

ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL

Facultad de Ingeniería en Electricidad y Computación

Pronóstico de carga a largo plazo de alimentadores distribución basado en una metodología híbrida de predicción. Caso de estudio: Empresa

Eléctrica Regional del Sur S.A.

PROYECTO DE TITULACIÓN

Previo la obtención del Título de:

**MAGÍSTER EN ELECTRICIDAD, MENCIÓN SISTEMAS
ELÉCTRICAS DE POTENCIA**

Presentado por:

Josué David Moreno Live

GUAYAQUIL - ECUADOR

Año: 2022

DEDICATORIA

“El presente proyecto se lo dedico a mis padres María Salomé y Fabricio, por ser mi ejemplo de superación y por su infinita entrega desinteresada a mi formación como ser humano y profesional. A mi hermana, por su infinita paciencia y fortaleza para motivarme a lograr la mejor versión de mí, a toda mi familia que siempre es y será mi refugio contra todas las adversidades de la vida. Y a todos quienes me impulsaron a cumplir este objetivo”.

AGRADECIMIENTOS

Mi más sincero agradecimiento a mi tutor el PhD. Miguel Torres por sus conocimientos y experiencia compartida conmigo, y además por su disposición desinteresada para cumplir este objetivo. También quiero agradecer al PhD. José Córdova por su apoyo académico durante el desarrollo de mi proyecto de titulación. Finalmente, a la Superintendencia de Subestaciones y Comunicaciones de la Empresa Eléctrica Regional del Sur S.A por darme todas las facilidades para culminar exitosamente el presente proyecto.

DECLARACIÓN EXPRESA

“Los derechos de titularidad y explotación, me(nos) corresponde conforme al reglamento de propiedad intelectual de la institución; *(nombre de los participantes)* y doy(damos) mi(nuestro) consentimiento para que la ESPOL realice la comunicación pública de la obra por cualquier medio con el fin de promover la consulta, difusión y uso público de la producción intelectual”

Josué David Moreno
Live

EVALUADORES

.....
Nombre del Profesor

Phd. Miguel Torres

.....
Nombre del Profesor

Phd. José Córdova

.....
Nombre del Profesor

MSc. Fernando Vaca

RESUMEN

La Estimación de la Demanda Eléctrica a largo plazo (LTLF) se considera una problemática actual para las Empresas Eléctricas Distribuidoras, ya que es la base para la toma de decisiones y directrices de planeamiento y expansión del Sistema Eléctrico de Distribución (SED).

Por lo tanto, una inadecuada metodología de cálculo puede provocar limitaciones técnicas y operativas del SED a futuro. Es por esto, que esta problemática debe tener un enfoque que implemente tanto registros históricos, como la aplicación algoritmos matemáticos que determinen el escenario de mayor probabilidad de demanda máxima.

Para el presente trabajo se desarrolló una metodología a partir de los registros históricos de potencia activa medida en cabecera de los A/P (Parque Industrial, Motupe, Chuquiribamba y Carigán) de la S/E Norte, esta información fue extraída del ADMS en el periodo 2012-2021. Posterior a esto se realizó un preprocesamiento en el cual se depuro valores correspondientes a fallas transitorias , fallas permanentes, transferencia de carga, mallado entre alimentadores, pérdidas de comunicación y datos inconsistentes. Con el lenguaje de programación Python se aplicó el algoritmo GMM para obtener las curvas de demanda máxima de mayor representación para cada año histórico por cada alimentador. Y mediante programación de los métodos ARIMA y SARIMA se obtuvo el modelo con menor AIC, para luego proceder a seleccionar el modelo con mejores métricas de estimación (MAPE), y proyectar la demanda eléctrica en un horizonte de 10 años. Finalmente, con los valores estimados se calculó las caídas de voltaje, pérdidas de potencia, cargabilidad del transformador, y límites térmicos mediante un software de simulación.

Palabras Clave: Alimentadores de distribución, machine learning, modelos gaussianos mixtos, estimación carga, largo plazo.

ABSTRACT

The Long-term Electricity Demand Estimation (LTLF) is considered a current problem for Electricity Distribution Companies, since it is the basis for decision-making and guidelines for planning and expansion of the Electricity Distribution System (SED).

Therefore, an inadequate calculation methodology can cause technical and operational limitations of the SED in the future. For this reason, this problem must have an approach that implements both historical records and the application of mathematical algorithms that determine the scenario with the highest probability of maximum demand.

For the present work, a methodology was developed based on the historical records of active power measured at the head of the feeder (Parque Industrial, Motupe, Chuquiribamba and Carigán) of the S/E Norte, this information was extracted from the ADMS in the period 2012-2021. After this, a preprocessing was carried out in which values corresponding to transient faults, permanent faults, load transfer, meshing between feeders, communication losses and inconsistent data were filtered. With the Python programming language, the GMM algorithm was applied to obtain the maximum demand curves with the highest representation for each historical year for each feeder. And by programming the ARIMA and SARIMA methods, the model with the lowest AIC was obtained, to then proceed to select the model with the best estimation metrics (MAPE), and project the electricity demand over a 10-year horizon. Finally, with the estimated values, the voltage drops, power losses, transformer loadability, and thermal limits were calculated using simulation software.

Keywords: *distribution feeders, machine learning, mixed Gaussian models, forecasting load, long-term*

ÍNDICE GENERAL

EVALUADORES.....	5
RESUMEN.....	I
<i>ABSTRACT</i>	II
ÍNDICE GENERAL.....	III
ABREVIATURAS	VI
SIMBOLOGÍA	VII
ÍNDICE DE FIGURAS.....	VIII
ÍNDICE DE TABLAS	XI
CAPÍTULO 1	12
1. Introducción	12
1.1 Descripción del problema	12
1.2 Justificación del problema.....	13
1.3 Objetivos.....	14
1.3.1 Objetivo General	14
1.3.2 Objetivos Específicos	14
1.4 Contribución.....	14
CAPÍTULO 2.....	16
2. Marco teórico	16
2.1 Planificación de la Expansión de los Sistemas Distribución	16
2.2 Clasificación de Técnicas de Pronóstico de Demanda	17
2.2.1 Técnicas de Estimación Tradicionales	17
2.2.2 Técnicas de Estimación Tradicionales Modificadas	19
2.2.3 Técnicas de Computación Suaves	23
2.3 Métricas de dispersión del error del pronóstico	25

2.3.1	Error porcentual absoluto medio (MAPE).....	25
2.3.2	Error de raíz cuadrada media (RMSE).....	26
2.3.3	Error cuadrático medio (MSE).....	26
2.3.4	Coefficiente de determinación (R^2).....	27
2.4	Estimadores de calidad del modelo estadístico.....	27
2.4.1	Criterio de Información Akaike (AIC).....	27
2.4.2	Criterio de Información Bayesiano (BIC).....	28
CAPÍTULO 3.....		29
3.	Propuesta de Estimación de demanda a largo plazo.....	29
3.1	Introducción.....	29
3.2	Normalización de la Base de Datos.....	31
3.2.1	Procedimiento de Normalización.....	31
3.2.2	Criterios de Normalización.....	32
3.3	Modelo Gaussiano Mixture.....	33
3.3.1	Modelamiento Matemático.....	33
3.3.2	Mezcla de dos Componentes Gaussianas.....	35
3.3.3	Estimación de Parámetros mediante el algoritmo de maximización de expectativas (EM).....	35
3.4	Técnica Pronóstico-Adoptada.....	36
3.4.1	Prueba de Estacionalidad.....	37
3.4.2	Identificación de Modelo.....	37
3.4.3	Ajuste de Modelo.....	40
3.4.4	Evaluación de Desempeño.....	41
3.5	Modelación y Simulación.....	41
CAPÍTULO 4.....		43
4.	pruebas y resultados.....	43

4.1	Normalización de las Curvas de Demanda Históricas de los A/P de la S/E Norte	43
4.1.1	A/P Parque Industrial	43
4.1.2	A/P Chuquiribamba	46
4.1.3	A/P Motupe	48
4.1.4	A/P Carigán	50
4.2	Aplicación del Algoritmo GMM para los Registros Históricos Normalizados.	51
4.3	Proyección de la Demanda de los A/P de la S/E Norte	58
4.3.1	Modelo ARIMA	58
4.3.2	Modelo ARIMA Optimizado	63
4.3.3	Modelo SARIMA Optimizado.....	65
4.3.4	Incorporación de Cargas Especiales.....	68
4.3.5	Proyección de la Demanda para el periodo 2022-2031	69
4.4	Simulación de Resultados de la Demanda Proyectada	73
4.4.1	Diagrama Unifilar.....	73
4.4.2	Cargabilidad del Transformador de Potencia	74
4.4.3	Límites Térmicos de los A/P.....	76
4.4.4	Caídas de Voltaje y Pérdidas de Potencia	78
CAPITULO 5.....		81
5.	CONCLUSIONES	81
5.1	Conclusiones	81
5.2	Recomendaciones	82
REFERENCIAS		83
ANEXOS.....		85

ABREVIATURAS

ESPOL	Escuela Superior Politécnica del Litoral
LTLF	Estimación de carga a largo plazo en alimentadores de distribución
EERSSA	Empresa Eléctrica Regional del Sur S.A
SED	Sistema Eléctrico de Distribución
ARCONEL	Agencia de Regulación y Control de Electricidad
ARCERNNR	Agencia de Regulación y Control de Energía y Recursos Naturales No Renovables
ADMS	Advanced Distribution Management System
SCADA	Supervisory Control and Data Acquisition
CDE	Curva de Demanda Eléctrica
AR	Modelo Autorregresivo
ARMA	Promedio Móvil Autoregresivo
ARIMA	Promedio Móvil Integrado Autoregresivo
SARIMA	Promedio Móvil Integrado Estacional
SLT	Teoría de Aprendizaje Estadístico
GA	Algoritmos Genéticos
NN	Redes Neuronales
ANN	Redes Artificiales Neuronales
MAPE	Error Porcentual Absoluto Medio
RMSE	Error de Raíz Cuadrada Media
MSE	Error Cuadrático Medio
R ²	Coefficiente de Determinación
AIC	Criterio de Información Akaike
BIC	Criterio de Información Bayesiano
EM	Algoritmo de Máxima de Expectativa
FDP	Función de Densidad de Probabilidad
ACF	Función de Autocorrelación
PACF	Función de Autocorrelación Parcial
ADF	Prueba Aumentada de Dickey-Fuller
EP	Elaboración Propia

SIMBOLOGÍA

A/P	Alimentador Primario
S/E	Subestación Eléctrica
km	Kilómetro
kW	Kilovatio
kV	Kilovoltio
A	Amperio
p.u	Sistema por Unidad
t	Tiempo

ÍNDICE DE FIGURAS

Figura 3.1 Diagrama de flujo de propuesta metodológica de LTLF [E.P].....	30
Figura 3.2 Ejemplo de transferencia de carga de un A/P A hacia B [6].	32
Figura 3.3 Aproximación de mezcla guassiana de densidad [20].	34
Figura 4.1 CDE del A/P Parque Industrial año 2012 [E.P].....	44
Figura 4.2 CDE del A/P Parque Industrial año 2015 [E.P].....	44
Figura 4.3 CDE del A/P Parque Industrial año 2021 [E.P].....	45
Figura 4.4 CDE del A/P Chuquiribamba año 2012 [E.P].....	46
Figura 4.5 CDE del A/P Chuquiribamba año 2016 [E.P].....	47
Figura 4.6 CDE del A/P Chuquiribamba año 2017 [E.P].....	47
Figura 4.7 CDE del A/P Motupe año 2012 [E.P].	48
Figura 4.8 CDE del A/P Motupe año 2019 [E.P].	49
Figura 4.9 CDE del A/P Motupe año 2020 [E.P].	50
Figura 4.10 CDE del A/P Carigán año 2012 [E.P].....	51
Figura 4.11 CDE del A/P Carigán año 2014 [E.P].....	51
Figura 4.12 FDP de la Demanda Eléctrica A/P Parque Industrial [E.P].	53
Figura 4.13 Número óptimo de componentes para FPD A/P Parque Industrial 2012 [E.P].....	54
Figura 4.14 Número óptimo de componentes FPD A/P Parque Industrial 2020 [E.P].	54
Figura 4.15 Número óptimo de componentes Caso 1 vs Caso 2 A/P Parque Industrial [Elaboración Propia].....	56
Figura 4.16 CDE Históricas A/P Parque Industrial periodo 2012-2021 [E.P].....	57
Figura 4.17 CDE Históricas A/P Chuquiribamba periodo 2012-2021[E.P].....	57
Figura 4.18 CDE Históricas A/P Motupe periodo 2012-2021[E.P].	57
Figura 4.19 CDE Históricas A/P Carigán periodo 2012-2021 [E.P].....	57

Figura 4.20 Diferenciación de la Base de Datos A/P Parque Industrial [E.P].	59
Figura 4.21 Gráfico PACF A/P Parque Industrial [E.P].	60
Figura 4.22 Gráfico ACF A/P Parque Industrial [E.P].	60
Figura 4.23 Resumen Modelo ARIMA (1,1,1) A/P Parque Industrial [E.P].	61
Figura 4.24 Resultados Prueba Ljung-Box Modelo ARIMA (1,1,1) A/P Parque Industrial [E.P].	62
Figura 4.25 Validación Cruzada Serie de Tiempo Modelo ARIMA (1,1,1) A/P Parque Industrial [E.P].	63
Figura 4.26 Parámetros de pm.auto_arima A/P Parque Industrial [E.P].	64
Figura 4.27 Procedimiento recursivo de la aplicación pm.auto_arima A/P Parque Industrial [E.P].	64
Figura 4.28 Validación Cruzada Serie de Tiempo Modelo ARIMA (3,0,1) A/P Parque Industrial [E.P].	65
Figura 4.29 Diferenciación modelos ARIMA y SARIMA [E.P].	66
Figura 4.30 Parámetros modelo SARIMA A/P Parque Industrial [E.P].	66
Figura 4.31 Procedimiento recursivo modelo SARIMA A/P Parque Industrial [E.P].	67
Figura 4.32 Validación Cruzada Serie de Tiempo Modelo SARIMA (2,1,2)(0,1,1) A/P Parque Industrial [E.P].	67
Figura 4.33 Validación Cruzada Completa SARIMA (2,1,2)(0,1,1) A/P Parque Industrial [E.P].	68
Figura 4.34 C.D.E Carga Especial [E.P].	69
Figura 4.35 Proyección de la Demanda A/P Parque Industrial periodo 2022-2031 [E.P].	71
Figura 4.36 Proyección de la Demanda A/P Chuquiribamba periodo 2022-2031 [E.P].	71
Figura 4.37 Proyección de la Demanda A/P Motupe periodo 2022-2031 [E.P].	72
Figura 4.38 Proyección de la Demanda A/P Carigán periodo 2022-2031 [E.P].	72

