co}}{Nt} \quad (3.1)$$

Donde:

C , es el ciclo de trabajo

N_{co} , es el número de muestras de canal ocupado y

Nt , es número de muestras totales.


²⁶Fuente: DURÁN DURÁN, Diego Erley y PLATA ESPINOSA, Manuel Arnulfo. Implementación, validación y verificación de los algoritmos de convulsión y transformada rápida de Fourier en dos dimensiones sobre un clúster de computadores MAC. Universidad Industrial de Santander. 2009. p: 3-5.

²⁷Fuente:PNSN (red sísmica del noroeste del pacífico) [en línea]. Disponible en internet: <https://pnsn.org/spectrograms/what-is-a-spectrogram>.

²⁸CELY LEÓN, Carlos A; BRAVO GÓMEZ, Jefferson Angelo y MEDINA MOREIRA, Washington. Medición, caracterización y modelamiento del rango de frecuencias asignado a radiodifusión AM (525-1705 KHz) de la banda MF del espectro electromagnético en la FIEC, Campus Prosperina. Ecuador: Escuela Superior Politécnica del Litoral (ESPOL). Facultad de Ingeniería en Electricidad y Computación

Para una determinada banda, el ciclo de trabajo promedio se calcula como la media aritmética de los ciclos de trabajo obtenidos para las diversas frecuencias medidas dentro de dicha banda. En la siguiente imagen se puede observar el ciclo de trabajo promedio para cada uno de los canales (Ver figura 7).

Figura 7: Ciclo de trabajo promedio




Como se mencionó anteriormenete la figura 7 fue obtenida con los datos medidos en diferentes franjas durante el día por 7 días; para obtener una serie de tiempo que permita obtener resultados representativos, en algunos estudios²⁹, se ha indicado que una opción razonable es considerar periodos de medición de al menos 24 horas a fin de no subestimar o sobrestimar la ocupación de bandas de frecuencia con algunos patrones temporales.

Por esta razon y para poder observar cualquier pequeño cambio en potencia se disminuyo el spam a los canales que tuvieran mayor variación en el ciclo de trabajo, para que esto permita disminuir el tiempo de barrido; por lo cual la franja de frecuencia analizada durante 24 horas comprende las frecuencias desde 850 MHz hasta 908 MHz, ya que esto nos da un spam de 58 MHz, lo que permite subir el tiempo de barrido a 174 ms.

El análisis de esta banda se realizó siguiendo el diagrama de flujo mostrado en la figura 4, cambiando el tiempo de espera a 5 minutos y la cantidad de archivos tomados a 288, por lo tanto al final de la toma de datos se obtiene 28.800 muestras que corresponde a un periodo de medición de 24 horas con una frecuencia mínima de toma de datos de 5 minutos, en la siguiente gráfica se muestra el ciclo de trabajo de estas mediciones.

²⁹Lopez M. and Casadevall F., "Methodological aspects of spectrum occupancy evaluation in the context of cognitive radio,"European Transactions on Telecommunications, vol. 21, no. 8, pp. 680-693, 2010.

Figura 8: Ciclo de trabajo durante 24 horas.



Esta banda de frecuencia fue dividida en 5 canales, con una ancho de banda de 11.6 [MHz] y frecuencias centrales de 855.6, 867.4, 879, 890.6 y 902.2 MHz respectivamente.

Como se observa en la figura anterior dichos canales no tienen mayor variación en su ciclo de trabajo durante las 24 horas que fueron analizados, por esta razón y para tener una predicción más dinámica se alteró su comportamiento original con transmisiones a 2 diferentes frecuencias.

Para determinar las frecuencias a las que se iban a realizar las transmisiones se analizó el espectro de 850 a 908 [MHz], midiendo los valores de frecuencia que estuvieran por debajo de los -73[dBm], ya que a este valor de potencia se considera como piso de ruido; analizando estos valores se encontró que en esta banda se pueden diferenciar dos grandes huecos espectrales, por lo tanto se calculó la frecuencia central de estos dos

huecos espectrales, dando como resultado 858,1 y 904 MHz por lo tanto se escogieron estos dos valores para realizar las pruebas.

Estas transmisiones se realizaron cada media hora transmitiendo la señal mostrada en la figura 14, alternando entre los dos valores de frecuencia central que se mencionaron anteriormente, esto se realizó durante 11 horas, debido a la disponibilidad de los equipos, del lugar donde se realizaron dichas transmisiones y ya que con la prueba realizada durante 24 horas, comprobó que el espectro no varía durante el día.

En la figura 9 se muestra el montaje utilizado para estas pruebas y a continuación, se describen los implementos utilizados.

Figura 9: **Montaje utilizado para las pruebas de transmisión y recepción**




3.2.2 Antena Esta antena ofrece un excelente rendimiento de 400 - 1000 MHz. Esta gama incluye todos los canales de televisión de alta definición en UHF (HDTV). También se puede aplicar fácilmente a otras aplicaciones de aficionados en este rango, excelente para aplicaciones EMI / RFI y muy popular entre las aplicaciones de micrófono inalámbrico³⁰.

El fabricante de estas antenas nos proporcionan los factores típicos de la antena y el parámetro S11, que se muestran a continuación.

³⁰Fuente: Kent Electronics: WA5VJB. [en línea].[Consultado: 8 de Octubre de 2018]. Disponible en: <https://www.wa5vjb.com/products1.html>.

Figura 10: **Parámetro S11.**



Fuente: Kent Electronics: WA5VJB. [en línea].[Consultado: 8 de Octubre de 2018]. Disponible en: <https://www.wa5vjb.com/products1.html>.

Tabla 1: Factores típicos de la antena.

MHz	Ganancia [dB]
400	18.8
450	17.7
500	18.2
600	19.8
700	21.2
800	22.3
900	23.3
1000	24.2
1050	24.7

Fuente: Kent Electronics: WA5VJB. [en línea].[Consultado: 8 de Octubre de 2018]. Disponible en: <https://www.wa5vjb.com/products1.html>.

3.2.3 USRP NI 2920 El USRP-2920 es un transceptor de RF ajustable con un convertidor analógico-digital de alta velocidad y un convertidor digital-analógico para para la transmisión de señales de banda base I y Q a una PC principal por Gigabit Ethernet 1/10³¹ (Ver figura 23).

Es comunmente utilizado para aplicaciones de comunicaciones como: espacio en blanco, emisión FM, seguridad pública, dispositivos móviles terrestres, radioficionado o GPS.

³¹ Fuente: NATIONAL INSTRUMENT. USRP [en línea].[Consultado: 8 de Octubre de 2018]. Disponible en: <http://www.ni.com/es-co/support/model.usrp-2920.html>

Figura 11: **USRP NI 2920**



Fuente: NATIONAL INSTRUMENT. USRP [en línea]. [Consultado: 8 de Octubre de 2018].
Disponible en: <http://www.ni.com/es-co/support/model.usrp-2920.html>

En las siguientes tablas se muestran las especificaciones dadas por el fabricante para la transmisión y recepción con el USRP 2920.

Tabla 2: **Parámetros del USRP en transmisión.**

Transmisión	
Rango de Frecuencia	50 MHz a 2.2 GHz
Pasos de Frecuencia	<1kHz
Maxima potencia de salida (Pout)	
50 MHz a 1.2 GHz	50mW a 100mW (17 dBm a 20 dBm)
1.2 GHz a 2.2 GHz	30 mW a 70mW (15dBm a 18 dBm)
Rango de ganancia	0 dB a 31 dB
Pasos de ganancia	1.0 dB
Exactitud de frecuencia	2.5 ppm
Máximo ancho de banda instantáneo en tiempo real	
Ancho de la muestra de 16 bit	20 MHz
Ancho de la muestra de 18 bit	40 MHz
Frecuencia máxima de muestreo	
Ancho de la muestra de 16 bit	25 MS/s
Ancho de la muestra de 18 bit	50 MS/s
DAC	2 canales, 400 MS/s, 16 bit

Fuente: USRP 2920: Software Defined Radio Device.