Figura 4.39 Diagrama Unifilar S/E Norte [E.P].	73
Figura 4.40 Corrientes máximas proyectadas S/E Norte periodo 2012-203 [E.P].	75
Figura 4.41 Curva de Corriente Proyectada A/P Parque Industrial año 2031 [E.P].	76
Figura 4.42 Curva de Corriente Proyectada A/P Chuquiribamba año 2031 [E.P].	76
Figura 4.43 Curva de Corriente Proyectada A/P Chuquiribamba año 2031 [E.P].	77
Figura 4.44 Curva de Corriente Proyectada A/P Carigán año 2031 [E.P].	77
Figura 4.45 Caídas de Voltaje en pu barra 13.8kV S/E Norte periodo 2022-2031 [E.P].	79
Figura 4.46 Caídas de Voltaje en kV barra 13.8kV S/E Norte periodo 2022-2031 [E.P]	79
Figura 4.47 Pérdidas de Potencia del Transformador Potencia de la S/E Norte periodo 2022-2031[E.P]	80

ÍNDICE DE TABLAS

Tabla 3.1 Característica Teóricas para la ACF y PACF para Procesos Estacionarios [22].	38
Tabla 3.2 Criterio para el Orden del Modelo ARMA [21].	39
Tabla 4.1 Parámetros para el Modelo Gaussiano [E.P].	52
Tabla 4.2 Resultados de covarianzas, pesos y medias A/P Parque Industrial año 2012 [E.P].	52
Tabla 4.3 Determinación de Escenario Dmáx A/P Parque Industrial [E.P].	55
Tabla 4.4 Análisis Número de Componentes FDP A/P Parque Industrial [E.P].	55
Tabla 4.5 Resultados Prueba Dikey-Fuller A/P Parque Industrial [E.P].	58
Tabla 4.6 Resultados Prueba Dikey-Fuller primera diferenciación A/P Parque Industrial [E.P].	59
Tabla 4.7 P-valor del Modelo ARIMA (1,1,1) A/P Parque Industrial [E.P].	61
Tabla 4.8 Métricas Pronóstico Modelo ARIMA (1,1,1) A/P Parque Industrial [E.P].	63
Tabla 4.9 Métricas Pronóstico Modelo ARIMA (2,1,3) A/P Parque Industrial [E.P].	65
Tabla 4.10 Métricas Pronóstico Modelo SARIMA (2,1,2)(0,1,1) A/P Parque Industrial [E.P].	68
Tabla 4.11 Características de carga A/P de la S/E Norte [SIG EERSSA].	68
Tabla 4.12 Resultados de Métricas de Dispersión de Error de Pronóstico A/P DES/E Norte [E.P].	70
Tabla 4.13 Demanda Máximas Proyectadas S/E Norte [E.P].	74
Tabla 4.14 Resultados de cargabilidad, corriente máxima, pérdidas de potencia, y caídas de voltaje de la S/E Norte [E.P].	75

CAPÍTULO 1

1. INTRODUCCIÓN

1.1 Descripción del problema

Las empresas eléctricas encargadas de la distribución y comercialización de la energía eléctrica emplean la estimación de demanda a largo plazo como la base para la planificación de su sistema de potencia. La estimación de la demanda solventa las necesidades de consumo eléctrico de clientes residenciales, comerciales e industriales para un periodo de tiempo, y bajo criterios de confiabilidad y calidad de servicio [1].

El pico de demanda máxima se utiliza como el principal parámetro de estimación en alimentadores de distribución. La demanda máxima representa el peor escenario de operación del sistema, lo cual permite evaluar sus límites operativos tanto para condiciones normales, como para contingencias en un periodo de tiempo determinado [2].

La LTLF en alimentadores de distribución no solo tiene una alta implicación en la confiabilidad de la red futura, sino también con la satisfacción y calidad del producto entregado al cliente. Además, garantiza que la inversión realizada por la empresa distribuidora tenga resultados financieros positivos [3].

La Empresa Eléctrica Regional del Sur S.A actualmente dispone de 23 subestaciones, con 61 alimentadores de distribución con niveles de voltaje a 13.8kV y 22 kV, los cuales dotan de servicio de energía eléctrica a las provincias de Loja, Zamora Chinchipe y parte Morona Santiago. Actualmente, la empresa no dispone de ninguna metodología estructurada para la estimación de la demanda eléctrica a largo plazo en alimentadores distribución. Debido a lo cual, la planificación del SED se basa en tasas de crecimiento anual por cada alimentador, y se proyecta para un periodo de tiempo.

La actual metodología de pronóstico de demanda no realiza ningún preprocesamiento de la base datos extraída de las mediciones del Sistema de Gestión Avanzada de Distribución (ADMS). Además, no utiliza ninguna herramienta computacional basada en algoritmos matemáticos que faciliten el pronóstico de carga. Los resultados obtenidos no emplean ninguna métrica de pronóstico comparativa, que permita validar que dichos resultados estén dentro de una margen de error de estimación aceptable.

Con el fin de mejorar esta metodología se busca evitar que los transformadores de potencia de las subestaciones del área de servicio de la EERSSA en hora pico no lleguen a niveles de cargabilidad superiores al 80%; y que el Operador del Centro de Control disponga de mayor margen de tiempo para realizar maniobras de alivio de carga en condiciones de contingencia del SED. Así también, garantizar que los perfiles de voltaje en todos los alimentadores de distribución en cabecera y fin de circuito, cumplan con los límites establecidos por la regulación 005/18 del ARCONEL.

Adicionalmente, la actual previsión inadecuada de la demanda eléctrica ha ocasionado que cuando se requiere realizar mantenimientos programados o emergentes en las líneas de subtransmisión del anillo 69kV de la EERSSA, debido a la limitada capacidad de los transformadores de potencia, y límites térmicos de los conductores en alimentadores de distribución, se ejecuten planes de maniobras que modifican la topología de la red, y que comprometen la confiabilidad del suministro de energía eléctrica.

Por todo lo aquí expuesto, el presente proyecto de titulación busca contribuir a solventar los problemas técnicos y económicos ocasionados por una inadecuada metodología de LTLF del Sistema Eléctrico de la Empresa Eléctrica Regional del Sur S.A.

1.2 Justificación del problema

El presente proyecto de titulación busca implementar una adecuada metodología de LTLF para la EERSSA. Esta metodología será aplicable a cualquier empresa distribuidora, y permitirá evaluar de manera razonada las mejoras de infraestructura, y modificaciones que el SED requiere a largo plazo. Como, por ejemplo, transferencia de carga entre alimentadores distribución, construcción de nuevos alimentadores de distribución, construcción de nuevos puntos de mallado entre alimentadores, ampliación de la capacidad de instalación de sus centros de transformación, y la construcción de nuevas subestaciones, etc.

Además, a partir de la implementación de esta nueva metodología se busca proveer a la empresa distribuidora una herramienta que combine de manera efectiva la información

económica, demográfica y temperatura con la información histórica de carga de un alimentador de distribución obtenida del Sistema de Distribución Avanzada (ADMS).

De esta forma, con los resultados obtenidos de la metodología propuesta, se busca obtener una mejor precisión en la estimación de carga en comparación a la actual metodología aplicada, y se evite un sobredimensionamiento de la infraestructura del sistema de la EERSSA. Además, con la metodología propuesta se busca conseguir niveles adecuados de calidad de producto del servicio de energía eléctrica dentro del área de servicio.

1.3 Objetivos

1.3.1 Objetivo General

- Desarrollar una metodología de proyección de demanda eléctrica a largo plazo basada en un método híbrido para alimentadores de distribución.

1.3.2 Objetivos Específicos

- Implementar un método híbrido de estimación de demanda eléctrica que combine de manera eficiente información económica, demográfica, temperatura, e información histórica de carga de un alimentador de distribución en un solo modelo matemático.
- Aplicar un modelo de predicción que contribuya a la mejora de la precisión de los resultados del pronóstico de demanda.
- Utilizar un software de simulación que permita validar los resultados obtenidos de la proyección de demanda en un alimentador de distribución en referencia a pérdidas potencia, caídas de voltaje, límites térmicos, y nivel de cargabilidad del transformador de potencia.

1.4 Contribución

El presente trabajo de titulación propone una metodología de LTLF para lo cual se contribuyó de la siguiente manera:

- Se realizó la revisión del estado del arte en referencia a metodologías de estimación de carga a largo plazo en A/P, lo cual permitió determinar que el

método SARIMA y ARIMA son los métodos que mejor se adaptan y ajustan a la base de datos facilitada por la EERSSA.

- Se aplicó un preprocesamiento de la base de datos extraídas del ADMS, con el fin de eliminar comportamientos atípicos de la demanda eléctrica y que distorsionan la proyección para un determinado periodo de tiempo.
- Mediante la implementación del algoritmo GMM y el método del codo bajo el criterio AIC y BIC, se determinaron las curvas de demanda máxima de mayor probabilidad, y representatividad por cada año histórico de los A/P de la S/E Norte.
- A partir de las métricas de estimación de pronóstico (MAPE, RMSE, MSE, R2) de los resultados obtenidos de los métodos SARIMA y ARIMA, se determinó el modelo con mejor ajuste para realizar la proyección de demanda en un horizonte de 10 años para cada A/P de la S/E Norte.

CAPÍTULO 2

2. MARCO TEÓRICO

2.1 Planificación de la Expansión de los Sistemas Distribución

Para una eficiente operación y expansión del sistema eléctrico de distribución, la empresa distribuidora debe anticipar la cantidad de energía que requiere del sistema interconectado, y su vez la demanda de sus clientes para un escenario actual y futuro [4].

El planeamiento de los sistemas de distribución implica una gran cantidad de información obtenida de diferentes sistemas. La calidad y eficiencia del planeamiento dependerá del procesamiento y análisis de esta información [5]. De tal forma, que la estimación de la demanda a largo plazo se aborda como un fundamento esencial para garantizar un sistema adecuado y confiable.

La demanda máxima es generalmente usada como el principal objetivo de la estimación, debido a que representa el peor escenario, y pone a prueba al sistema a sus limitaciones operativas. La LTLF es la principal variable de entrada para determinar la cantidad de suministro de energía que requiere en operación normal, y la capacidad de restauración del sistema durante contingencias para los próximos años [6].

Después de una adecuada estimación y evaluación, las empresas distribuidoras de energía eléctrica pueden razonadamente planificar a largo plazo las mejoras y repotenciaciones de su infraestructura [6]. Como por ejemplo, transferencia de carga entre alimentadores, factibilidad de nuevos puntos de conexión en alimentadores, construcción de nuevos alimentadores, instalación de nuevos transformadores, y construcción de nuevas subestaciones, etc.

Por lo tanto, la LTLF afecta significativamente la confiabilidad de la red futura, la satisfacción de los clientes, la inversión de capital y resultados financieros de la empresa eléctrica distribuidora.

2.2 Clasificación de Técnicas de Pronóstico de Demanda

En los últimos años, existen muchos estudios relacionados a la metodología de estimación de la demanda. Estas clasificaciones se basan en la duración de la estimación y el método de estimación [7].

Los métodos para la estimación de la demanda también pueden ser clasificados de acuerdo al grado de análisis matemático aplicado al modelo de estimación. Estos métodos se presentan en dos tipos: cuantitativos y cualitativos [7].

En la mayoría de los casos la información histórica es insuficiente, y no se encuentra disponible en su totalidad. Debido a lo cual, los métodos cualitativos son generalmente utilizados para una estimación lo más precisa posible, entre estos métodos destacan los siguientes: método Delphi, ajuste curvas y comparaciones tecnológicas, etc. Por otro lado, métodos como análisis de regresión, suavizado exponencial, aproximación Box-Jenkins son métodos cuantitativos [7].

Para el presente trabajo se ha realizado la clasificación de las técnicas de estimación de demanda en tres grandes grupos: Técnicas de Pronóstico Tradicionales, Técnicas de Pronóstico Tradicionales Modificadas, y Técnicas de Computación Suave [7].

2.2.1 Técnicas de Estimación Tradicionales

En sus inicios la predicción de la demanda futura que se empleaba para planificar la infraestructura del sistema de eléctrico de potencia de un país, fue llevada a cabo mediante métodos matemáticos convencionales. Los mismos que a través del desarrollo de nuevas herramientas de cálculo permitieron una mejor precisión en sus resultados de estimación [7].

2.2.1.1 Regresión Lineal

La regresión lineal es uno de los métodos estadísticos más utilizados, y más fácil de implementar. Este método emplea un modelo que relaciones el consumo de carga con otros factores tales como: clima, tipo de días y tipo de cliente.

El modelo matemático puede ser escrito de la siguiente forma:

$$L(t) = Ln(t) + \sum a_i x_i(t) + e(t) \quad (2.1)$$

Donde:

$Ln(t)$ = Es la carga a lo largo del tiempo.

a_i = Coeficiente de variación lenta estimado.

$x_i(t)$ = Factores de influencia independientes.

$e(t)$ = Componente de ruido blanco.

2.2.1.2 Regresión Múltiple

La regresión múltiple es uno de los métodos más conocidos, y emplea la estimación de la carga bajo la consideración de algunos factores que van desde los meteorológicos, crecimiento per capital, precios de la electricidad, etc. Esta metodología emplea la técnica de estimación de cuadrados mínimos [7].

$$Y(t) = V_t a_t + e_t \quad (2.2)$$

Donde:

t = Es el tiempo de muestreo.

$Y(t)$ = Carga total medida del sistema.

V_t = Es el vector de variables adaptadas tales como tiempo, temperatura, viento, humedad, tipo de día, etc.

a_t = Vector transpuesto de los coeficientes de regresión.

e_t = Modelo de error en el tiempo t .

2.2.1.3 Suavizado Exponencial

El suavizado exponencial es una de las aproximaciones más usadas para la estimación de carga. En este método, la primera carga se modela en base a la información de carga previa, y luego emplea este modelo para predecir la carga futura [7].

$$y(t) = \beta(t)Tf(t) + e(t) \quad (2.3)$$

$y(t)$ = Es la carga a lo largo del tiempo.

$\beta(t)$ = Coeficiente del vector.

T = Operador de transposición

$f(t)$ = Vector de función de ajuste del proceso.

$e(t)$ = Ruido blanco.

2.2.2 Técnicas de Estimación Tradicionales Modificadas

Las técnicas de estimación tradicionales han sido modificadas de tal forma que, automáticamente corrijan los parámetros del modelo de estimación en condiciones variantes [7]. Algunas de las técnicas que han sido modificadas de su versión original son: estimación de carga adaptativa, series de tiempo estocásticas y máquina de vector de soporte.

2.2.2.1 Estimación de Demanda Adaptativa

En este método los parámetros del modelo de estimación de demanda son automáticamente corregidos para seguir la tendencia del cambio de carga [7]. Por esto, la estimación de la demanda tiene una naturaleza adaptativa y solo puede ser usada como un paquete de software en línea.

El vector de estado es calculado mediante el análisis de información histórica. En este método los cambios múltiples y regresiones adaptativas son posibles [7].

El modelo está expresado en la siguiente ecuación:

$$Y(t) = X_t a_t + e_t \quad (2.4)$$

$Y(t)$ = Carga total medida del sistema.

X_t = Vector de variables adaptadas tales como tiempo, temperatura, intensidad de luz, humedad, viento, etc.

a_t = Vector transpuesto de coeficientes regresivos.

e_t = Modelo de error al tiempo t .

2.2.2.2 Series de Tiempo Estocásticas

Los métodos de series de tiempo aparecen entre las aproximaciones más populares aplicadas a la estimación de demanda a corto plazo. Estos métodos son basados en que

la información tiene una estructura interna: autocorrelación, tendencia o variación estacional [7].

El enfoque de este método es ensamblar con precisión un patrón que coincida con la información disponible, y permita obtener un valor estimado con respecto al tiempo usando un modelo establecido.

Algunas de los modelos de series de tiempo más utilizados se detallan a continuación:

- **Modelo Autorregresivo (AR)**

Este método puede ser utilizado para modelar el perfil de carga siempre y cuando, la carga asumida tenga un comportamiento lineal a partir de los valores de carga previos.

El modelo esta dado por la siguiente ecuación:

$$L_k = \sum_{i=1}^m \alpha_{ik} L_{k-i} + e_k \quad (2.5)$$

Donde:

L_k = Carga futura en el tiempo k.

α_{ik} = Coeficientes desconocidos.

L_{k-i} = Carga previa en el tiempo k-i. $i=1 \dots m$.

e_k = Ruido blanco.

Los coeficientes desconocidos de la ecuación 2.5 pueden ser sintonizados mediante el algoritmo de los cuadrados mínimo medios (LMS) de Mbamalu y El-Hawary [8].

- **Promedio Móvil Autorregresivo (ARMA)**

Este método representa el valor actual de la serie de tiempo $y(t)$ expresada linealmente en función de los valores de periodos previos [$y(t-1)$, $y(t-2)$, ...] y de los valores previos de ruido [$a(t)$, $a(t-1)$, ...].

El modelo del ARMA de orden (p,q) está expresado de acuerdo a la siguiente ecuación:

$$y(t) = \phi_1 y(t-1) + \dots + \phi_p y(t-p) + a(t) - \phi_1 a(t-1) - \dots - \phi_q a(t-q) \quad (2.6)$$

El esquema recursivo es utilizado para identificar los parámetros con el fin de obtener la máxima probabilidad de estimación [7].

- **Promedio Móvil Integrado Autoregresivo (ARIMA)**

Para este método, si el proceso a ser estudiado corresponde a uno de tipo dinámico/no estacionario, el primer paso a realizar es la transformación de la serie a una de tipo estacionario. Esta transformación puede ser realizada mediante distintos métodos [7].

La incorporación del ∇ operador hace que la serie se exprese de la siguiente forma:

$$\nabla X(t) = (1 - B) X(t) \quad (2.6)$$

En donde la serie requiere ser d veces diferenciada, tiene un orden p y q para las componentes AR y MA.

El modelo ARIMA puede ser expresado de la siguiente forma:

$$\Phi(B)\nabla^d X(t) = \theta(B) * a(t) \quad (2.7)$$

- **Promedio Móvil Integrado Autorregresivo Estacional (SARIMA)**

El SARIMA es un método para el modelado de series de tiempo univariantes con fuertes patrones estacionarios; es una extensión del modelo ARIMA, y el cual es una generalización del modelo ARMA [9].

Por esto, antes de presentar los conceptos del modelo SARIMA empezamos con el modelo ARMA. El orden del modelo ARMA (p, q) describe cualquier serie estacionaria de tiempo como la suma de diferentes polinomios: el orden p del polinomio AR está expresada en la Ec. 2.8, y el orden q del polinomio MA está expresado en la Ec. 2.9 [9].

$$y(t) = c + \epsilon_t + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} \quad (2.8)$$

$$y(t) = c + \epsilon_t + \theta_1 y_{t-1} + \theta_2 y_{t-2} + \dots + \theta_q y_{t-q} \quad (2.9)$$

Donde:

c = Es una constante independiente.

ϵ_t = Es el ruido blanco de la muestra.

$y(t)$ = Es el valor de la serie de tiempo en tiempo t .

ϕ y θ = Son parámetros del modelo ARMA

El orden (p,d,q) del modelo ARIMA está dado por la Ec. 2.10 [9]:

$$y'(t) = c + \epsilon_t + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \theta_1 y_{t-1} + \theta_2 y_{t-2} + \dots + \theta_q y_{t-q} \quad (2.10)$$

Donde:

$$y'(t) = y(t) - y(t - 1) \quad (2.11)$$

La Ec. 2.11 también puede ser expresada de la siguiente manera:

$$y'(t) = y(t) - B^1(y(t)) \quad (2.12)$$

Donde:

B^1 = Es el operador de cambio regresivo de orden 1.

El orden (p,d,q) x (P,D,Q) del modelo SARIMA puede ser expresado por las siguientes ecuaciones [9]:

$$\phi_p(B)\phi_P(B^L)y(t) = \theta_q(B)\vartheta_Q(B^L)\epsilon_t \quad (2.13)$$

Donde L es el periodo estacionario y,

$$\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p \quad (2.14)$$

$$\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q \quad (2.15)$$

$$\phi_P(B^L) = 1 - \phi_{1L} B^L - \dots - \phi_{PL} B^{PL} \quad (2.16)$$

$$\vartheta_Q(B^L) = 1 - \vartheta_{1L} B^L - \dots - \vartheta_{QL} B^{QL} \quad (2.17)$$

Donde:

ϕ, θ, ϑ = Son parámetros del modelo SARIMA

2.2.2.3 Vector Máquina de Apoyo

El vector máquina de apoyo es un poderoso método de machine learning basado en la teoría de aprendizaje estadístico, el cual analiza información y reconoce patrones usado para la clasificación y regresión. Esto combina el control generalizado con una técnica que direcciona la dimensionalidad [7].

2.2.3 Técnicas de Computación Suaves

Es un hecho que los sistemas eléctricos de distribución son penetrantemente imprecisos, inciertos, y difíciles de modelar de manera exacta. Las técnicas de computación suave buscan modelar que dicho sistema de manera precisa, y eficiente dentro de un escenario objetivo.

Las técnicas de computación suave destacan la importancia de la habilidad de la mente humana para aprender y adaptarse en ambientes inciertos e imprecisos. Este método, es empleado como herramienta para ayudar a sistemas basados en inteligencia informática a imitar el razonamiento de la mente humana de la forma más aproximada.

Este método se caracteriza por su alta precisión, y certeza en sus estimaciones, lo cual tiene un elevado costo que se refleja el procesamiento de datos, pero a pesar de esto en sistemas inteligentes debe ser implementado.

2.2.3.1 Algoritmos Genéticos (GA)

Este método también es conocido como programación evolutiva, cuyo enfoque es identificar el promedio móvil autorregresivo con variables sistémicas para el modelado de la estimación de la demanda [7].

El algoritmo utiliza un proceso natural evolutivo que permite que la capacidad de converger se direcciona hacia el extremo global de una superficie de error compleja. Esto es una técnica de búsqueda global, que simula el proceso natural evolutivo, y constituye un algoritmo de optimización estocástica [7].

Los algoritmos genéticos evalúan simultáneamente varios puntos en un espacio de búsqueda, y no necesitan asumir si el espacio de búsqueda es diferenciables o unimodal. Los GA's son capaces de converger asintóticamente hacia una solución global de solución y de esta forma obtener una precisión de ajuste en el modelo [7].

De acuerdo a **Yang** modelo del sistema de carga puede ser descrito de la siguiente con la siguiente expresión:

$$A(q) * y(t) = B(q) * u(t) + C(q) * e(t) \quad (2.18)$$

Donde:

$y(t)$ = Es la carga en el tiempo t.

$u(t)$ = Entrada de temperatura exógeno en el tiempo t.

$e(t)$ = Ruido blanco en el tiempo t.

$A(q)$ = Parámetro de la parte autorregresiva (AR).

$B(q)$ = Parámetro de la parte exógena.

$C(q)$ = Parámetro del promedio móvil (MA).

2.2.3.2 Lógica Difusa

Se conoce que un sistema lógico difuso con un centroide de defuzificación puede identificar, y aproximar cualquier sistema dinámico desconocido [7].

Liu [10] indica que un sistema de lógica difusa tiene una gran capacidad para establecer similitudes en una extensa base de información. Las similitudes en la información de entrada (L-i L-o) puede ser identificadas por variadas diferencias de primer orden (V_k) y segundo orden (A_k), que se puede expresar de la siguiente forma:

$$V_k = \frac{L_k - L_{k-1}}{T} \quad (2.19)$$

$$A_k = \frac{V_k - V_{k-1}}{T} \quad (2.20)$$

La estimación basada en lógica difusa trabaja en dos etapas: una de entrenamiento y otra de pronóstico en línea. En la etapa de entrenamiento, los registros históricos son

usados para entrenar dos variables de entrada, y dos variables de salida; basadas en lógica difusa de pronóstico que permiten generar patrones de la base de datos.

Para la segunda etapa, los resultados del entrenamiento son vinculados con un controlador que prediga el cambio de carga en línea [10].

2.2.3.3 Redes Neuronales

Las redes neuronales (NN) o redes artificiales neuronales (ANN) debido a su habilidad para aprender tiene un gran campo de aplicación. De acuerdo a Damborg [11], las redes neuronales ofrecen un gran potencial para superar la dependencia sobre la forma funcional del modelo de estimación. Existe muchos tipos de redes neuronales: multicapa, unicapas, redes auto-organizadas, etc.

En una red neuronal existen muchas capas ocultas, en donde cada capa está formada por varias neuronas. Las variables de entrada son multiplicadas de acuerdo a sus pesos y son agregadas a un umbral para formar un producto interno denominada la función red [11].

La principal ventaja de este método de estimación es que en la mayoría de los casos no se requiere un modelo de carga. Sin embargo, el entrenamiento de la red neuronal puede llegar a tomar mucho tiempo [7].

2.3 Métricas de dispersión del error del pronóstico

2.3.1 Error porcentual absoluto medio (MAPE)

El error porcentual absoluto medio es utilizado ampliamente como una medida de rendimiento para las estimaciones. La razón principal de su popularidad se debe a su fácil interpretación y comprensión [12].

El error porcentual absoluto medio se calcula usando el error absoluto en cada periodo dividido por los valores observados para cada periodo, y luego se promedia los porcentajes fijos. Esta aproximación es útil cuando el tamaño de la variable es significativo para evaluar la precisión. El MAPE indica el error que existen en los resultados de la predicción en comparación con los valores reales [13].

Y se lo calcula de acuerdo a la siguiente expresión:

$$MAPE = 100\% * \frac{1}{n} \sum_{t=1}^n |A_t - P_t / A_t| \quad (2.21)$$

A_t = Valores reales de la muestra.

P_t = Resultados de la predicción.

2.3.2 Error de raíz cuadrada media (RMSE)

El error de raíz de cuadrada media es utilizado como métrica estadística estándar para medir el rendimiento de modelos de estimación en distintas de áreas de la ingeniería. En esta métrica a partir de n muestras de errores del modelo se calcula como ($e_i, i = 1, 2, \dots, n$) [14].

Las incertidumbres debidas a los errores de observación o del modelo empleado para comparar el modelo, y las observaciones no se consideran en esta métrica. Además, se asume que el conjunto muestra de error es imparcial [14].

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (2.22)$$

2.3.3 Error cuadrático medio (MSE)

El error cuadrático medio es una medida de dispersión del error de pronóstico, esta medida maximiza el error al elevar al cuadrado. Esto implica que en los periodos donde exista mayor diferencia entre los valores reales y pronosticados, el error cuadrático será más altoz [15].

Se recomienda la aplicación del error cuadrático medio en casos donde las desviaciones sean pequeñas. El MSE puede ser calculado con la siguiente fórmula:

$$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2 \quad (2.23)$$

2.3.4 Coeficiente de determinación (R^2)

El coeficiente de determinación puede ser interpretado como la proporción de la varianza de la variable independiente que es predecible a partir de las variables independientes [16].

El coeficiente de determinación puede ser calculado con la siguiente expresión:

$$R^2 = 1 - \frac{\sum_{i=1}^m (X_i - Y_i)^2}{\sum_{i=1}^m (\bar{Y} - Y_i)^2} \quad (2.24)$$

2.4 Estimadores de calidad del modelo estadístico

Para seleccionar el orden de un modelo autorregresivo ajustado a datos de series de tiempo, se requiere emplear un criterio de selección. El criterio de Akaike y el criterio Bayesiano son los más utilizados y de mejor rendimiento. Cuando se generan muestras a partir de una autorregresión de orden finito, el criterio de información bayesiano es más consistente. Mientras que cuando la dimensión de la muestra es de orden finito o considerablemente alto el criterio de Akaike presenta mejores resultados [17].

2.4.1 Criterio de Información Akaike (AIC)

Este criterio de información fue propuesto por el estadístico Japonés H. Akaike cuando estudiaba la teoría de información, específicamente la determinación del orden de las series de tiempo. El criterio de Akaike es basado en el concepto de entropía, el cual es usado para medir la complejidad del modelo estimado y la superioridad del modelo de ajuste [18].

El AIC puede ser expresado de la siguiente forma [18]:

$$AIC = 2k - 2\ln(L) \quad (2.25)$$

Donde:

k = Es el número de parámetros

L = Es la probabilidad de la función

Este criterio prioriza la superioridad del ajuste de datos y evitar el sobreajuste. Por esto el modelo preferido es aquel que presenta el valor mínimo de AIC.

En caso de no existir suficientes muestras, el AIC es sustituido por AICc.

$$AICc = AIC + \frac{2k(k+1)}{n-k-1} \quad (2.26)$$

El AICc converge al AIC con el incremento de n, por esto el AIC puede ser utilizado sin considerar el número de muestras.

2.4.2 Criterio de Información Bayesiano (BIC)

Este criterio de información fue propuesto por G. Schwarz, en donde la selección del orden de modelo es analizada desde el punto de vista Bayesiano. En este criterio, se asume que a cada modelo se le puede asignar una probabilidad previa, para posteriormente seleccionar el modelo con la máxima probabilidad posterior [19].

El criterio de información Bayesiano puede ser expresado de la siguiente forma [19]:

$$\hat{q} = \arg \min\{BIC(k) = -2\log f(X|\hat{\vartheta}^{(k)}) + n_k \log N\} \quad (2.27)$$

Donde:

$X = \{x_1, \dots, x_n\}$ son las observaciones de la muestra, y el correspondiente parámetro desconocido del vector $\hat{\vartheta}^{(k)}$ con tamaño k. Y n_k es el número de parámetros ajustables libres.

CAPÍTULO 3

3. PROPUESTA DE ESTIMACIÓN DE DEMANDA A LARGO PLAZO

3.1 Introducción

Para el presente trabajo de titulación se propone desarrollar una metodología de estimación de demanda para alimentadores de distribución para un periodo de 10 años. La presente metodología se dividirá en tres etapas: la primera parte se realizará un proceso de normalización que consiste en la depuración de las curvas de demanda anuales de los registros históricos obtenidos del Sistema ADMS. Este procedimiento se realizará para eliminar el ruido debido a fallas transitorias o permanentes, transferencias de carga o mallados con otros alimentadores de distribución, así también como valores incoherentes causados por pérdidas de comunicación o mal reporte del Sistema SCADA.

Para la segunda parte se aplica el algoritmo del modelo mixto Guassiano (GMM), con el fin de obtener la función de densidad de probabilidad de los A/P de la S/E Norte, y con esto determinar el escenario de mayor representación de demanda máxima para cada año histórico. Para la obtención de los parámetros del GMM se propone emplear el algoritmo de maximización de expectativas.