Tabla 3: **Parámetros del USRP en recepción.**

Recepción	
Rango de Frecuencia	50 MHz a 2.2 GHz
Pasos de Frecuencia	<1kHz
Rango de ganancia	0 dB a 31.5 dB
Pasos de ganancia	0.5 dBm
Máxima potencia de entrada	0 dBm

Fuente: USRP 2920: Software Defined Radio Device.

3.2.4 GNU Radio GNU Radio es un juego de herramientas de desarrollo de software libre y de código abierto que proporciona bloques de procesamiento de señal para implementar radios de software. Se puede usar con hardware externo de RF de bajo costo para crear radios definidas por software, o sin hardware en un entorno parecido a la simulación. En resumen, un software de radio es un sistema de radio que realiza el

procesamiento de señal requerido en el software en lugar de utilizar circuitos integrados dedicados en el hardware.

GNU Radio realiza todo el procesamiento de la señal. Puede usarse para escribir aplicaciones para recibir y transmitir datos con hardware de radio, o para crear aplicaciones totalmente basadas en simulación. Las aplicaciones de Radio GNU se pueden escribir en lenguaje de programación C ++ o Python, mientras que la ruta de procesamiento de señal crítica para el rendimiento se implementa en C ++ usando extensiones de coma flotante donde estén disponibles.

El proyecto GNU Radio utiliza Universal Software Radio Peripheral (USRP) que es un transceptor computarizado que contiene cuatro conversores analógico digital (A/D) de 64 mega muestras-por-segundo (MS/s) de 12-bit , cuatro conversores digital a analógico (D/A) de 128 MS/s de 14-bit, y soporta circuitos para la interfaz con una computadora. Dependiendo del modelo, la interfaz computadora-a-USRP es a través de un puerto USB 2.0 o Gigabit Ethernet. USRP puede procesar señales de hasta 25-MHz de ancho de banda, dependiendo del modelo³².

3.2.4.1 Montaje de transmisión Para hacer las debidas pruebas en transmisión se utilizó un USRP NI-2920 conectado a un antena de placa de circuito impreso y un equipo de cómputo como se muestra en la figura 24, en el cual se implementa el siguiente montaje en GNU (Véase figura 25).


³²Fuente: GNU Radio[en línea].[Consultado: 10 de Octubre de 2018]. Disponible en: <https://www.gnuradio.org/>

Figura 12: **Montaje de transmisión.**



Para las pruebas se utilizaron como señal un coseno real con offset; los bloques funcionales se describen a continuación.

Figura 13: **Montaje de transmisión en GNU.**



❖ **Bloque signal source** Se utiliza para generar una variedad de tipos de señal: seno, coseno, cuadrado, triángulo y diente de sierra. El bloque anterior tiene los siguientes parámetros de entrada:

- **Sample rate:** Muestreo o sample rate define cada cuánto tiempo se tomará

el valor de la señal analógica para generar el audio digital. Esta tasa se mide en Hertzios (Hz).

- **Waveform:** Especifica la forma de onda de salida.
 - **Frecuency:** especifica la tasa de muestreo de salida. Este parámetro debe ser un valor real.
 - **Amplitude:** Especifica la amplitud máxima (seno y coseno) o la amplitud de pico a pico (cuadrado, triángulo y diente de sierra). Cuando se utiliza la salida constante, normalmente esto se establece en 0 y se usa el parámetro de compensación. Este parámetro debe ser un valor real y se debe tener cuidado en no saturar el radio, ya que esto generaría armónicos.
 - **Offset:** Especifica el desplazamiento que se agrega a la forma de onda generada.
- ❖ **Null Source** Produce ceros para cada muestra. Esto puede ser útil si desea crear un valor complejo a partir de un valor de punto flotante con la parte real o imaginaria establecida en cero.
- ❖ **Float to complex** Implementa la función $out = re + jim$. Tenga en cuenta que el tipo de datos cambia de punto flotante (real) a complejo. Hay que tener en cuenta como se observa en la imagen 24 que el bloque Null source va conectado a la entrada imaginaria y el bloque signal source a la parte real.
- ❖ **Bloque UHD: USRP Source** Este bloque que permite la interacción entre GNU y el USRP.
- **Ch0: Center Freq (Hz):** Corresponde al valor de frecuencia en el cual deseamos poner nuestra portadora, es decir, la frecuencia en la cual se desea transmitir.
 - **Ch0: Gain (dB):**
 - **Ch0: Antenna:** es la configuración en la cual deseamos operar, es decir en nuestro caso es Tx/Rx ya que esta asignación es la utilizada para transmisión.
 - **Ch0:Bandwidth (Hz):** Configura el valor del ancho de banda deseado en la señal transmitida.
 - **Address device:** Representa la dirección IP del dispositivo.

- ❖ **QT GUI Frequency Sink** Bloque de interfaz gráfica que permite visualizar la representación en frecuencia de la señal de entrada. Donde:
 - **FFT Size:** Representa la cantidad de muestras que se desea sean procesadas para que el bloque realice la transformada de Fourier.
 - **Center Frequency (Hz):** Representa frecuencia del central durante la visualización en la ejecución de programa.
 - **Bandwidth:** Es el tamaño de la ventana (Spam) durante la visualización.
- ❖ **Variable** Este bloque asigna un valor a una variable única. Este bloque de variables no tiene representación gráfica. La variable puede ser referenciada por la ID, es decir la asignación o nombre de la variable, desde otros bloques en el diagrama de flujo.
- ❖ **QT GUI Range** Este bloque asigna un valor a una variable única, pero a diferencia del bloque variable, este bloque se puede modificar durante la ejecución del programa, permitiendo una interacción en tiempo real. La variable puede ser referencia (por ID) desde otros bloques en el diagrama de flujo.
 - **Default Value:** Es el valor asignado por defecto durante la ejecución del programa.
 - **Start:** Es el valor inicial en el rango de operación del cual podemos hacer uso durante la ejecución del programa.
 - **Stop:** Es el valor final en el rango de operación del cual podemos hacer uso durante la ejecución del programa.
 - **Step:** Es la cantidad o escala que toma la variable durante la ejecución del programa cuando se desea modificar la variable en tiempo real.


A continuación, se muestra una tabla con el respectivo valor que se le asignó a cada parámetro del montaje principal:

Tabla 4: **Configuración de parámetros de los bloques.**

Parámetro	Valor
Samp Rate	200[KHz]
Ch0:Center freq(Hz)	Fc
Ch0: Gain (dB)	0
Address device	"192.168.10.2"
Ch0:Bandwidth	32[MHz]
Amplitude	0.5
Frequency	1[KHz]
Waveform	cosine
Offset	10m
ID(Variable)	Samp_rate
ID(QT GUI Range)	fc
Default Value	858.55 M
Start	840M
Stop	1G
Step	1M

La señal generada (ver figura 14) es la resultante de la transformada de Fourier de la parte real de un coseno con offset de 10mV, lo que nos permite observar los tres pulsos.

Figura 14: **Señal generada por GNU.**



3.2.5 Montaje de recepción En este montaje se usó el analizador de espectro HMS-X que se describió en la sección de adquisición de datos y una antena WA5VJB


con ancho de banda de 400-1000 MHz, este se puede observar en la siguiente imagen.

Figura 15: **Montaje de recepcion.**




Al alterar el espectro con dichas transmisiones se obtiene los siguientes resultados para el ciclo de trabajo (Ver figura 16).