Para la tercera parte con los resultados obtenidos del algoritmo GMM se procede a aplicar los métodos ARIMA y SARIMA, y mediante métricas de estimación se determina el modelo con mejor ajuste de pronóstico, y se proyecta la demanda eléctrica en un horizonte de 10 años. En el caso, de que un alimentador prevea la incorporación de cargas industriales o especiales, se deberá analizar en conjunto con el crecimiento vegetativo.

Finalmente, con los valores obtenidos de la proyección de demanda mediante un software de simulación se calcularán las pérdidas de potencia, caídas de voltaje, límites térmicos y cargabilidad del transformador de potencia.

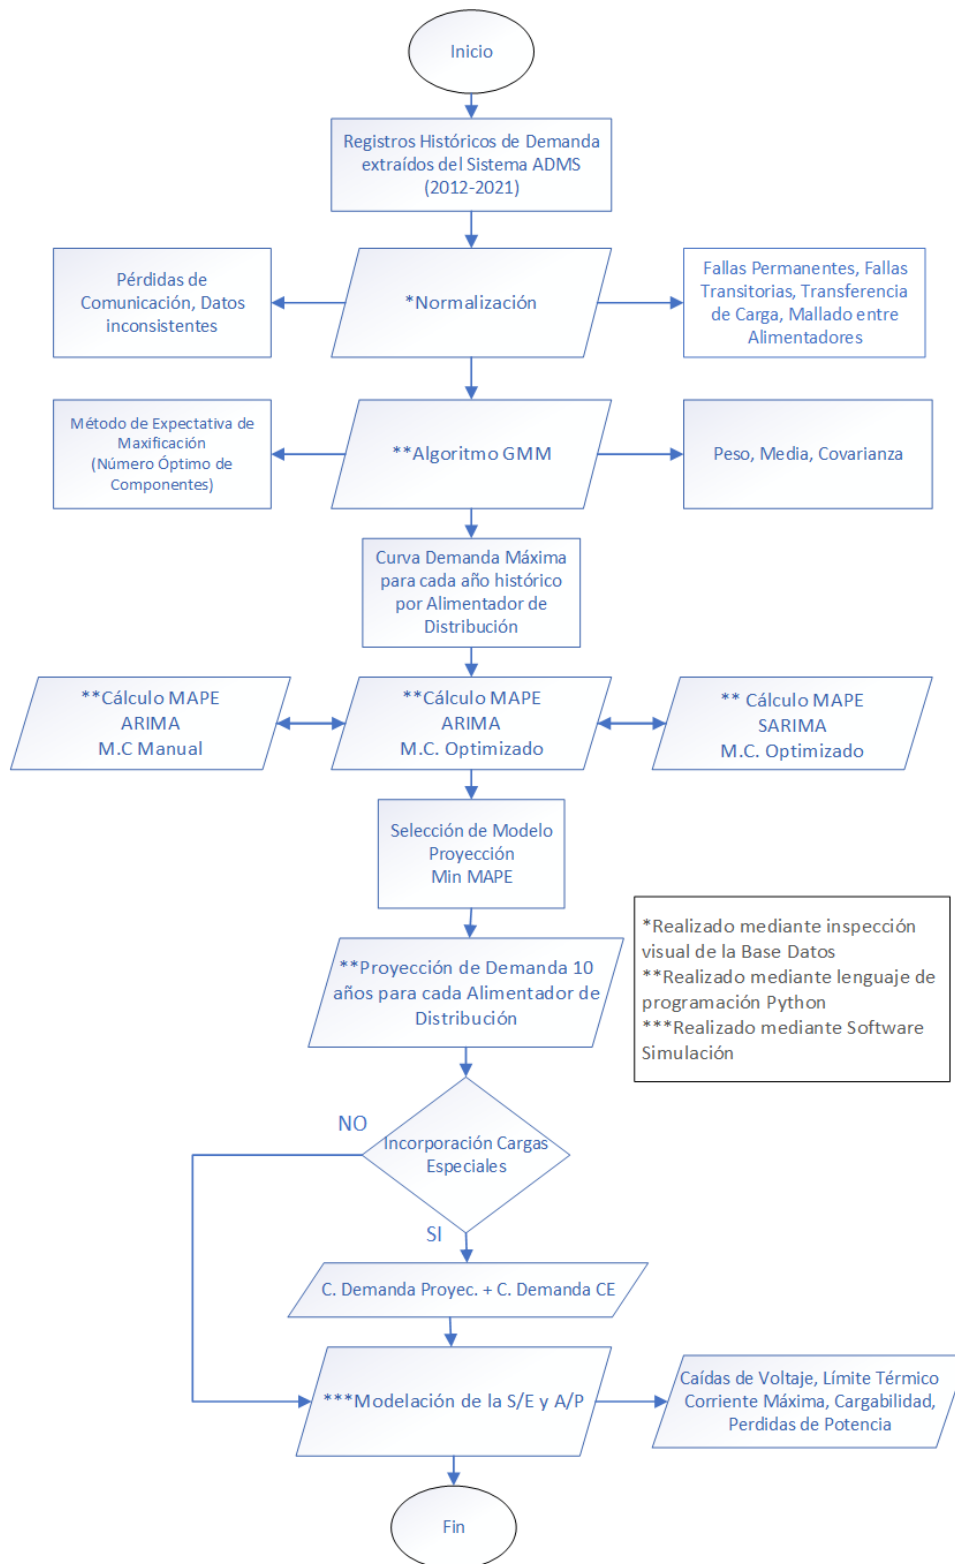


Figura 3.1 Diagrama de flujo de propuesta metodológica de LTLF [E.P].

3.2 Normalización de la Base de Datos

3.2.1 Procedimiento de Normalización

En la práctica, el ruido de datos afecta principalmente al valor pico de la demanda máxima de un alimentador de distribución. En un periodo de largo plazo, este ruido se debe a eventos de transferencia de carga entre alimentadores adyacentes o fallas transitorias. Las transferencias de carga parciales debido a mantenimientos preventivos o correctivos, ocasionan un comportamiento atípico en la curva de demanda, pero que responde a una necesidad operativa del sistema para evitar los cortes del suministro de energía eléctrica.

Por ejemplo, cuando los valores de corriente de un alimentador de distribución denominado "A" están cerca de sus valores límite, el operador del centro de control ejecuta una maniobra de transferencia de carga parcial de ciertos ramales del alimentador "A" al "B" con el fin de mantener la confiabilidad del sistema [6].

Esta transferencia de carga produce una caída de potencia en el alimentador "A" mientras que en el alimentador "B" se produce un incremento, esto ocasiona una desviación en la tendencia de demanda de ambos alimentadores.

Otro ejemplo, es cuando se realiza el cambio o reparación del interruptor de potencia en cabecera del alimentador, lo que conlleva a la transferencia total de su carga hacia uno o varios alimentadores de distribución debido a restricciones operativas.

En la fig.1 podemos observar como la transferencia de carga entre alimentadores de distribución adyacentes se puede realizar mediante reconectores "Branch switch" y seccionadores tipo barra "tie-points".

La transferencia de carga es un evento casi inevitable en un SED, y que a lo largo de los años afecta a los alimentadores de distribución. De tal forma, que este tipo de eventos produce ruido lo cual reduce significativamente la precisión de los datos si no se depuran previamente.

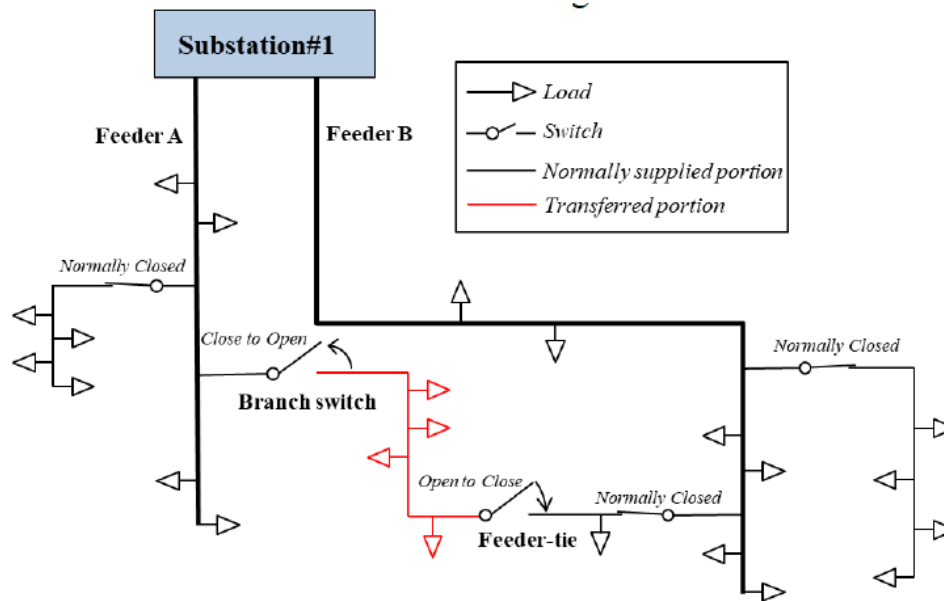


Figura 3.2 Ejemplo de transferencia de carga de un A/P A hacia B [6].

Para solventar este problema, el presente trabajo se propone realizar un análisis de las curvas de demanda anuales históricas, con el fin de eliminar registros históricos que no correspondan a un comportamiento típico de los alimentadores de distribución de la S/E Norte; principalmente los que correspondan a mallados o transferencia de carga entre alimentadores adyacentes, pérdidas de comunicación del relé en cabecera o de la RTU de la subestación, mal de reporte de datos al SCADA, y fallas de transitorias o permanentes. Este procedimiento se realiza mediante inspección visual basada en la experiencia del Operador del Centro de Control y los criterios de normalización detallados a continuación:

3.2.2 Criterios de Normalización

Para el procedimiento de normalización los registros históricos se realizarán considerando lo siguiente:

- **Falla Permanentes:**

Para los registros que correspondan a fallas permanentes de tipo monofásicas se validará que la potencia activa trifásica sufra una disminución, y se contrastará que el valor de corriente de la fase afectada llegue a valores cercanos a cero o cero.

- **Fallas Transitorias:**

Para los registros que corresponda a fallas transitorias debido a cortocircuitos por contacto de las redes eléctricas de medio voltaje con vegetación o animales, se considerará que existe un incremento de potencia activa superior al 15% del valor típico que generalmente se tiene en ese rango de tiempo, y que sus valores de corriente para cualquier de las fases sufra un incremento superior al 25% o alcance la corriente de arranque del relé del alimentador de distribución.

- **Pérdidas de Comunicación o mal reporte de datos del SCADA**

Debido a pérdidas del canal de comunicación primario del relé del alimentador, pueden existir registros incompletos en las mediciones que deberán ser descartados y únicamente considerar aquellos que sean de al menos un día completo.

- **Transferencia de carga entre alimentadores adyacentes**

Para los registros que corresponda a transferencias de carga entre alimentadores adyacentes, se verificará que exista una correspondencia entre los valores de corrientes y potencia de los alimentadores implicados, ya sea de dos o varios de la misma subestación. Previo al descarte de una falla permanente, y que dicha maniobra ejecutada corresponda al respaldo de la carga desconectada.

- **Mallado entre alimentadores adyacentes**

Para considerar que los registros corresponden a maniobras de mallado entre alimentadores adyacentes, se verificará que exista un cambio en el comportamiento de los flujos de potencias, o se visualicen valores de potencia activa o corrientes son signo negativo.

3.3 Modelo Gaussiano Mixture

3.3.1 Modelamiento Matemático

Una función de densidad de probabilidad gaussiana mixta es una suma finita ponderada de funciones de probabilidad gaussianas. Esta función se caracteriza por el número de componentes de la mezcla, peso, medias y varianza [20].




Figura 3.3 Aproximación de mezcla gaussiana de densidad [20].

Para el modelo de mezcla gaussiano se debe considerar lo siguiente: la función de probabilidad no debe ser negativa, y la integral de la función de probabilidad sobre el espacio de muestreo de cuantificación aleatoria que representa debe evaluarse a la unidad [20]. Los pesos de la mezcla deben ser no negativos, y la suma de todos los pesos debe ser iguala a uno.

Para casos multivariados, la función de probabilidad GMM puede ser expresada con la siguiente ecuación:

$$f(z|\gamma) = \sum_{i=1}^{M_c} w_i f(z|u_i, \Sigma_i) \quad (3.1)$$

En donde:

M_c = Número de la mezcla de componentes.

w_i = Peso de la componente i_{th} . Siempre y cuando se cumpla lo siguiente:

$$\sum_{i=1}^{M_c} w_i = 1 \text{ y } w_i = 1$$

γ = Se selecciona a partir del conjunto de parámetros $\Gamma = \{\gamma: \gamma = \{w_i, u_i, \Sigma_i\}_{i=1}^{M_c}\}$

Dada una variable aleatoria z de dimensión d , con una media μ_i y una covarianza Σ_i , la función de densidad de mezcla de cada componente $f(z|u_i, \Sigma_i)$ es una distribución normal dada por la expresión [20]:

$$f(z|u_i, \Sigma_i) = N(u_i, \Sigma_i)(z) \quad (3.2)$$

$$= \frac{1}{(2\pi)^{d/2} \det(\Sigma_i)^{0.5}} e^{-0.5(z-u_i)^T \Sigma_i^{-1} (z-u_i)} \quad (3.3)$$

3.3.2 Mezcla de dos Componentes Gaussianas

Teniendo en cuenta que la función de densidad de probabilidad está dada por la suma de pesos de dos FPD normalmente distribuidas. La función de probabilidad resultante se la puede expresar de la siguiente forma [20]:

$$f(z|\mu_1, \mu_2, \sigma_1^2, \sigma_2^2) = w_1 N(\mu_1, \sigma_1^2) + w_2 N(\mu_2, \sigma_2^2) \quad (3.4)$$

$$= \frac{w_1}{\sqrt{2\pi\sigma_1^2}} e^{-\frac{(z-\mu_1)^2}{2\sigma_1^2}} + \frac{w_2}{\sqrt{2\pi\sigma_2^2}} e^{-\frac{(z-\mu_2)^2}{2\sigma_2^2}} \quad (3.5)$$

Integrando la parte izquierda y derecha de la Ec. 3.5 sobre el espacio de muestreo de la variable $z \in (-\infty + \infty)$

$$\int_{-\infty}^{\infty} f(z|\mu_1, \mu_2, \sigma_1^2, \sigma_2^2) dz = w_1 \int_{-\infty}^{\infty} \frac{e^{-\frac{(z-\mu_1)^2}{2\sigma_1^2}}}{\sqrt{2\pi\sigma_1^2}} dz + w_2 \int_{-\infty}^{\infty} \frac{e^{-\frac{(z-\mu_2)^2}{2\sigma_2^2}}}{\sqrt{2\pi\sigma_2^2}} dz \quad (3.6)$$

Dado que la integral de cualquier FDP de todo el espacio muestral es una probabilidad igual a 1, los términos de la izquierda y derecha de la Ec. 3.6 son evaluados a la unidad.

$$w_1 + w_2 = 1 \quad (3.7)$$

La Ec. 3.7 demuestra que la densidad resultante es la combinación convexa de dos densidades gaussianas. Para comprobar esto se requiere saber los parámetros $\{w_1, \mu_1, \mu_2, \sigma_1^2, \sigma_2^2\}$, para lo cual el algoritmo EM es una eficiente herramienta para obtenerlos [20].

3.3.3 Estimación de Parámetros mediante el algoritmo de maximización de expectativas (EM)

El algoritmo EM empleado para obtener los parámetros de la GMM es construido a partir del muestreo de una distribución dada, el cual ha sido adoptado por varias aplicaciones como clustering, y reconocimiento de patrones [20].

Para el modelado del perfil de carga de un alimentador de distribución el algoritmo EM se utiliza para obtener Y en las condiciones que $f(z|\gamma)$ puede ser considerado como una

distribución marginal de una distribución conjunta $f(z, y|\gamma)$, y además disponer de una variable auxiliar y [20]. Expresado con la siguiente ecuación:

$$f(z|\gamma) = \int f(z, y|Y)dy \quad (3.8)$$

La variable Z representa el conjunto de muestras de datos distribuidos independientemente e idénticamente $Z = \{z_1, z_2, \dots, z_n\}$, y la variable $y = \{y_1, y_2, \dots, y_n\}$ representa a las variables aleatorias escondidas tal que $y_i \in Y = \{y: y = \{1, 2, \dots, M_c\}\}$ [20]. En términos más sencillos y_i se refiere a la mezcla de componentes a través de la cual una observación z_i viene dada.

El algoritmo EM empleado para el presente trabajo se detalla a continuación:

$$Q(\gamma, \gamma^s) = E[\ln (f(Z, Y|\gamma)|Z, \gamma^s)] \quad (3.9)$$

En donde:

γ^s = Son las estimaciones de los parámetros actuales para evaluar la expectativa.

γ = Son los nuevos parámetros utilizados para optimizar Q.

El algoritmo recursivo EM genera una secuencia de parámetros $\gamma^s = \{w_j^s, \mu_j^s, \Sigma_j^s\}_{j=1}^{M_c}$, $s = 1, 2, \dots$, los cuales en condiciones factibles convergen para maximizar $Q(\gamma, \gamma^s)$ $\gamma \in \Gamma$. Para el primer paso de recursividad para γ^{s+1} dado γ^s se tiene lo siguiente [20]:

$$w_j^{s+1} = \frac{1}{N} \sum_{i=1}^N f(j|z_i, \gamma^s) \quad (3.10)$$

$$\mu_j^{s+1} = \frac{\sum_{i=1}^N z_i f(j|z_i, \gamma^s)}{\sum_{i=1}^N f(j|z_i, \gamma^s)} \quad (3.11)$$

$$\Sigma_j^{s+1} = \frac{\sum_{i=1}^N f(j|z_i, \gamma^s) (z_i - \mu_j^{s+1})(z_i - \mu_j^{s+1})^T}{\sum_{i=1}^N f(j|z_i, \gamma^s)} \quad (3.12)$$

3.4 Técnica Pronóstico-Adoptada

Para determinar el correcto modelo de estimación de la demanda eléctrica se han considerado cuatro etapas: prueba estacionaria, identificación del modelo, ajuste del modelo y evaluación de desempeño [21].

Para el modelo se empleó la demanda eléctrica histórica del periodo 2012-2021 de los alimentadores de distribución de la Subestación Norte (Parque Industrial, Chuquiribamba, Motupe y Carigán), extraídos del Sistema ADMS de la Empresa Eléctrica Regional.

Para la aplicación de los modelos SARIMA Y ARIMA se han utilizado las curvas de demanda históricas producto de la aplicación del algoritmo GMM y la normalización de la base de datos detalladas en los pasos 3.2 y 3.3.

3.4.1 Prueba de Estacionalidad

En el presente trabajo el grado de diferenciación de la base de datos se lo determina usando ACF y PACF seguida de la prueba Dick-Fuller (ADF) para esto se ha utilizado la librería `statsmodels.tsa.stattools` y `statsmodels.graphics.tsaplots` en el lenguaje de programación Python, para luego realizar la importación de las herramientas `adfuller` y `plot_acf`, `plot_pacf` respectivamente.

Esto se aplica a la serie original, la cual debe presentar un indicador $p < 0.05$, en caso de no ser así, se procederá a realizar otro proceso de diferenciación hasta que el indicador p cumple el requerimiento establecido.

Para el proceso de diferenciación se utilizará la librería `statsmodels.tsa.seasonal` con su herramienta `seasonal_decompose`.

3.4.2 Identificación de Modelo

La identificación del modelo corresponde a la determinación de los parámetros $p(P)$ y $q(Q)$ para los métodos ARIMA y SARIMA. A partir de la revisión del estado del arte se comprobó que existen muchas técnicas, pero para el presente trabajo de titulación los parámetros del modelo han sido determinados usando las gráficas de la Función de Autocorrelación (ACF) y la Función Parcial de Autocorrelación (PACF).

En esta etapa se selecciona un modelo en donde sus ACF y PACF tenga similitud y concordancia con los ACF y PACF obtenidos con la base de datos, y de acuerdo con los criterios de la Tabla 3.1.

Tabla 3.1 Característica Teóricas para la ACF y PACF para Procesos Estacionarios [22].

Proceso	ACF	PACF
AR	Colas de (Desintegración exponencial o seno amortiguado)	Cortes (después del retraso de p)
MA	Cortes (después del retraso de q)	Colas de (Desintegración exponencial o seno amortiguado)
ARMA	Colas fuera de rango	Colas fuera de rango

En la estimación del modelo se obtiene los parámetros del modelo ARIMA que tentativamente fueron escogidos en la de identificación del modelo. En la revisión y diagnóstico se realiza pruebas de desempeño para verificar, si el modelo estimado es estadísticamente adecuado. El modelo que no supere las pruebas mencionadas deberá ser descartado. Además, estos resultados sirven para validar que el modelo no está en la capacidad de ser implementado, lo cual provoca que se tenga que nuevamente regresar a la etapa de identificación. Este procedimiento se repite cíclicamente partiendo de la identificación, estimación y diagnóstico hasta encontrar un modelo final óptimo [22].

- **Funciones de Autocorrelación y Funciones de Autocorrelación Parcial**

Una vez graficada la serie tiempo, la herramienta estadística del ACF es utilizada para describir la relación entre varios valores de la serie de tiempo (Y_1, Y_2, \dots, Y_t) . La autocorrelación con retraso de un periodo de tiempo k es la correlación entre \bar{Y} y Y_{t-k} , sus valores se encuentran entre +1 y -1 (El valor de -1 significa una correlación perfectamente negativa y el +1 significa una correlación perfectamente positiva) [22].

Si $r_k = 0$, Y_t y Y_{t-k} no están correlacionados, esto se puede expresar de la siguiente forma:

$$r_k = \frac{\sum_{t=k+1}^n (Y_t - \bar{Y})(Y_{t-1} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2} \quad (3.13)$$

En donde:

$$\bar{Y} = \frac{1}{n} \sum_{t=1}^n Y_t \text{ en donde } \bar{Y} \text{ es el promedio de la base datos.}$$

En conjunto las correlaciones de los desfases 1,2,3...; constituyen la función de autocorrelación ACF.

Las Autocorrelaciones Parciales son utilizadas para medir el grado de asociación entre \bar{Y} y Y_{t-k} , cuando el efecto de otros retrasos de tiempo (1,2,3,...,k-1) son descartados [22].

- **Identificación de Modelo Óptimo [21] [23]**

La identificación del mejor modelo posible también se lo puede realizar con la ayuda del criterio de información Akaike (AIC) y el criterio de Información Bayesiano (BIC). El orden del modelo es determinado de acuerdo con lo indicado en la tabla 3.2. El modelo que presente el menor valor de AIC será seleccionado como el mejor.

Tabla 3.2 Criterio para el Orden del Modelo ARMA [21].

ACF	PACF	Modelo
Disminuye gradualmente	Desaparece después del retraso de p	AR(p)
Desaparece después del retraso de q	Disminuye gradualmente	MA(q)
Disminuye gradualmente	Disminuye gradualmente	ARMA(p,q)

Este procedimiento se realizará con ayuda de la librería pmdarima y la herramienta auto_arima del lenguaje de programación Python. En donde se evaluarán varios modelos que variarán p y q desde valores 1 hasta 3 para el cálculo del menor AIC.

La fundamentación matemática realizada mediante programación se detalla a continuación:

$$AIC = 2n + T \ln(f_{RSS}/T) \quad (3.14)$$

Donde:

n = Es el número de parámetros del modelo.

T = Es la longitud de la serie

f_{RSS} = Es la suma residual de las diferencias cuadráticas la cual indica la precisión del modelado.

El modelo con el valor de AIC más pequeño es el óptimo, de tal forma que la descripción matemática para el seleccionar el modelo ARIMA $S_{i,t}$ esta dada de la siguiente manera:

$$\min AIC = 2n + T \ln(f_{RSS}^2/T) \quad (3.15)$$

$$\text{s.t.} \left\{ \begin{array}{l} n = p + q \\ p = 0,1,2, q = 0, 1 \\ q \leq p \\ f_{RSS} = \sqrt{\sum_{t=1}^T (S_{i,t} - S_{i,t}^*)^2} \end{array} \right. \quad (3.16)$$

Donde:

$S_{i,t}^*$ = Es el valor de ajuste ARIMA (p,d,q) de $S_{i,t}$.

3.4.3 Ajuste de Modelo

En este procedimiento se selecciona el modelo con mejor rendimiento y ajuste tanto para la técnica ARIMA como SARIMA. En donde se divide el número total de muestras en un 75% para datos de entrenamiento y el otro 25% para datos de prueba [21].

Los modelos seleccionados son entrenados usando los datos de entrenamiento, y se estiman los parámetros para cada modelo. Luego se emplea la prueba Ljung-Box para verificar la correlación residual.

Para realizar la prueba Ljung-Box se emplea la librería statsmodels.api del lenguaje de programación Python.

Además, para realizar la validación cruzada se emplea las librerías `statsmodels.tsa.stattools` y `statsmodels.tsa.arima_model` del lenguaje de programación Python.

3.4.4 Evaluación de Desempeño

Para la evaluación del modelo se utiliza métricas de precisión como el error medio cuadrático (MSE), error de raíz cuadrática media (RMSE) el coeficiente de correlación (R²), y el error cuadrático porcentual medio (MAPE). El modelo que presente el menor MAPE se considerará como el más prometedor, y será empleado para realizar el pronóstico de demanda eléctrica en el alimentador de distribución para un periodo de 10 años.

Para el cálculo de las métricas de pronóstico del modelo final se utilizará la herramienta `metrics` de la librería `sklearn` del lenguaje de programación Python.

3.5 Modelación y Simulación

Una vez obtenidas las curvas de demanda anuales proyectadas hasta el 2031 para cada alimentador de la S/E Norte de acuerdo al procedimiento 3.4, se procede a determinar sus valores de demanda máxima. Con esta información, se modelan los A/P como una carga de tipo trifásico concentrada balanceada. Y mediante los datos facilitados por el Empresa Eléctrica Regional se proceda modelar el transformador de potencia de la S/E Norte.

El esquema de simulación utilizado corresponde a un sistema conectado a una barra infinita. La barra infinita estará conectada al devanado primario del transformador de potencia de la S/E Norte, y la carga trifásica balanceada se conectará al devanado secundario del transformador de potencia.

El presente esquema de modelación se consideró el más adecuado, ya que los resultados de la demanda eléctrica estimada hasta el 2031 desean ser evaluados en la barra a 13.8kV, y transformador de potencia de la S/E Norte. Los resultados aguas arriba de la barra de 69kV de la S/E Norte no son de interés en el presente trabajo de titulación.

Los resultados esperados de la presente simulación son los siguientes:

- Caída de voltaje en la barra a 13.8kV de la S/E Norte por cada año proyectado.
- Perdidas de potencia activa del transformador de potencia de la S/E Norte por cada año proyectado.
- Valores de corriente máxima por cada año proyectado de los alimentadores de distribución (Parque Industrial, Motupe, Chuquiribamba y Carigán).
- Cargabilidad del transformador de potencia de la S/E Norte hasta el año 2031.

Previo a realizar las simulaciones respectivas por cada año proyectado, el modelamiento fue validado con valores reales extraídos del Sistema ADMS de la EERSSA.

CAPÍTULO 4

4. PRUEBAS Y RESULTADOS

4.1 Normalización de las Curvas de Demanda Históricas de los A/P de la S/E Norte

La base datos facilitada por la Superintendencia de Subestaciones y Comunicaciones de la EERRSA se encontraba en archivos .csv sin previo procesamiento, y compilada de manera desordenada. Para lo cual, se requirió realizar una estructuración homogénea del formato mensual y llevarlo a uno de tipo anual.

Al procedimiento de estructuración de la base de datos se trató automatizarlo mediante programación sin éxito alguno, esto debido a la incompatibilidad e inconsistencia de los formatos extraídos del periodo 2012-2018.

Por lo que, la compilación se la hizo de manera manual en un formato mensual por cada año histórico y alimentador de distribución. Luego, se procedió a realizar la depuración de los valores de demanda de acuerdo con el procedimiento detallado en el capítulo 3.2.

Y con esto, se realizó un código de programación en el lenguaje Python que permitió la importación de manera ordenada de los registros, y consolidarlos por cada año histórico. Finalmente, se representó los datos sin normalización y normalizados.

Para el código desarrollado en Python se utilizó las librerías pandas, numpy, y matplotlib.

A continuación, se indican los resultados obtenidos del proceso de normalización para cada alimentador de la S/E Norte.

4.1.1 A/P Parque Industrial

El 2012 fue el año para el A/P Parque Industrial en donde existieron más fallas transitorias y permanentes, tal como se indica en la Fig. 4.1. También, se puede observar que durante el mes de junio existen datos incompletos, esto se debió posiblemente a problemas de comunicación del relé de cabecera o de la RTU de la S/E Norte.

En la Fig. 4.1 se puede observar varios eventos transitorios que en su gran mayoría ocasionaron desconexiones durante un par de horas hasta que se realice el mantenimiento correctivo.

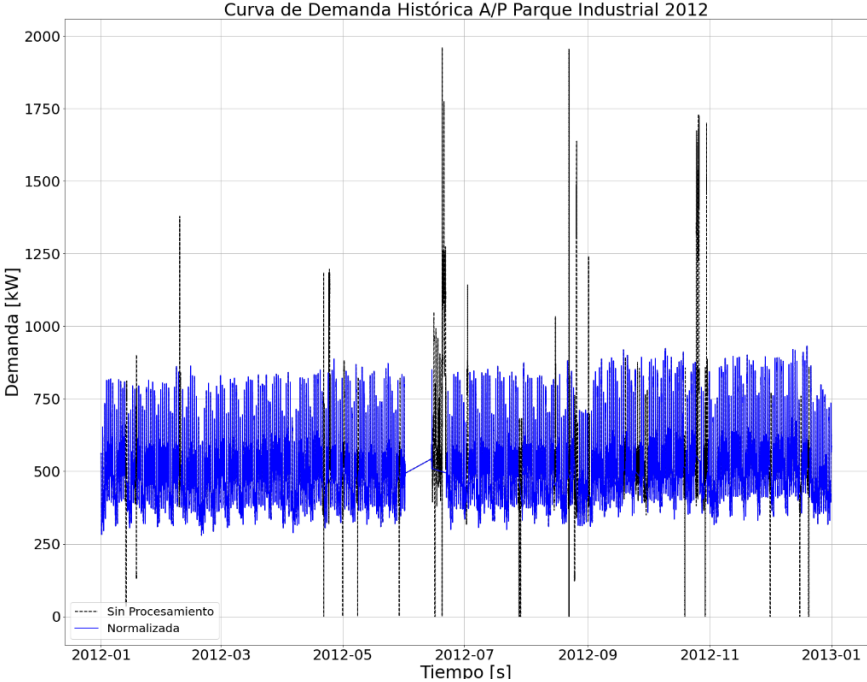


Figura 4.1 CDE del A/P Parque Industrial año 2012 [E.P].