Figura 16: **Ciclo de trabajo de los 5 canales afectado por las transmisiones.**



Como se observa en la figura anterior, los canales tienen mayor variación en su ciclo de trabajo comparado con las medidas tomadas para el análisis de 24 horas; con estos valores de ciclo de trabajo se escogen los 3 canales que tengan comportamiento de ocupación alta media y baja; para esto se calculó el valor máximo, mínimo y la media del ciclo de trabajo de cada uno de los canales y se tomo como canal de ocupación alta aquel que obtuvo el valor más alto comparado con los valores máximos de los demás canales, en este caso el canal 3, con frecuencia central de 879 MHz; para el canal de ocupación baja se compararon los valores minimos de cada canal y se eligió aquel canal cuyo valor mínimo fuese menor a todos los demás valores mínimos, en este caso el canal 5, con frecuencia central de 902.2 MHz; como canal de ocupación media se eligió, comparando los valores medios de cada canal y se escogió aquel que obtuvo la menor variación entre su valor medio y su máximo, y el valor medio y el mínimo, en este caso el canal 2, con frecuencia central de 867,4 MHz.

Figura 17: **Gráfica de serie de tiempo para los 3 canales**



Esta serie de tiempo fue obtenida de 22 archivos, cada uno con 1000 muestras; cada canal tiene 200 muestras de cada uno de los archivos, así que en total cada serie de tiempo tiene 4400 muestras, es decir 200 muestras equivalen a media hora de toma de

datos, por lo tanto el periodo de la serie es de media hora.

Para determinar la estacionariedad de las series se aplicó la prueba Dickey-Fuller para los 3 canales, la cual devuelve un valor lógico con la decisión de rechazo de la hipótesis nula la cual indica que presenta raíz unitaria que quiere decir que la serie de tiempo no es estacionaria. Es decir si el resultado de esta prueba es 0 quiere decir que no se puede rechazar la hipótesis nula y la serie tiempo no es estacionaria y lo contrario si el resultado es 1.

En este caso la prueba para las 3 series de tiempo dio como resultado que la serie es estacionaria .

Para saber cómo influyen las muestras del pasado con las muestras del futuro, se obtuvieron las gráficas de ACF (Sample Autocorrelation Function) y PACF (Sample Partial Autocorrelation Function).

3.2.6 ACF (Sample Autocorrelation Function) La función de autocorrelación simple (FAS) o sample autocorrelation function (ACF), representa una dependencia lineal de la serie. Denominando que z_t son los valores de una serie de tiempo, los valores observados se describen como³³:

$$z_1, z_2, \dots, z_{t-2}, z_{t-1}, z_t, z_{t+1}, \dots$$


Donde z_1 , representa el primer valor de la serie, así sucesivamente hasta z_t que será el valor actual de la serie. Suponiendo que z_1 influye sobre z_2 , la función de autocorrelación simple busca estudiar la influencia en las diversas observaciones.

Los coeficientes de la ACF, $\rho_1, \rho_2, \dots, \rho_k$ representa la influencia sobre las siguientes observaciones. están acotados entre $[-1, 1]$. Cuando ρ_i vale cero, quiere decir que no existe efecto entre una observación y la i posiciones anteriores. Si ρ_i es cercano a 1 indica que hay mucha relación entre una observación y las i posiciones anteriores, y es una relación positiva y si es cercano a -1 indica que la relación es negativa³⁴(Ver figura 9).

³³F. Pérez. Introducción a las series de tiempo. Métodos paramétricos. Universidad de Medellín. 2007

³⁴F. Pérez. Introducción a las series de tiempo. Métodos paramétricos. Universidad de Medellín. 2007

Figura 18: **Función de autocorrelación simple (ACF o FAS)**




La gráfica anterior fue obtenida para 3000 retrasos, ya que con este valor se obtiene un patrón que puede ser interpretado para la obtención del modelo ARIMA.

Analizando el comportamiento de la función de Autocorrelación para las 3 serie de tiempo, se puede observar que existe un patrón de decrecimiento, que corresponde con la forma de la función para una serie de tiempo estacionaria y con un al menos un termino autorregresivo³⁵.

³⁵Fuente: Minitab Inc. Soporte técnico de Minitab 18. [en línea]. [Consultado: 12 de agosto de 2018]. Disponible en: <https://support.minitab.com>.

3.2.7 PACF (Sample Partial Autocorrelation Function) La función de autocorrelación parcial (FAP) o sample partial autocorrelation function (PACF) proporciona la relación directa que existe entre observaciones separadas k retardos. Es decir, que el primer coeficiente será significativo pero el segundo no lo es. Cuando el primer retardo es significativo mientras que ninguno de los demás lo es, por lo tanto esto representa que existe una relación directa entre una observación y la siguiente, pero no existe ninguna otra relación directa.

Figura 19: Función de autocorrelación parcial (PACF o FAP)



La gráfica fue obtenida para 300 retrasos, ya que con esta cantidad se observa un patrón que sugiere que el modelo ARIMA tendrá mínimo 4 términos autorregresivos ³⁶. En la

³⁶Fuente: Minitab Inc. Soporte técnico de Minitab 18. [en línea]. [Consultado: 12 de agosto de 2018].

siguiente sección se muestra el modelo de estimación ARIMA y los valores de predicción.

3.3. MODELO DE ESTIMACIÓN ARIMA

En la original metodología de Box-Jenkins, la serie se diferencia hasta conseguir que sea estacionaria, entonces el modelo de la serie diferenciada modela el proceso estacionario como ARMA(p,q). El paquete de “Econometric Tools” de Matlab se ajusta y pronostica procesos ARIMA (p, D, q) directamente, por lo que no hay necesidad de diferenciar los datos antes de modelar³⁷.

La forma del modelo ARIMA(p,D,q) en “Econometrics Toolbox” utilizando el operador de retardo $L^m ey_t = y_{(t-me)}$, se puede escribir como:

$$\Phi^*(L)Y_t = \Phi(L)(1 - L)^D Y_t = c + \Theta(L)E_t \quad (3.2)$$

Donde $\Phi^*(L)$ es el término AR con D raíces de la unidad, también expresado como $\Phi(L)(1 - L)^D$, donde $\Phi(L) = (1 - \Phi_1 L - \dots - \Phi_p L^p)$ con un operador de retardo p que representa los términos AR. Del mismo modo $\Theta(L) = (1 - \Theta_1 L - \dots - \Theta_q L^q)$ donde q representa el grado del término MA³⁸.


El proceso para determinar el modelo que mejor se ajusta a la serie de tiempo analizada se puede explicar con el siguiente diagrama de flujo:

Disponible en: <https://support.minitab.com>.

³⁷Fuente: MathWorks Inc. MathWorks. [en línea]. [Consultado: 12 de agosto de 2018]. Disponible en: <https://la.mathworks.com>.

³⁸Fuente: MathWorks Inc. MathWorks. [en línea]. [Consultado: 12 de agosto de 2018]. Disponible en: <https://la.mathworks.com>.

Figura 20: Diagrama de flujo para la estimación ARIMA



Fuente: BOX G.; JENKINS G. Y REINSEL, G., “Time series analysis, forecasting and control.”, 3ra Ed, New Jersey, USA: Prentice Hall, 1994

Para la determinación del mejor modelo se hace una comparación entre varios de ellos, variando los parámetros para encontrar el que mejor se ajuste; los modelos se escogieron basados en las gráficas de la función de autocorrelación (FAS) y autocorrelación parcial (FAP) y sabiendo que las series de tiempo son estacionarias.