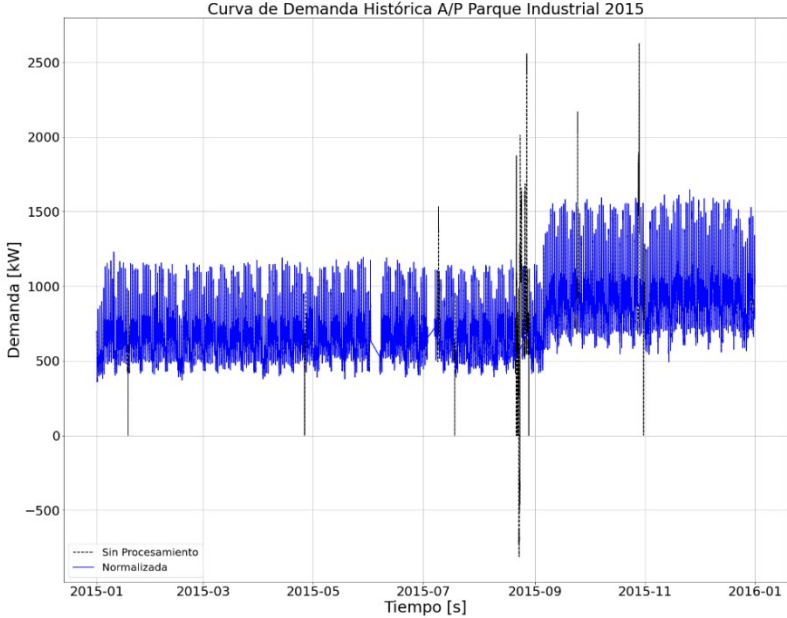


Figura 4.2 CDE del A/P Parque Industrial año 2015 [E.P].

Posterior al mes de septiembre del 2015, la demanda eléctrica sufrió un incremento de aproximadamente 250kW. Es importante destacar, que solo en este año la demanda eléctrica del A/P Parque Industrial sufrió un incremento fuera del crecimiento vegetativo.




Figura 4.3 CDE del A/P Parque Industrial año 2021 [E.P].

Durante el mes de abril del año 2021 se puede observar que la demanda del A/P Parque Industrial sufrió una disminución considerable, esto se produce cuando se realiza transferencias de potencia de un alimentador a otro, en el caso de la Fig. 4.3 del Parque Industrial al Motupe.

Como se puede observar en las gráficas anteriores, las curvas de demanda de color negro representan el comportamiento sin procesamiento de la demanda eléctrica, en donde se consideran fallas transitorias, permanentes, transferencia de carga, mallados entre alimentadores, y pérdidas de comunicación, etc. Mientras, que la de color azul representan las curvas demanda depuradas y normalizadas, las cuales fueron utilizadas para la aplicación del algoritmo GMM, y los métodos ARIMA y SARIMA.

En el anexo A se encuentra todas la curvas de demanda eléctrica históricas para el periodo 2012-2021.

4.1.2 A/P Chuquiribamba

De acuerdo a las gráficas del Anexo A.2 el comportamiento de la demanda eléctrica del A/P Chuquiribamba corresponde a uno de tipo residencial. Este A/P abastece del servicio energía eléctrica a gran parte de la parroquia rural Chuquiribamba, y barrios aledaños de las zonas marginales del cantón Loja. Por lo que, sus clientes reflejan un consumo más conservador durante el día, y presentan su demanda máxima alrededor de las 19:15 de la noche.

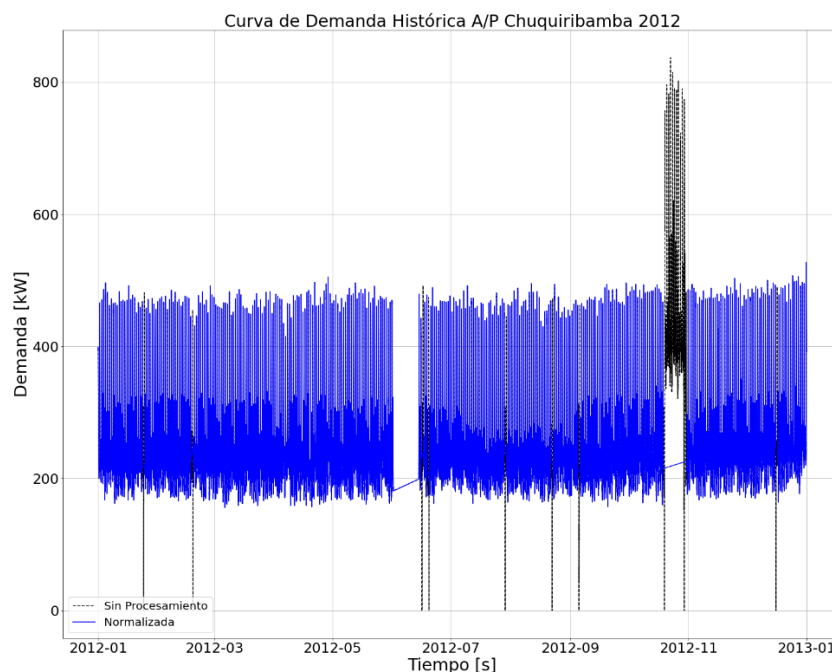


Figura 4.4 CDE del A/P Chuquiribamba año 2012 [E.P].

Como se puede observar en la Fig. 4.4 durante el mes octubre existió una transferencia de carga del A/P Malca-San Pedro de la S/E Catamayo hacia el A/P Chuquiribamba, lo que ocasionó un incremento de potencia activa. Por este motivo, estos datos fueron descartados de acuerdo al procedimiento establecido en la Capítulo 3.2.2.

Al igual que el A/P Parque Industrial, el año 2012 fue el año con más fallas transitorias y permanentes para el A/P Chuquiribamba.




Figura 4.5 CDE del A/P Chuquiribamba año 2016 [E.P].

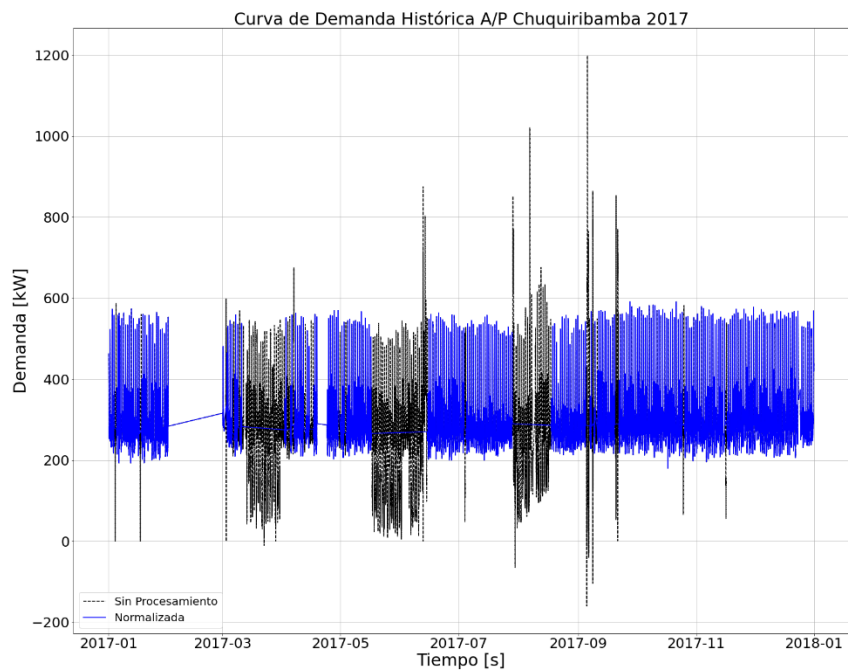


Figura 4.6 CDE del A/P Chuquiribamba año 2017 [E.P].

En la Fig. 4.5 se puede observar que durante el mes de enero y febrero del 2016 se requirió transferir potencia del A/P Chuquiribamba hacia el A/P Malca-San Pedro, por lo existió una reducción de demanda, comportamiento inverso al indicado en la Fig. 4.4.

También, se pudo observar que durante los meses abril, junio y agosto del 2017 el A/P Chuquiribamba sufrió constantes eventos de falla transitorios, que ocasionaron desconexiones automáticas.

4.1.3 A/P Motupe

De acuerdo con los registros históricos detallados en el Anexo C el A/P Motupe, es el alimentador con mayor consumo de potencia de la S/E Norte. Este alimentador abastece gran parte de la carga residencial de la zona norte de la ciudad de Loja, y algunos barrios urbano-marginales del cantón Loja. Además, es el alimentador de la S/E Norte que presenta la menor cantidad de fallas permanentes en el periodo 2012-2021.

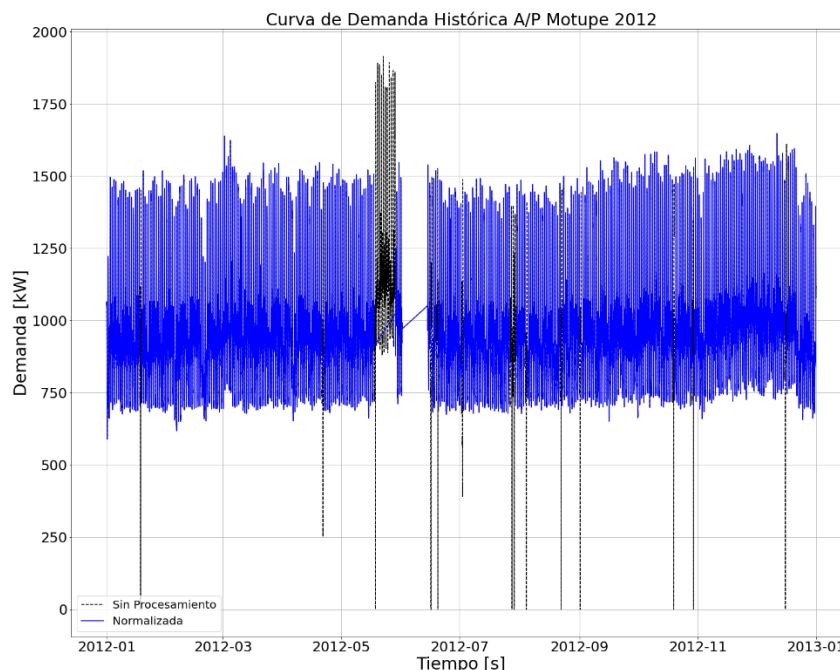


Figura 4.7 CDE del A/P Motupe año 2012 [E.P].

En la Fig. 4.7 se puede observar que durante el mes de junio existió una transferencia de potencia del A/P Motupe hacia el A/P Parque Industrial, esta maniobra se realizó debido a que el relé de cabecera del A/P Parque Industrial se encontraba inhabilitado.

Al igual que el A/P Parque Industrial y Chuquiribamba, el año 2012 fue el año con mayor número de fallas transitorias y permanentes para el A/P Motupe.

Es importante mencionar el A/P Motupe presenta una reducción importante de desconexiones automáticas y fallas permanentes desde el año 2012 hasta el año 2021.




Figura 4.8 CDE del A/P Motupe año 2019 [E.P].

En la Fig. 4.8 durante el mes diciembre existió un evento transitorio que no produjo la desconexión automática del A/P Motupe. Este ejemplo, destaca la importancia de realizar la depuración de la base datos previo a la estimación de carga. Con lo cual, se eliminan datos exagerados que no representan un escenario operativo real.

Durante el mes de mayo del 2020, se presentaron valores de potencia activa iguales a cero, tal como se indica en la Fig. 4.9. Esto fue ocasionado debido a que existía una falla en el relé de cabecera del alimentador; más no porque la carga se haya transferido hacia otro alimentador o se haya realizado un mantenimiento correctivo del A/P Motupe. Cuando existen este tipo de anomalías, generalmente se suele transferir la carga prioritaria del alimentador afectado hacia otro.




Figura 4.9 CDE del A/P Motupe año 2020 [E.P].

4.1.4 A/P Carigán

Los registros históricos detallados en el Anexo A.4 indican que el comportamiento de la demanda del A/P Carigán corresponden a una de tipo residencial, y es el alimentador con menor aporte de potencia activa para la S/E Norte.

En la Fig. 4.10 se puede observar que los valores de demanda máxima del A/P Carigán se producen alrededor 18:45 y 19:00 horas. También, que durante los meses de marzo, junio y octubre existió una pérdida de comunicación del relé.

En la Fig. 4.11 se observa que existen muchos picos de corriente, pero estos se encuentran muy alejados de los valores del alarma y disparo del relé de protección; por lo que, no existen desconexiones automáticas del alimentador. Cabe destacar que, estos picos de corriente no son descartados debido a que no representan un comportamiento atípico de la demanda.




Figura 4.10 CDE del A/P Carigán año 2012 [E.P].

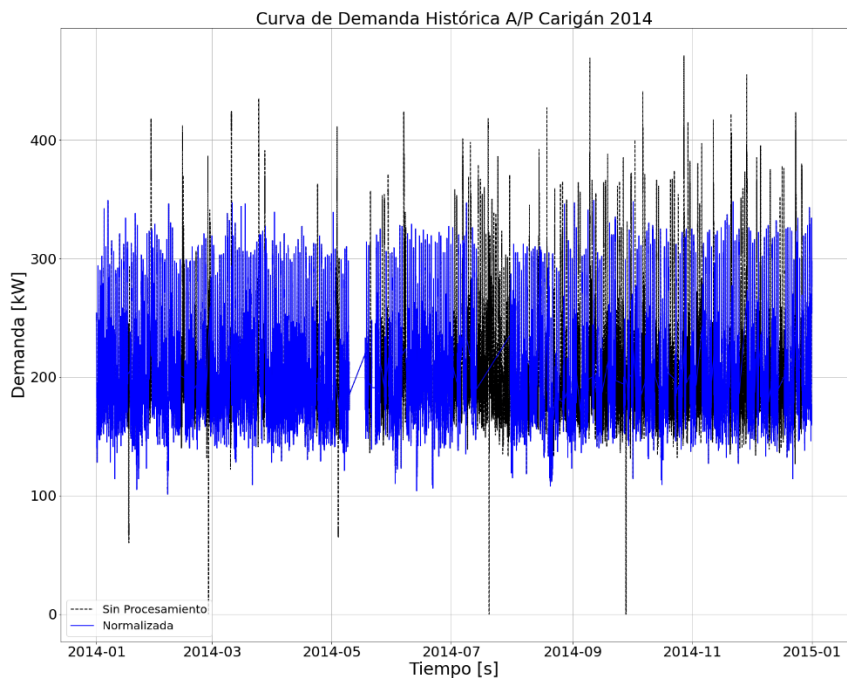


Figura 4.11 CDE del A/P Carigán año 2014 [E.P].