Los parámetros utilizados para compararlos son el criterio AIC y BIC, el resultado de esta comparación se resumen en la siguiente tabla:

Tabla 5: **Comparación de modelos**

Modelo	AIC			BIC		
	Alto	Medio	Bajo	Alto	Medio	Bajo
ARIMA(4,0,0)	29309	26959	27050	29348	26998	27088
ARIMA(4,0,1)	28818	26673	26483	28863	26718	26527
ARIMA(4,1,1)	29341	27010	27063	29386	27055	27108
ARIMA(4,0,2)	28631	26374	26168	28682	26425	26220
ARIMA(4,0,3)	28612	26342	26072	28669	26400	26130
ARIMA(4,1,3)	28680	26453	26206	28738	26511	26264

De acuerdo con la tabla anterior, se seleccionan los modelos con los valores más bajos en los parámetros escogidos; estos son ARIMA(4,0,2), ARIMA(4,0,3) y ARIMA(4,1,3).

3.3.1 Selección del modelo verificando comportamiento de residuos

Para escoger de entre estos 3 modelos el que mejor se ajuste a la serie, se realizó el análisis de los residuos de cada uno, con base en ese análisis se escogió el modelo final, para usarlo en la implementación del algoritmo.

3.3.1.1 ARIMA(4,0,2) Los estimados para el modelo ARIMA(4,0,2) para la serie de tiempo del canal de ocupación alta, muestran que el modelo tiene una distribución gaussiana y no se ajusta por completo a la serie debido a que la función de autocorrelación tiene valores que aún no se pueden despreciar ya que se encuentran por fuera de los coeficientes de ajuste (Ver figura 21).

En la tabla 6 se muestran los valores AR, MA, el término constante y la varianza del modelo, junto con los valores de error estándar.

Figura 21: **Gráfica residuos para ARIMA(4,0,2) para la serie de tiempo de ocupación alta**




Tabla 6: **Resultados estimación modelo ARIMA(4,0,2) para el serie de tiempo de ocupación alta**

Parámetro	Valor	Error estándar
Constante	-6.6146	1.1225
AR(1)	-0.0756	0.0466
AR(2)	0.8455	0.0232
AR(3)	0.0357	0.0426
AR(4)	0.1124	0.0186
MA(1)	0.1980	0.0377
MA(2)	-0.5395	0.0250
Varianza	39.0787	0.5084

Los estimados para el modelo ARIMA(4,0,2) para la serie de tiempo del canal de ocupación media, muestran que el modelo tiene una distribución gaussiana y tiene un buen ajuste a la serie debido a que la función de autocorrelación los valores se encuentran dentro de los coeficiente de ajuste (Ver figura 22).

En la tabla 7 se muestran los valores AR, MA, el término constante y la varianza del modelo, junto con los valores de error estándar.

Figura 22: **Gráfica residuos para ARIMA(4,0,2) para la serie de tiempo de ocupación media**




Tabla 7: **Resultados estimación modelo ARIMA(4,0,2) para el serie de tiempo de ocupación media**

Parámetro	Valor	Error estándar
Constante	-8.8252	1.5684
AR(1)	-0.1135	0.0513
AR(2)	0.8534	0.0273
AR(3)	0.0627	0.0469
AR(4)	0.0950	0.0210
MA(1)	0.1893	0.0397
MA(2)	-0.6141	0.0286
Varianza	23.3948	0.3065

Los estimados para el modelo ARIMA(4,0,2) para la serie de tiempo del canal de ocupación baja, muestran que el modelo tiene una distribución gaussiana y tiene un buen ajuste a la serie debido a que la función de autocorrelación los valores se encuentran dentro de los coeficiente de ajuste (Ver figura 23).

En la tabla 8 se muestran los valores AR, MA, el término constante y la varianza del modelo, junto con los valores de de error estándar.

Figura 23: **Gráfica residuos para ARIMA(4,0,2) para la serie de tiempo de ocupación baja**




Tabla 8: **Resultados estimación modelo ARIMA(4,0,2) para el serie de tiempo de ocupación baja**

Parámetro	Valor	Error estándar
Constante	-3.9790	0.7967
AR(1)	-0.1414	0.0386
AR(2)	0.9540	0.0272
AR(3)	-0.1187	0.0363
AR(4)	0.0233	0.0249
MA(1)	0.3300	0.0278
MA(2)	-0.6586	0.0278
Varianza	22.3285	0.3297

3.3.1.2 ARIMA(4,0,3) Los estimados para el modelo ARIMA(4,0,3) para la serie de tiempo del canal de ocupación alta, muestran que el modelo tiene una distribución gaussiana y no se ajusta por completo a la serie debido a que la función de autocorrelación no se encuentran dentro de los coeficientes de ajuste (Ver figura 24).

En la tabla 9 se muestran los valores AR, MA, el término constante y la varianza del modelo, junto con los valores de error estándar.

Figura 24: **Gráfica residuos para ARIMA(4,0,3) para la serie de tiempo de ocupación alta**




Tabla 9: **Resultados estimación modelo ARIMA(4,0,3) para el serie de tiempo de ocupación alta**

Parámetro	Valor	Error estándar
Constante	-9.7906	1.6685
AR(1)	-0.6078	0.0773
AR(2)	0.7973	0.0438
AR(3)	0.5479	0.0732
AR(4)	0.1412	0.0376
MA(1)	0.7358	0.0750
MA(2)	-0.4310	0.0417
MA(3)	-0.3279	0.0500
Varianza	38.8890	0.5153

Los estimados para el modelo ARIMA(4,0,3) para la serie de tiempo del canal de ocupación media, muestran que el modelo tiene una distribución gaussiana y tiene un buen ajuste a la serie debido a que la función de autocorrelación los valores se encuentran dentro de los coeficiente de ajuste (Ver figura 25).

En la tabla 10 se muestran los valores AR, MA, el término constante y la varianza del modelo, junto con los valores de error estándar.

Figura 25: **Gráfica residuos para ARIMA(4,0,3) para la serie de tiempo de ocupación media**




Tabla 10: **Resultados estimación modelo ARIMA(4,0,3) para el serie de tiempo de ocupación media**

textbfParámetro	Valor	Error estándar
Constante	-2.3090	0.4049
AR(1)	0.8312	0.0484
AR(2)	0.9487	0.0386
AR(3)	-0.8440	0.0479
AR(4)	0.0373	0.0378
MA(1)	-0.7652	0.0324
MA(2)	-0.7738	0.0209
MA(3)	0.6616	0.0262
Varianza	23.2172	0.3083

Los estimados para el modelo ARIMA(4,0,3) para la serie de tiempo del canal de ocupación baja, muestran que el modelo tiene una distribución gaussiana y tiene un buen ajuste a la serie debido a que la función de autocorrelación los valores se encuentran dentro de los coeficiente de ajuste (Ver figura 26).

En la tabla 11 se muestran los valores AR, MA, el término constante y la varianza del modelo, junto con los valores de error estándar.

Figura 26: **Gráfica residuos para ARIMA(4,0,3) para la serie de tiempo de ocupación baja**




Tabla 11: **Resultados estimación modelo ARIMA(4,0,3) para el serie de tiempo de ocupación baja**

Parámetro	Valor	Error estándar
Constante	-0.5486	0.0747
AR(1)	0.9055	0.0273
AR(2)	1.0361	0.0246
AR(3)	-0.9086	0.0272
AR(4)	-0.0392	0.0246
MA(1)	-0.7421	0.0140
MA(2)	-0.9608	0.0048
MA(3)	0.7542	0.0126
Varianza	21.8346	0.3157

3.3.1.3 ARIMA(4,1,3) Los estimados para el modelo ARIMA(4,1,3) para la serie de tiempo del canal de ocupación alta, muestran que el modelo tiene una distribución gaussiana y se ajusta por completo a la serie debido a que la función de autocorrelación se encuentran dentro de los coeficientes de ajuste (Ver figura 27).

En la tabla 12 se muestran los valores AR, MA, el término constante y la varianza del modelo, junto con los valores de error estándar.