4.2 Aplicación del Algoritmo GMM para los Registros Históricos Normalizados

Con los valores históricos de demanda normalizados, se aplicó el algoritmo GMM y se obtuvo la función de probabilidad gaussiana mixta, de donde se extrajo la media con el valor más alto, la cual es la demanda máxima de mayor representación probabilística.

Para la aplicación del algoritmo GMM se desarrolló un código en el lenguaje de programación Python, en donde se utilizó las librerías pandas, numpy, matplotlib, seaborn, sklearn, datasets.

El código de programación desarrollado está estructurado de la siguiente manera:

En la primera parte, se realizó la importación de los valores demanda indicados en el capítulo 4.1, y Anexo A, los cuales fueron conglomerados por alimentador y de manera anual. Para la segunda parte se realizó el denominado clustering empleando la librería sklearn.mixture y la herramienta GuassianMixture. Y con el número de componentes, tipo de covarianza, número máximo de iteraciones, y parámetros iniciales se ajustó la base de datos a un modelo guassiano.

Tabla 4.1 Parámetros para el Modelo Gaussiano [E.P].

Nro. Componentes	Número óptimo basado en AIC y BIC
Tipo de Covarianza	Full
Máximo de Iteraciones	100
Parámetros Iniciales	kmeans

Del modelo gaussiano mixto se obtuvo las medias, covarianzas y pesos de cada función de probabilidad según el número de componentes y año histórico. Además, se graficaron las funciones de probabilidad en escala logarítmica con el fin de facilitar su interpretación y análisis.

Tabla 4.2 Resultados de covarianzas, pesos y medias A/P Parque Industrial año 2012 [E.P].

Covarianzas	Pesos	Medias
0.414766	2073.37	529.6531
0.429726	1821.701	407.4166
0.155508	4843.633	739.3198

En la tabla 4.2 se visualizan los resultados obtenidos de la función de probabilidad mixta correspondiente al A/P Parque Industrial para el año 2012. Este procedimiento también fue realizado para los A/P Chuquiribamba, Motupe y Carigán desde el año 2012 al 2021.




Figura 4.12 FDP de la Demanda Eléctrica A/P Parque Industrial [E.P].

En la Fig. 4.12 se puede observar que la función de probabilidad del A/P Parque Industrial para el año 2012 corresponde a una suma finita de tres funciones de densidad. Razón por la cual, el modelo arroja tres valores de media, covarianza y peso. Es importante destacar que, cada componente representa un escenario operativo del SED; respectivamente a demanda máxima, media y baja.

La aplicación del modelo gaussiano mixto guarda muy estrecha relación con el número de componentes seleccionados, por lo que una incorrecta selección puede llegar a provocar errores sustanciales en los resultados de media, covarianza y pesos. La determinación del número óptimo de componentes se lo realizó bajo los criterios AIC y BIC en el lenguaje de programación Python.

De acuerdo a la Fig. 4.13 se puede observar que la base de datos analizada tiene más de 458000 datos. Para la selección del valor óptimo de componentes se utilizó el criterio del codo, el cual corresponde al punto de inflexión de la curva, siendo este punto cercano a tres.

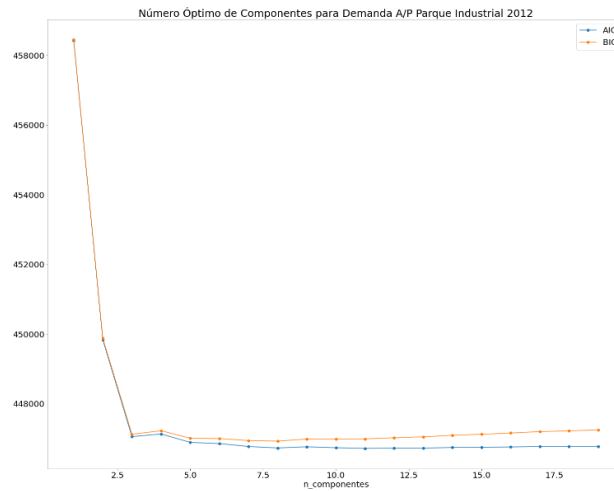


Figura 4.13 Número óptimo de componentes para FPD A/P Parque Industrial 2012 [E.P].




Figura 4.14 Número óptimo de componentes FPD A/P Parque Industrial 2020 [E.P].

Si bien, en la mayoría de los registros históricos analizados la determinación del número óptimo de componentes tiene comportamiento similar al de la Fig. 4.13. En algunos casos no, como es la del año 2020 para el A/P Parque Industrial Fig. 4.14. Este comportamiento dificulta la selección intuitiva del número componentes, debido a lo cual se debe analizar detalladamente la curva de función de probabilidad, en contraste con la curva de número componentes, y encontrar concordancias analíticas entre las mismas previa la determinación del número de componentes final.

El comportamiento de la Fig. 4.14 se da debido a que el año 2020 fue el año pico de la cuarentena por el COVID-19, y esto obligó a gran parte de los ciudadanos a encerrarse en sus hogares, y cambiar sus hábitos de consumo de energía eléctrica.

Finalmente, de los resultados obtenidos de la aplicación del algoritmo GMM, se seleccionó la media con el valor de demanda más alto. Y con una banda muerta del 15-20% de tolerancia, se evaluó en la base datos anual, y se determinaron el día y la hora de los escenarios de demanda máxima para cada alimentador en el periodo del 2012-2021, tal como se indica en la Tabla 4.3.

Tabla 4.3 Determinación de Escenario Dmáx A/P Parque Industrial [E.P].

Fecha	Demanda Máxima [kW]
2012-04-26 19:45:00	887
2012-09-07 20:15:00	887

Tabla 4.4 Análisis Número de Componentes FDP A/P Parque Industrial [E.P].

Caso 1			Caso 2		
Fecha	Nro. Comp	Demanda (kW)	Fecha	Nro. Comp	Demanda (kW)
2012-09-07 20:15:00	3	887.00	2012-12-19 20:00:00	5	932.00
2013-03-13 20:15:00	3	963.00	2013-11-18 20:00:00	5	1001.00
2014-11-17 20:15:00	3	1090.00	2014-11-25 20:00:00	5	1129.00
2015-11-11 20:00:00	4	1612.00	2015-11-25 19:29:00	5	1646.00
2016-11-07 21:15:00	3	1649.00	2016-01-13 21:00:00	5	1752.00
2017-11-10 20:00:00	3	1690.00	2017-06-30 10:29:00	5	1797.00
2018-09-17 20:45:00	3	1667.00	2018-04-17 21:45:00	5	1738.00
2019-09-30 20:00:00	3	1731.14	2019-08-30 14:45:00	5	1784.06
2020-06-05 20:45:00	12	1946.67	2020-06-04 19:15:00	11	2287.88
2021-08-03 20:15:00	8	1807.00	2021-03-15 09:45:00	11	1841.39

En la Fig. 4.15 se puede observar que la desviación de los valores entre el caso 1 y caso 2 es mínima, únicamente para el año 2020 existe un error significativo. Es por esto, que para el presente trabajo se consideró el criterio 1 como la mejor opción para determinar el número de componentes.




Figura 4.15 Número óptimo de componentes Caso 1 vs Caso 2 A/P Parque Industrial [Elaboración Propia].

Los resultados del número de componentes obtenidos de la aplicación del algoritmo GMM fueron evaluados en dos casos, el primero corresponde al determinado por el criterio del código y el análisis de las gráficas de función de densidad de probabilidad. Mientras que, el segundo corresponde a un criterio netamente más conservador del número de componentes; donde se pudo determinar, que el primer criterio es el más adecuado y con mejores resultados. Como se puede observar en la Tabla 4.4, para el caso 2 los horarios para los años 2017, 2018, 2019 y 2021 no corresponden a un escenario de demanda máxima.

En las figuras 4.16, 4.17, 4.18 y 4.19 se presentan los resultados de la aplicación del algoritmo GMM para determinar las curvas de demanda máxima históricas de mayor representación probabilística para los A/P de la S/E Norte para el periodo 2012-2021.




Figura 4.16 CDE Históricas A/P Parque Industrial periodo 2012-2021 [E.P].




Figura 4.17 CDE Históricas A/P Chuquiribamba periodo 2012-2021[E.P].




Figura 4.18 CDE Históricas A/P Motupe periodo 2012-2021[E.P].




Figura 4.19 CDE Históricas A/P Carigán periodo 2012-2021 [E.P].

4.3 Proyección de la Demanda de los A/P de la S/E Norte

Para la determinación del modelo con mejores métricas de estimación se consideró tres criterios, el primero corresponde a la construcción del modelo ARIMA tomando la información detallada en los subcapítulos 3.4.1,3.4.2,y 3.4.3, este procedimiento se lo realizó con la ayuda de algunas librerías del lenguaje de programación Python, tal como se indicó en el Capítulo 3.4. Para el segundo el criterio se utilizó la herramienta `auto_arima`, con el fin de buscar el modelo ARIMA con menor AIC. Y finalmente, para el tercer criterio se utilizó de igual manera la herramienta `auto_arima`, pero en este caso se realizó ciertos ajustes de parámetros al código, que permitieron encontrar el mejor modelo SARIMA con menor AIC.

4.3.1 Modelo ARIMA

Para la construcción del modelo ARIMA se utilizó las librerías `numpy`, `pandas`, `statsmodels`, y `matplotlib`.

Con la ayuda de la librería `statsmodels.tsa.stattools` se importó la librería `adfuller`, para realizar la prueba Dikey-Fuller, y determinar si la base datos requiere un proceso de diferenciación o no.

A partir de los resultados de la prueba Dikey-Fuller se pudo observar que la base de datos para el A/P Parque Industrial requiere un proceso de diferenciación, ya que el valor de p es mayor 0.05, tal como se indica en la Tabla 4.5.

Tabla 4.5 Resultados Prueba Dikey-Fuller A/P Parque Industrial [E.P].

ADF-Statistic	-2.5163
p-value	0.1116

Mediante programación se realizó el proceso de diferenciación, en donde se pudo observar que, en la primera diferenciación el gráfico de autocorrelación presenta el mejor ajuste de valores, ya que para la segunda y tercera diferenciación existe rezagos negativos, que indican un sobreajuste de los parámetros.

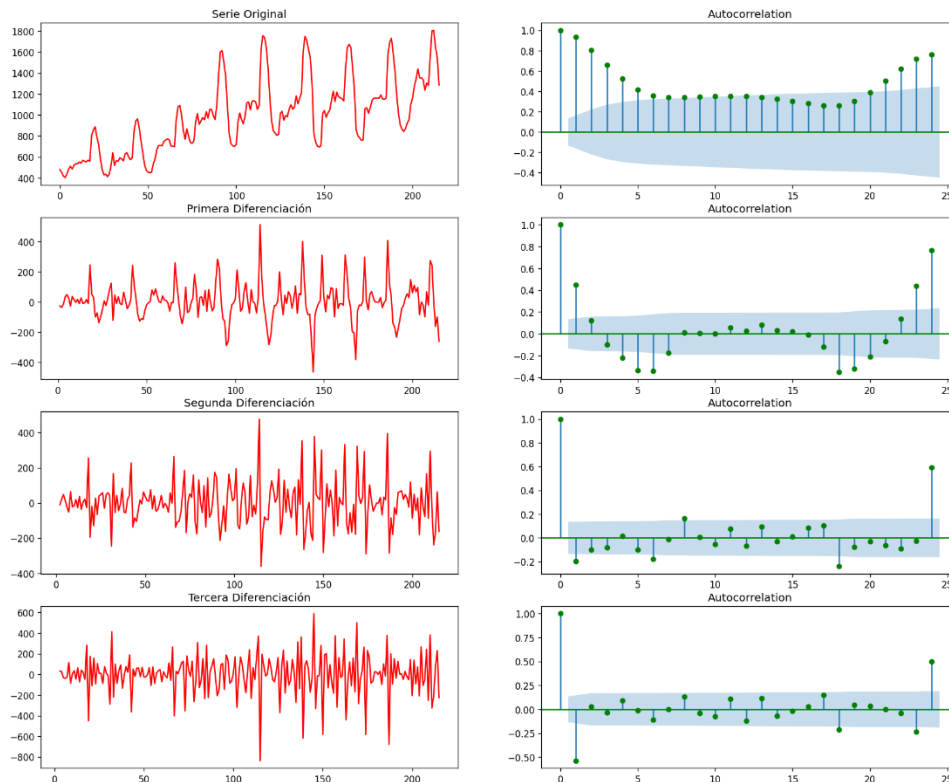


Figura 4.20 Diferenciación de la Base de Datos A/P Parque Industrial [E.P].

Posterior a esto, para la primera diferenciación se realizó la prueba Dikey-Fuller, y se obtuvo que el valor de p es menor es a 0.05. Tal como se indica en la Tabla 4.6.

Tabla 4.6 Resultados Prueba Dikey-Fuller primera diferenciación A/P Parque Industrial [E.P].

ADF-Statistic	-8.9222
p-value	0.0000

A partir del gráfico de Autocorrelación Parcial (PACF) se observó que existen dos rezagos por encima del límite de significancia, para este caso únicamente se consideró el primer coeficiente siendo este el de mayor aporte al valor del parámetro AR del modelo.




Figura 4.21 Gráfico PACF A/P Parque Industrial [E.P].




Figura 4.22 Gráfico ACF A/P Parque Industrial [E.P].

Para la determinación del parámetro MA, se observó que existe tres rezagos por encima del límite de significancia de la Autocorrelación, tomando un criterio conservador se seleccionó el primero.

El parámetro AR guarda relación con el error del pronóstico retrasado, y el parámetro MA indica cuantos términos se requieren para eliminar cualquier autocorrelación de la serie estacionaria.

```

SARIMAX Results
=====
Dep. Variable:          Potenciaf      No. Observations:          216
Model:                 ARIMA(1, 1, 1)  Log Likelihood             -1314.606
Date:                  Mon, 20 Feb 2023  AIC                        2635.211
Time:                  18:57:45        BIC                        2645.323
Sample:                0              HQIC                       2639.297
                        - 216
Covariance Type:      opg
=====
              coef      std err          z      P>|z|      [0.025      0.975]
-----
ar.L1          0.3485      0.178         1.958      0.050      -0.000      0.697
ma.L1          0.1405      0.199         0.707      0.479      -0.249      0.530
sigma2        1.197e+04      732.143       16.344      0.000      1.05e+04      1.34e+04
=====
Ljung-Box (L1) (Q):          0.01      Jarque-Bera (JB):          141.96
Prob(Q):                    0.91      Prob(JB):                   0.00
Heteroskedasticity (H):     3.09      Skew:                       0.98
Prob(H) (two-sided):        0.00      Kurtosis:                   6.47
=====

```

Figura 4.23 Resumen Modelo ARIMA (1,1,1) A/P Parque Industrial [E.P].

En el resumen del modelo ARIMA (1,1,1) existe información con respecto al número de observaciones, valores de los criterios AIC y BIC, los coeficientes los parámetros AR y MA. Así como, los errores estándares y el valor P respectivamente. Los valores de los coeficientes corresponden a los pesos de los términos AR y MA del modelo implementado.

Mediante la librería statsmodels.api con la herramienta sm.stats.acorr_ljungbox, se realizó la prueba Ljung-Box para verificar el contenido de ruido blanco del modelo seleccionado. En donde se determinó que el P-valor del modelo es superior 0.05, con lo cual se demostró que nuestro modelo se ajusta bien y existe ruido blanco.