Figura 27: **Gráfica residuos para ARIMA(4,1,3) para la serie de tiempo de ocupación alta**




Tabla 12: **Resultados estimación modelo ARIMA(4,1,3) para el serie de tiempo de ocupación alta**

Parámetro	Valor	Error estándar
Constante	0.0029	0.05772
AR(1)	-0.3989	0.1969
AR(2)	0.4554	0.11452
AR(3)	-0.1914	0.05247
AR(4)	-0.0474	0.0367
MA(1)	-0.4692	0.1046
MA(2)	-0.6188	0.02977
MA(3)	-0.4467	0.05976
Varianza	39.5039	0.5334

Los estimados para el modelo ARIMA(4,1,3) para la serie de tiempo del canal de ocupación media, muestran que el modelo tiene una distribución gaussiana y tiene un buen ajuste a la serie debido a que la función de autocorrelación los valores se encuentran dentro de los coeficiente de ajuste (Ver figura 28).

En la tabla 13 se muestran los valores AR, MA, el término constante y la varianza del modelo, junto con los valores de error estándar.

Figura 28: **Gráfica residuos para ARIMA(4,1,3) para la serie de tiempo de ocupación media**




Tabla 13: **Resultados estimación modelo ARIMA(4,1,3) para el serie de tiempo de ocupación media**

textbfParámetro	Valor	Error estándar
Constante	0.0015	0.07
AR(1)	-0.7837	0.2601
AR(2)	0.1348	0.2753
AR(3)	-0.1182	0.0763
AR(4)	-0.0371	0.0591
MA(1)	-0.124	0.2605
MA(2)	-0.688	0.0434
MA(3)	-0.2172	0.01735
Varianza	23.814	0.3202

Los estimados para el modelo ARIMA(4,1,3) para la serie de tiempo del canal de ocupación baja, muestran que el modelo tiene una distribución gaussiana y tiene un buen ajuste a la serie debido a que la función de autocorrelación los valores se encuentran dentro de los coeficiente de ajuste (Ver figura 29).

En la tabla 14 se muestran los valores AR, MA, el término constante y la varianza del modelo, junto con los valores de error estándar.

Figura 29: **Gráfica residuos para ARIMA(4,1,3) para la serie de tiempo de ocupación baja**




Tabla 14: **Resultados estimación modelo ARIMA(4,1,3) para el serie de tiempo de ocupación baja**

Parámetro	Valor	Error estándar
Constante	-0.0261	0.1123
AR(1)	-1.336	0.3134
AR(2)	0.4447	0.3328
AR(3)	-0.2138	0.03799
AR(4)	-0.1049	0.02402
MA(1)	0.5533	0.3178
MA(2)	-0.5267	0.0927
MA(3)	-0.0869	0.2262
Varianza	22.586	0.3380

Según la metodología de Box-Jenkins, se sugiere que el modelo sea lo más simple posible, pero debido a que el modelo ARIMA(4,1,3) se ajusta bien para las 3 series de tiempo, se decide realizar las pruebas de implementación del algoritmo con el modelo ARIMA(4,1,3).

El modelo ARIMA que se obtuvo al final tiene 4 términos AR, 3 términos MA y 1 término de integración, descrito por la siguiente ecuación:

$$(1 - \Phi_1(L) - \Phi_2(L^2) - \Phi_3(L^3) - \Phi_4(L^4))(1 - L)Y_t = c + (1 + \Theta_1(L) + \Theta_2(L^2) + \Theta_3(L^3))E_t \quad (3.3)$$

Donde:

$\Phi_1, \Phi_2, \Phi_3, \Phi_4$ son los coeficientes del polinomio del proceso AR.

$\Theta_1, \Theta_2, \Theta_3$ son los coeficientes del polinomio del proceso MA.

Y el término $1 - L$, representa el término de integración.

3.4. CONFIGURACIÓN Y DESARROLLO DEL ALGORITMO

El código se desarrolló en Matlab, ya que este software proporciona herramientas computacionales que permite cálculos estadísticos y modelos predictivos que son precisos y bastante sencillos de utilizar.

3.4.1 Matlab Para el desarrollo de este algoritmo se hizo uso de las funciones de la librería "Econometrics", específicamente la función ARIMA y forecast que se describirán a continuación:

3.4.1.1 Función ARIMA Según MathWorks³⁹, la aplicación "Econometric Modeler" es una herramienta interactiva para analizar datos de series temporales univariadas, es ideal para visualizar y transformar datos, realizar pruebas de identificación estadística e identificación de modelos, ajustar modelos a los datos e iterar entre estas acciones. Cuando esté satisfecho con un modelo, puede exportarlo al espacio de trabajo de MATLAB para pronosticar respuestas futuras o para un análisis posterior. También puede generar código o un informe de una sesión.

Usando la función de generar un código a partir del análisis que se hace en la aplicación, se obtuvo la función ARIMA, la cual tiene como entrada la serie de tiempo y su salida es un objeto de tipo arima que guarda toda la información del modelo; el cual tiene las siguientes propiedades:

- ❖ **P:** Es el número total de observaciones necesarias para inicializar el componente autorregresivo del modelo, esto incluye los efectos de la integración estacional y no estacional capturados por las propiedades D y estacionalidad, respectivamente, y los polinomios autorregresivos no estacionales y estacionales AR y SAR. La propiedad P no necesariamente se ajusta a la notación estándar de Box y Jenkins, sólo se ajusta si el modelo no tiene integración ni componente estacional autorregresivo. Para este caso este valor corresponde a 5, ya que se tiene 4 valores del vector AR y un proceso de integración.
- ❖ **Q:** Es el número total necesario para inicializar el componente de media móvil del modelo, Q incluye los efectos de los polinomios promedio móviles no estacionales y estacionales MA y SMA, respectivamente. La propiedad Q no necesariamente se ajusta a la notación estándar de Box y Jenkins. Sólo se ajusta si el modelo no tiene ninguna componente promedio móvil estacional. Para este caso este valor corresponde a 3, que corresponde con los tres valores del vector MA.
- ❖ **Descripción:** Es una cadena de string que contiene la descripción del modelo.

³⁹Fuente: MathWorks Inc. MathWorks. [en línea]. [Consultado: 16 de agosto de 2018]. Disponible en: <https://la.mathworks.com>.

- ❖ **Distribución:** Estructura de datos para la distribución de probabilidad condicional del proceso de innovación. Si la distribución es "t", entonces la estructura tiene el campo DoF para almacenar los grados de libertad.
- ❖ **Constante:** Escalar constante en el modelo de serie de tiempo lineal.
- ❖ **AR:** Es el vector de coeficientes autorregresivos no estacional correspondiente a un polinomio estable, que corresponde a los coeficientes 1, 2,... según el grado del polinomio autorregresivo.
- ❖ **SAR:** Vector de coeficientes autoregresivos estacionales correspondientes a un polinomio estable, que corresponde a los coeficientes 1, 2,... según el grado del polinomio estacional autorregresivo.
- ❖ **MA:** Vector de coeficientes promedio móviles no estacional correspondiente a un polinomio inversible. MA es un vector de coeficientes en los rezagos 1, 2,... según el grado del polinomio de promedio móvil no estacional.
- ❖ **SMA:** Vector de coeficientes promedio móviles estacionales correspondiente a un polinomio inversible. SMA es un vector de coeficientes 1, 2,... según el grado del polinomio promedio móvil estacional.
- ❖ **D:** Entero no negativo que indica el grado de integración no estacional en la serie de tiempo lineal.
- ❖ **Estacionalidad:** Número entero no negativo que indica el grado polinomial de diferenciación estacional en el modelo lineal de series temporales.
- ❖ **Beta:** Vector real de coeficientes correspondientes al componente de regresión en un modelo ARIMAX.
- ❖ **Varianza:** Varianza escalar positiva de las innovaciones del modelo, o un objeto modelo de varianza condicional compatible (por ejemplo, un objeto modelo garch).

3.4.1.2 Forecast La función forecast es una clase del tipo arima, el cual hace un pronóstico basado en el modelo ARIMA. La estructura general es la siguiente:


$$[YF, YMSE] = \text{forecast}(Md1, numPeriods)$$

Donde:

- ❖ **Md1**: Es el modelo ARIMA o ARIMAX; este puede estar descrito como un objeto tipo arima como el que se describió anteriormente o utilizando la función “estimate”.
- ❖ **numPeriods**: Es un valor entero positivo que representa el número de periodos en los que se desea hacer el pronóstico.
- ❖ **Y**: Es el vector de valores de pronósticos; el tamaño del vector depende del valor de número de periodos que se desea calcular.
- ❖ **YMSE**: Las raíces cuadradas de YMSE son los errores estándar de las previsiones de Y.

Para el desarrollo del algoritmo se planteó una estructura general, esta se muestra en la siguiente figura.

Figura 30: **Diagrama de flujo que describe el algoritmo**



Capítulo 4

PRUEBAS Y RESULTADOS

Todo pronóstico tiene asociado un alcance, pudiendo ser éste de corto, mediano o largo plazo. En cuanto al tipo de pronóstico que se deba utilizar depende de la decisión que se desea tomar o cantidad de datos con los que se puede comparar; a mayor alcance de pronóstico mayor es el nivel de incertidumbre que se debe enfrentar.

4.1. CONJUNTOS DE ENTRENAMIENTO Y EVALUACIÓN


Para evaluar la precisión de los pronósticos se debe tener en cuenta la cantidad de muestras con las que se cuentan en total y el modelo predictivo que se va a utilizar. Para esta investigación se cuentan con 11 horas y un modelo tipo ARIMA, que se mencionó anteriormente.

Al conjunto de datos empleados para la construcción del modelo se le denomina conjunto de entrenamiento, mientras que el resto de los datos conforman el conjunto de evaluación. Para este caso en particular teniendo una muestra total de 11 horas, se tomaron 3 como tiempo de entrenamiento, ya que con este valor se encontraron errores RMSE aceptables comparados con otras investigaciones de este tipo⁴⁰.

Para el tiempo de evaluación es necesario definir el tamaño de la muestra de observación y la de predicción; para esto se realizaron pruebas cambiando estos tiempos, el resultado de dichas pruebas se muestran en la siguiente imagen.

⁴⁰PEDRAZA, Luis., Modelo de propagación para un entorno urbano que identifica las oportunidades espectrales para redes móviles de radio cognitiva. Tesis doctoral Bogotá D.C.: Universidad Nacional de Colombia. 2016. 128p

Figura 31: Tiempo de observación vs Error RMSE.



Como se puede observar en la imagen anterior a medida que se aumenta el tiempo de predicción aumenta el error RMSE, y a medida que se aumenta el tiempo de observación este error disminuye. El mejor compartimiento en las 4 gráficas es para la serie de tiempo de ocupación baja.


Basado en la gráfica anterior se eligió como tiempo de observación y de predicción de 3 horas ya que aunque el mejor comportamiento sería para media hora de predicción tomando 4 horas de observación, este modelo sería poco práctico ya que el alcance sería mínimo con una observación máxima.

4.2. VALIDACIÓN DEL MODELO DE PREDICCIÓN

Después de obtener los tiempo de entrenamiento y de evaluación, tal como se mencionó en la sección anterior, lo siguiente fue validar el tipo de predicción que se desea hacer; ya que esta investigación fue hecha con fines académicos, la forma de evaluar la precisión del pronósticos es con los de datos que previamente se separó de la muestra disponible y que no participó de la construcción del modelo, es decir la muestra total fue de 11 horas, el tiempo que se tomo para la construcción del modelo fue de 3 horas, por lo tanto el conjunto disponible para la evaluación del pronóstico es de 8 horas, como se mencionó anteriormente se tomó 6 horas para la evaluación dividido en 2 conjuntos de 3 horas.

La primera prueba de predicción que se hizo fue con el ciclo de trabajo, calculandolos cada media hora desde la 2 p.m hasta las 5 p.m con los datos obtenidos en la medición y compararlos con los datos obtenidos con el modelo predictivo.

Figura 32: **Ciclo de trabajo real y predicho.**



Como se observa en la imagen anterior en promedio el modelo predictivo es capaz de predecir los cambios que se producen en el canal ya que como se ve en la barras azules, que representan el valor real del ciclo de trabajo, presenta variaciones cada media hora; y las otras representan el valor predicho, intentan seguir dichas variaciones. En la siguiente tabla se muestra el error relativo porcentual para la predicción del ciclo de trabajo de cada media hora.

Tabla 15: **Error relativo porcentual para el ciclo de trabajo.**

Tiempo	Error relativo porcentual [%]		
	Bajo	Medio	Alto
14:00-14:30	5	12,66	7,53
14:30-15:00	11,67	5,95	19,30
15:00-15:30	28,57	22,09	4,81
15:30-16:00	15,49	9,20	13,59
16:00-16:30	54,05	16,67	0
16:30-17:00	18,64	1,23	6,67

Para determinar los posibles huecos espectrales que se encuentran en la banda estudiada se analizaron los datos obtenidos del vector de predicción de todos los canales para cada 200 muestras, en la siguiente tabla se muestra el resumen de los posibles huecos

espectrales que se encontraron para los 3 canales, cada media hora.

La serie de tiempo de ocupación alta tiene ciclos de trabajo superiores al 50 %, lo que quiere decir que en su mayoría los niveles de potencia superan el piso de ruido, por eso los posibles huecos espectrales que se muestran en la tabla 13 disminuye significativamente con respecto a los otros dos canales analizados.

Tabla 16: **Posibles huecos espectrales para el canal de ocupación alta.**

Tiempo	Frecuencia central (MHz)	Ancho de banda (KHz)
14:30-15:00	875,6	348
	878,5	348
	880,9	232
15:30-16:00	873,8	348
	877,9	812
16:30-17:00	874,9	232

En la siguiente tabla se muestra los posibles huecos espectrales para el canal de ocupación media, su frecuencia central y ancho de banda, para un tiempo de 2 p.m a 5 p.m, medidos cada media hora. En la columna de ancho de banda se puede ver que se obtiene anchos de banda superiores al 200 [KHz] y variaciones en su frecuencia central.

Tabla 17: **Posibles huecos espectrales para el canal de ocupación media.**

Tiempo	Fecuencia central (MHz)	Ancho de banda (KHz)
14:00-14:30	862,4	1200
	864,7	1700
	865,3	580
	867,9	580
14:30-15:00	861,7	232
	864,4	580
	865,7	348
	868	348
15:00-15:30	868,6	348
	862,2	812
	864	2000
	865,4	232
15:30-16:00	868	812
	861,7	232
	862,5	928
	863,7	232
16:00-16:30	864,8	580
	868,5	580
	862,1	1000
	863,6	1300
16:30-17:00	864,8	232
	868	348
	862,3	928
	863,4	348
	864,6	348
	868,3	906,5

En la tabla 15, se muestra los posibles huecos espectrales que se encuentran en la banda del canal de ocupación baja, que como se esperaba varían cada media hora; En la columna de ancho de banda se muestra ancho de bandas superiores a los 200 [KHz] y variaciones en la frecuencia central cada media hora.


Tabla 18: **Posibles huecos espectrales para el canal de ocupación baja.**

Tiempo	Fecuencia central (MHz)	Ancho de banda (KHz)
14:00-14:30	898,7	1300
	900,3	1200
	901,4	232
	902,4	464
	904,7	580
	905,6	580
	907,5	812
14:30-15:00	897,6	348
	897,9	232
	899,5	1200
	900,8	928
	906,3	812
	907,4	464
15:00-15:30	897	348
	898,2	812
	900,4	1000
	901,4	232
	903,4	348
	904,6	812
	907,1	1200
15:30-16:00	898,5	1400
	900,5	1500
	906	928
	907,8	232
16:00-16:30	898,2	348
	899,2	589
	900,2	928
	903,3	580
	906,9	348
16:30-17:00	898.4	1200
	900,8	232
	902.1	464
	906,5	1200

Para ver como se comportó el modelo de predicción durante este tiempo, se gráfico el tiempo de observación y el tiempo de predicción para observar el comportamiento del

espectro predicho durante estas 3 horas de predicción (Ver figura 33).

Figura 33: Tiempo de observación y predicho.




Como se puede ver en la imagen anterior el modelo planteado con el algoritmo propuesto

para esta investigación, intenta durante estas tres horas de predicción seguir el espectro tal como lo observo, durante el tiempo de observación y basado en el modelo que se ajusto a las 3 primeras horas de recopilación de datos. En la figura 34 se comparan los valores reales y los predichos para las 3 horas de predicción.

Los errores RMSE y MAPE para la predicción en la serie de tiempo de ocupación bajo fueron **9.32** y **0.040**, en la serie de ocupación medio fueron **10.834** y **0.098**, en la serie de ocupación alta fueron **15.57** y **0.156**.

Figura 34: Comparación entre el tiempo real y el predicho.



Capítulo 5

CONCLUSIONES

Los algoritmos de predicción son un método de implementación de radio cognitiva, los cuales presentan errores mínimos, por esto se considera una de las mejores formas de implementación de este sistema: esto mismo se pudo corroborar con este proyecto, ya que el algoritmo que se diseñado funciona correctamente en la banda utilizada, por lo tanto puede ser facilmente replicado para otras bandas de frecuencia. Una forma de mejorar este método es implementando una base conocimiento de la geolocalización del espectro ocupado ya que así ya se tiene información a priori del compartamiento del espectro en otras bandas.

La banda de frecuencia escogida para esta investigación fue de 850 a 1900 [MHz] debido a que durante el tiempo de recopilación de datos no se encontró ninguna variación que supere el piso de ruido en la banda de 1000 a 1900 [MHz] debido a que estas bandas están siendo utilizadas por comunicación satelital, radionavegación y servicios de meteorología que no fueron detectados con la antena utilizada para este fin, se decidió analizar la banda de 850 a 1000 [MHz]. Para poder disminuir el tiempo de barrido y poder detectar cualquier pequeña variación en este canal se bajo el span analizado a 58 [MHz] escogiendo los canales cuyo ciclo de trabajo varía entre los valores más altos y los mínimos.

Dada la serie de tiempo obtenida por el monitero del espectro planteado en este proyecto y después de probar otros modelos de estimación se encontró que el modelo ARIMA(4,1,3), es el más adecuado ya que ningún término del modelo es igual a cero y con el criterio de la función de autocorrelación residual se ajusta al conjunto de serie de tiempo analizada.

La estructura general implementada para el diseño del algoritmo puede ser replicada en cualquier lenguaje de programación y banda de frecuencia, para este caso se utilizó Matlab ya que esta herramienta computacional presenta cálculos sencillos y fácil de implementar para modelos predictivos ARIMA.

Capítulo 6

TRABAJOS FUTUROS

El siguiente trabajo que tome como base esta investigación es el desarrollo de un algoritmo de transmisión autónomo, teniendo en cuenta los parámetros de transmisión que se necesite, buscando el ancho de banda necesario para que sea el mejor canal disponible y evitando interferencias.

Para una mejor validación del espacio en blanco encontrado se sugiere transmitir señales de audio o datos para conocer el comportamiento de la transmisión y validar la recepción de la señal con valores reales.

También se desea implementar esta misma metodología en otras bandas de frecuencia, analizando el comportamiento del espectro y la posible serie de tiempo, y poder adaptar el modelo de predicción analizado en este proyecto.

BIBLIOGRAFÍA

ANTIRI, J.; KHADIMI, E. y ZEROUAL A., "Identification parameters of MA model and non-minimum phase channel using adaptive method". En: IEEE. Octubre, 2012.

BOX G.; JENKINS G. Y REINSEL G., "Time series analysis, forecasting and control.", 3ra Ed, New Jersey, USA: Prentice Hall, 1994.

CHATFIELD C., "The analysis of time series: theory and practice", Londres: Chapman and Hall., 1978.

CONGALTON, Russell G y GREEN, Kass. Assessing the accuracy of remotely sensed data: Principles and Practices. Second Edition. New York: Taylor & Francis Group. p-193

Cuadro Nacional de atribución de bandas de Frecuencias (CNABF) [en línea]. Disponible en internet: <http://cnabf.ane.gov.co>

CUROTTO, Franco; ESPINOSA, Sebastián y VERGARA, Mario. Antenas, polarización y diagramas de radiación. Universidad de Chile. Facultad de ciencias físicas y matemáticas. (Octubre de 2012)

DURÁN DURÁN, Diego Erley y PLATA ESPINOSA, Manuel Arnulfo. Implementación, validación y verificación de los algoritmos de convulsión y transformada rápida de Fourier en dos dimensiones sobre un clúster de computadores MAC. Universidad Industrial de Santander. 2009. p: 3-5.

Ente Nacional de Comunicaciones (ENACOM) [en línea]. Disponible en internet: <http://www.enacom.gob.ar>.

GARCIA C. and SANCHEZ M., "Series temporales Univariantes". Universidad Politécnica de Madrid.

GERSCH, Will; Y BROTHERTON, Tom. "AR model prediction of time series with trends and seasonalities: A contrast with Box-Jenkins modeling". En: IEEE. Abril, 2007. p. 980-990.

GNU Radio[en línea].[Consultado: 10 de Octubre de 2018]. Disponible en: <https://www.gnuradio.org/>

GUJARATI D., "Econometría",3ra Ed., Santa Fé de Bogotá, Colombia: McGraw-Hill.1997.

HANKE, E.; and REITSCH G. Pronósticos en los Negocios, 5ta Ed, Prentice-Hall, 1996.

HANKE, E.; JHON, E. y WINCHERN, Dean W. Pronósticos en los negocios. Octava edición. Pearson:2006. p-413

IV SIMPOSIO DE METODOLOGÍA DE LAS CIENCIAS DEL COMPORTAMIENTO. Abril 1995: Murcia. Modelos multivariantes. Universidad de Murcia. p-277

Kent Electronics: WA5VJB. [en línea].[Consultado: 8 de Octubre de 2018]. Disponible en: <https://www.wa5vjb.com/products1.html>.

MathWorks Inc. MathWorks. [en línea]. [Consultado: 12 de agosto de 2018]. Disponible en: <https://la.mathworks.com>

Minitab Inc. Soporte técnico de Minitab 18. [en línea]. [Consultado: 12 de agosto de 2018]. Disponible en: <https://support.minitab.com>

NATIONAL INSTRUMENT. USRP [en línea].[Consultado: 8 de Octubre de 2018]. Disponible en: <http://www.ni.com/es-co/support/model.usrp-2920.html>

PEDRAZA, Luis., Modelo de propagación para un entorno urbano que identifica las oportunidades espectrales para redes móviles de radio cognitiva. Tesis doctoral Bogotá D.C.: Universidad Nacional de Colombia. 2016. 128p

PEDRAZA, Luis. y HERNANDEZ, Cesar. "Aplicaciones De Las Series De Tiempo En Modelos De Tráfico Para Una Red De Datos" .Scientia Et Technica. Ed: v.38.

PÉREZ, F. Introduccion a las series de tiempo. Métodos paramétricos. Universidad de Medellin. 2007.

PNSN (red sísmica del noroeste del pacífico) [en línea]. Disponible en internet: <https://pnsn.org/spectrograms/what-is-a-spectrogram>.

Qi Wang; Li-xin Wang and Qiang Shen., "Modeling strategy of high order ARMA model". En IEEE. Enero, 2017. p. 2001-2005

ROHDE& SCHWARZ. HMS-X Spectrum Analyzer. [en línea]. (Recuperado: 22 de agosto de 2018).Disponible: www.rohde-schwarz.com

StatsModels: Statistics in python. [en línea].[Consultado: 10 de octubre de 2018]. Disponible en:www.statsmodels.org

Wedding II y Cios., "Time series forecasting by combining RBF network, certainty factor, and the Box-Jenkins model". Neurocomputing, 1996. p. 149-168.

ZHANG, G. Peter, Neural Networks in Business Forecasting. Georgia State University, USA: Idea group publishing. p-285

ANEXOS

A. Código de Matlab

```

%%Tercera versión del algoritmo predictor de
huecos espectrales
%%Proyecto de grado 2019
%%Anghye Plata
%%
clc
clear all
close all
%Cargar variables y definir variables iniciales
load('Canal W2','W2')
load('Canal W3','W3')
load('Canal W5','W5')
load('Frecuecia C1','F1')
load('Frecuecia C2','F2')
load('Frecuecia C3','F3')
load('Frecuecia C4','F4')
load('Frecuecia C5','F5')
hora=400;
a=5;
c=1;
per=hora*3;
obs=hora*3;
Y1=W5;
entr=Y1(1:(hora*3));
tentr=1200
Md4 = modelTimeSeries(entr);
plot(Y1(tentr+1:tentr+per),'Color',[.7,.7,.7]);
hold on
for i=1:length(Y1(tentr+1:tentr+per))+5
    if a==length(Y1(tentr+1:tentr+per))+5
        break
    end
    [YF,YMSE] = forecast(Md4,5,'Y0',Y1(1:a));
    for l=1:length(YF)
        yf(c)=YF(l);
        ymse(c)=YMSE(l);
        c=c+1;
    end
end

```

```

plot(a+1+obs:a+5+obs,YF,'b','LineWidth',2);
    a=a+5;
end
RMSE_b=sqrt(mean(( W5(tentr+obs+1:tentr+obs+per)-
yf').^2));
pth=-73;
Ni=0;
    Nj=0;
b=2400;
for s=1:6
for i=b+1:b+200
    if W5(i)>pth
        Ni=Ni+1;
    end
    end
    c5r(s)=(Ni/200)*100;
    Ni=0;
    b=b+200;
end
b=0;
s=1;
for s=1:6
for j=b+1:b+200
    if yf(j)>pth
        Nj=Nj+1;
    end
end
    c5p(s)=(Nj/200)*100;
    Nj=0;
    b=b+200;
end
figure(2)

C=[c5r(1) c5p(1);c5r(2) c5p(2); c5r(3)
c5p(3);c5r(4) c5p(4); c5r(5) c5p(5); c5r(6)
c5p(6)];% c5r(7) c5p(7); c5r(8) c5p(8)];

```



```

subplot(3,1,1)
bar([1:6],C)
%%
%Media
Y1=W2;
a=5;
c=1;
figure(3)
plot(Y1(tentr+1:tentr+per),'Color',[.7,.7,.7]);
hold on
for i=1:length(Y1(tentr+1:tentr+per))+5
    if a==length(Y1(tentr+1:tentr+per))+5
        break
    end
    [YF,YMSE] = forecast(Md4,5,'Y0',Y1(1:a));
    for l=1:length(YF)
        yf1(c)=YF(l);
        ymse(c)=YMSE(l);
        c=c+1;
    end

plot(a+1+obs:a+5+obs,YF,'b','LineWidth',2);
a=a+5;
end
RMSE_m=sum(sqrt(mean((
W2(tentr+obs+1:tentr+obs+per)-yf1').^2))));
pth=-73;
Ni=0;
Nj=0;
b=2400;
for s=1:6
for i=b+1:b+200
    if W2(i)>pth
        Ni=Ni+1;
    end
end
c2r(s)=(Ni/200)*100;
Ni=0;

```

```

        b=b+200;
end
b=0;
s=1;
for s=1:6
for j=b+1:b+200
    if yf1(j)>pth
        Nj=Nj+1;
    end
end
c2p(s)=(Nj/200)*100;
Nj=0;
b=b+200;
end
figure(2)
C2=[c2r(1) c2p(1);c2r(2) c2p(2); c2r(3)
c2p(3);c2r(4) c2p(4); c2r(5) c2p(5); c2r(6)
c2p(6)];% c5r(7) c5p(7); c5r(8) c5p(8)];
subplot(3,1,2)
bar([1:6],C2)
%%
%Alta
Y1=W3;
a=5;
c=1;
figure(4)
plot(Y1(tentr+1:tentr+per),'Color',[.7,.7,.7]);
hold on
for i=1:length(Y1(tentr+1:tentr+per))+5
    if a==length(Y1(tentr+1:tentr+per))+5
        break
    end
    [YF,YMSE] = forecast(Md4,5,'Y0',Y1(1:a));
    for l=1:length(YF)
        yf2(c)=YF(l);
        ymse(c)=YMSE(l);
        c=c+1;
    end
end

```

```

plot(a+1+obs:a+5+obs,YF,'b','LineWidth',2);
    a=a+5;
end
pth=-73;
Ni=0;
    Nj=0;
b=2400;
for s=1:6
for i=b+1:b+200
    if W3(i)>pth
        Ni=Ni+1;
    end
    end
    c3r(s)=(Ni/200)*100;
    Ni=0;
    b=b+200;
end
b=0;
s=1;
for s=1:6
for j=b+1:b+200
    if yf2(j)>pth
        Nj=Nj+1;
    end
    end
    c3p(s)=(Nj/200)*100;
    Nj=0;
    b=b+200;
end
figure(2)
C3=[c3r(1) c3p(1);c3r(2) c3p(2); c3r(3)
c3p(3);c3r(4) c3p(4); c3r(5) c3p(5); c3r(6)
c3p(6)];% c5r(7) c5p(7); c5r(8) c5p(8)];
subplot(3,1,3)
bar([1:6],C3)


```

C. Script utilizado para la adquisición de datos

```
Loop 8
Send TRACe:DATA:FORMat {BIN|CSV}
Send TRACe:DATA:FORMat?
Send TRACe:DATA?
Send HCOPy:FORM {BMP,GIF}
Send HCOPy:DATA?
Wait 30000
End Loop
```

D. Características técnicas de los conectores utilizados


Adaptador BNC hembra a tipo N macho.



Características comunes

Resistencia de aislamiento	5000 Mohm
Rigidez dieléctrica	2500 VRMS mín
Impedancia	50 ohm
Tensión de trabajo	1500 VRMS máx
VSWR	1'3 máx
Rango de frecuencias	0-11 GHz
Resistencia de contacto máxima	3 mohm
Material aislante	PTFE


Adaptador N macho a UHF hembra.



Características comunes

Resistencia de contacto	3 mohm máx
Resistencia de aislamiento	5000 Mohm
Rigidez dieléctrica	2500 VRMS mín
Impedancia	50 ohm
Tensión de trabajo	1500 VRMS máx
VSWR	1'3 máx
Rango de frecuencias	0-11 GHz
Resistencia de contacto máxima	3 mohm
Material aislante	PTFE
Tipo conector 1	N macho
Tipo conector 2	UHF hembra

Adaptador N macho a UHF macho.



Características comunes

Resistencia de contacto	3 mohm máx
Resistencia de aislamiento	5000 Mohm
Rigidez dieléctrica	2500 VRMS mín
Impedancia	50 ohm
Tensión de trabajo	1500 VRMS máx
VSWR	1'3 máx
Rango de frecuencias	0-11 GHz
Resistencia de contacto máxima	3 mohm
Material aislante	PTFE
Tipo conector 1	N macho
Tipo conector 2	UHF macho