Tabla 4.7 P-valor del Modelo ARIMA (1,1,1) A/P Parque Industrial [E.P].

ADF-Statistic	12.4332
p-value	0.2571

En la Tabla 4.7 se puede observar que los valores residuales del modelo ARIMA (1,1,1) tienen una media igual a cero, y su función de distribución corresponde a una de tipo normal.

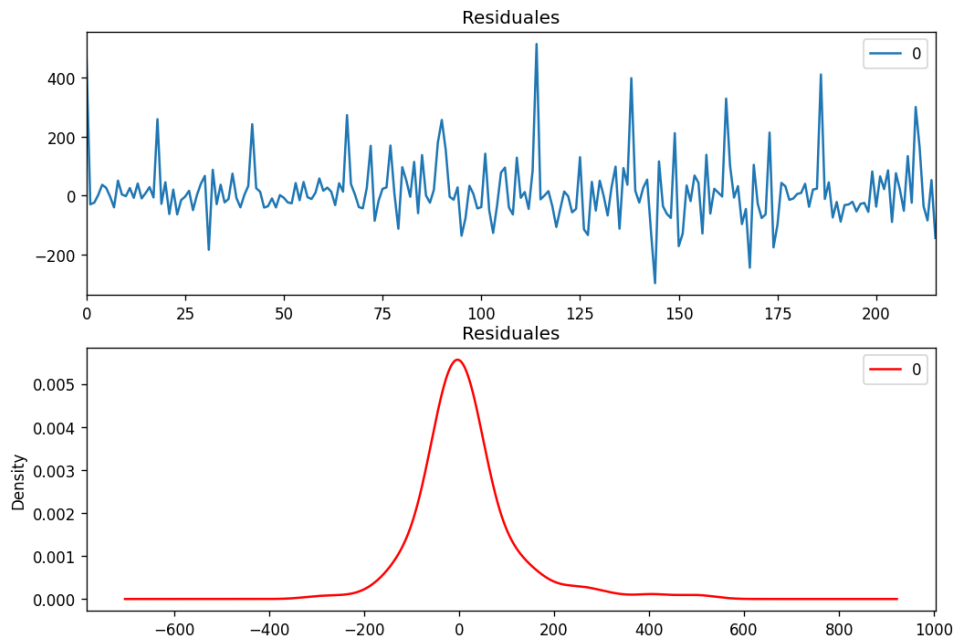


Figura 4.24 Resultados Prueba Ljung-Box Modelo ARIMA (1,1,1) A/P Parque Industrial [E.P].

Una vez determinados los parámetros del modelo ARIMA se procedió a realizar la validación cruzada manualmente, con el fin de encontrar el modelo óptimo. Para este procedimiento se requiere retroceder algunos pasos en el tiempo, y estimar en el futuro la misma proporción de pasos retrocedidos, y contrastar con los valores reales.

Para la validación cruzada se requirió separar un conjunto de datos de entrenamiento y prueba en dos partes contiguas de la serie, y en una proporción aproximadamente del 80:20, o una proporción adecuada basada en la frecuencia de la serie de tiempo.

Para el nuestro caso en específico, la cantidad de datos de prueba fue de 48 puntos, lo que corresponde a dos años de demanda históricos.

En la Fig. 4.25 se observa al conjunto de datos de entrenamiento y prueba en una proporción 80:20, y en el mismo gráfico se observa los valores estimados obtenidos al aplicar el modelo ARIMA (1,1,1). El modelo ARIMA (1,1,1) presentó un pronóstico con un direccionamiento correcto, y se encuentra dentro del margen de confianza del 95%; pero no tiene una tendencia adecuada con los valores reales de la serie de tiempo.




Figura 4.25 Validación Cruzada Serie de Tiempo Modelo ARIMA (1,1,1) A/P Parque Industrial [E.P].

Tabla 4.8 Métricas Pronóstico Modelo ARIMA (1,1,1) A/P Parque Industrial [E.P].

MAPE	0.1737
RMSE (kW)	255.2733
MSE (kW)	195.01
R2	0.1704

Con la ayuda de la herramienta metrics de la librería sklearn se obtuvo los valores de correspondientes al MAPE, RMSE, MSE, y R2. El error porcentual absoluto medio cuyo valor es de 17.37%, nos permitió determinar que el modelo ARIMA (1,1,1) presenta un elevado error para la estimación de demanda eléctrica a largo plazo.

El procedimiento detallado en el capítulo 4.3.1 se repitió para los A/P Chuquiribamba, Motupe, y Carigán.

4.3.2 Modelo ARIMA Optimizado

Para determinar el modelo óptimo mediante programación se utilizó la herramienta pm.auto_arima de la librería statsmodels.tsa.arima_model, y de manera recursiva y automatizada, el código de programación buscó el modelo con menor valor AIC. Para la aplicación de la herramienta pm.auto_arima se requirió ingresar los valores iniciales y máximos de los parámetros AR y MA, la frecuencia de la serie, e indicar si la serie tiene características estacionarias o no. Además, se utiliza la herramienta adftest para encontrar el valor de diferenciación “d” óptimo.

```

model = pm.auto_arma(P, start_p=0, start_q=0,
                    test='adf',
                    max_p=3, max_q=3,
                    m=1,
                    d=None,
                    seasonal=False,
                    start_P=0,
                    D=1,
                    trace=True,
                    error_action='ignore',
                    suppress_warnings=True,
                    stepwise=True)

print(model.summary())

```

Figura 4.26 Parámetros de pm.auto_arma A/P Parque Industrial [E.P].

```

Performing stepwise search to minimize aic
ARIMA(0,0,0)(0,0,0)[0] : AIC=3614.324, Time=0.00 sec
ARIMA(1,0,0)(0,0,0)[0] : AIC=inf, Time=0.01 sec
ARIMA(0,0,1)(0,0,0)[0] : AIC=inf, Time=0.03 sec
ARIMA(1,0,1)(0,0,0)[0] : AIC=2656.949, Time=0.04 sec
ARIMA(2,0,1)(0,0,0)[0] : AIC=2651.715, Time=0.07 sec
ARIMA(2,0,0)(0,0,0)[0] : AIC=2650.839, Time=0.02 sec
ARIMA(3,0,0)(0,0,0)[0] : AIC=2651.126, Time=0.05 sec
ARIMA(3,0,1)(0,0,0)[0] : AIC=2625.643, Time=0.15 sec
ARIMA(3,0,2)(0,0,0)[0] : AIC=2627.414, Time=0.20 sec
ARIMA(2,0,2)(0,0,0)[0] : AIC=2652.275, Time=0.08 sec
ARIMA(3,0,1)(0,0,0)[0] intercept : AIC=2637.224, Time=0.08 sec

Best model: ARIMA(3,0,1)(0,0,0)[0]
Total fit time: 0.749 seconds

```

Figura 4.27 Procedimiento recursivo de la aplicación pm.auto_arma A/P Parque Industrial [E.P].

Una vez ejecutado el procedimiento recursivo se observó que el modelo ARIMA con el menor AIC es el modelo (3,0,1). Es importante destacar, que este modelo presenta un valor de $d=0$, es decir que el modelo óptimo no requirió un proceso de diferenciación.




Figura 4.28 Validación Cruzada Serie de Tiempo Modelo ARIMA (3,0,1) A/P Parque Industrial [E.P].

En la validación cruzada del modelo ARIMA(3,0,1) se pudo observar que el pronóstico presentó un direccionamiento correcto dentro del margen de confianza del 95%, y además tiene una mejora sustancial en el ajuste de la tendencia.

Tabla 4.9 Métricas Pronóstico Modelo ARIMA (2,1,3) A/P Parque Industrial [E.P].

MAPE	0.2204
RMSE (kW)	275.4779
MSE (kW)	233.7664
R2	0.0338

De igual manera con la herramienta metrics se obtiene las métricas de dispersión del error del pronóstico, en donde el MAPE del modelo (3,0,1) presentó un valor (22.04%) superior al modelo obtenido por el modelo (1,1,1).

El procedimiento detallado en el capítulo 4.3.2 se repitió para los A/P Chuquiribamba, Motupe, y Carigán.

4.3.3 Modelo SARIMA Optimizado

Para la determinar el modelo SARIMA mediante programación se utilizó la herramienta pm.auto_arima de la librería statsmodels.tsa.arima_model, y de manera recursiva y automatizada el código de programación buscó el modelo con menor valor AIC.

Es importante destacar que el modelo SARIMA aplica un proceso de diferenciación estacionaria, que tiene un mejor ajuste en bases de datos con fuertes patrones estacionales. En la gráfica 4.29, se indica los resultados de diferenciación para los modelos ARIMA y SARIMA del A/P Parque Industrial.




Figura 4.29 Diferenciación modelos ARIMA y SARIMA [E.P].

En la Fig. 4.30 se indican los parámetros del modelo SARIMA, para este modelo se considera el criterio de estacionalidad.

```

smodel = pm.auto_arima(P, start_p=0, start_q=0,
                       test='adf',
                       max_p=3, max_q=3, m=24,
                       start_P=0, seasonal=True,
                       d=None, D=1, trace=True,
                       error_action='ignore',
                       suppress_warnings=True,
                       stepwise=True)

smodel.summary()

```

Figura 4.30 Parámetros modelo SARIMA A/P Parque Industrial [E.P].

```

ARIMA(1,1,1)(1,1,1)[24] : AIC=2147.017, Time=7.75 sec
ARIMA(1,1,1)(0,1,2)[24] : AIC=2147.464, Time=9.11 sec
ARIMA(1,1,1)(1,1,0)[24] : AIC=2151.749, Time=1.87 sec
ARIMA(1,1,1)(1,1,2)[24] : AIC=2149.693, Time=14.17 sec
ARIMA(2,1,1)(0,1,1)[24] : AIC=2146.790, Time=5.16 sec
ARIMA(1,1,2)(0,1,1)[24] : AIC=2146.803, Time=5.36 sec
ARIMA(0,1,2)(0,1,1)[24] : AIC=2153.144, Time=1.44 sec
ARIMA(2,1,0)(0,1,1)[24] : AIC=2153.286, Time=1.47 sec
ARIMA(2,1,2)(0,1,1)[24] : AIC=2144.665, Time=6.99 sec
ARIMA(2,1,2)(0,1,0)[24] : AIC=2183.934, Time=0.78 sec
ARIMA(2,1,2)(1,1,1)[24] : AIC=2146.415, Time=7.70 sec
ARIMA(2,1,2)(0,1,2)[24] : AIC=2146.465, Time=20.82 sec
ARIMA(2,1,2)(1,1,0)[24] : AIC=2152.351, Time=4.27 sec
ARIMA(2,1,2)(1,1,2)[24] : AIC=2148.675, Time=23.50 sec
ARIMA(3,1,2)(0,1,1)[24] : AIC=2149.759, Time=4.87 sec
ARIMA(2,1,3)(0,1,1)[24] : AIC=inf, Time=7.61 sec
ARIMA(1,1,3)(0,1,1)[24] : AIC=2152.951, Time=3.89 sec
ARIMA(3,1,1)(0,1,1)[24] : AIC=2154.658, Time=4.31 sec
ARIMA(3,1,3)(0,1,1)[24] : AIC=inf, Time=8.83 sec
ARIMA(2,1,2)(0,1,1)[24] intercept : AIC=inf, Time=7.29 sec

Best model: ARIMA(2,1,2)(0,1,1)[24]
Total fit time: 169.673 seconds

```

Figura 4.31 Procedimiento recursivo modelo SARIMA A/P Parque Industrial [E.P].

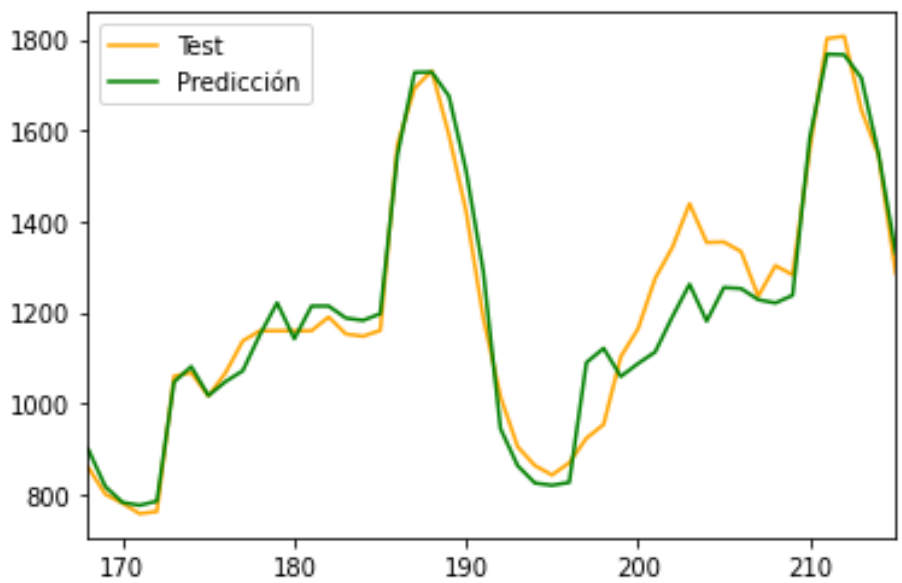


Figura 4.32 Validación Cruzada Serie de Tiempo Modelo SARIMA (2,1,2)(0,1,1) A/P Parque Industrial [E.P].

Del procedimiento recursivo se obtuvo que el modelo con menor AIC es el SARIMA (2,1,2)(0,1,1). Para los datos de prueba y entrenamiento se utilizó una proporción 80:20 igual que para los casos anteriores. El modelo SARIMA (2,1,2)(0,1,1) presentó un correcto direccionamiento, y los resultados de predicción un adecuado ajuste en la tendencia en comparación a los valores prueba.

Tabla 4.10 Métricas Pronóstico Modelo SARIMA (2,1,2)(0,1,1) A/P Parque Industrial [E.P].

MAPE	0.0471
RMSE (kW)	74.5803
MSE (kW)	56.0728
R2	0.9292

El MAPE obtenido del SARIMA (4.71%) presentó una mejoría considerable en comparación a la del ARIMA de (17.37%). El procedimiento detallado en el capítulo 4.3.3 se repitió para los A/P Chuquiribamba, Motupe, y Carigán, de donde se obtuvieron métricas de dispersión en todos los casos con un mejor rendimiento para los modelos SARIMA.




Figura 4.33 Validación Cruzada Completa SARIMA (2,1,2)(0,1,1) A/P Parque Industrial [E.P].

4.3.4 Incorporación de Cargas Especiales

Tabla 4.11 Características de carga A/P de la S/E Norte [SIG EERSSA].

A/P	Tipo de Clientes	Área de Servicio
Parque Industrial	Residencial+Industrial	Urbano
Chuquiribamba	Residencial	Urbano Marginal-Rural
Motupe	Residencial	Urbano
Carigán	Residencial	Urbano Marginal

De los A/P de la S/E Norte únicamente el Parque Industrial presenta características de carga industriales, y sus redes de medio voltaje están localizadas y distribuidas con el fin de abastecer de energía eléctrica a las actuales, y futuras fábricas y empresas productivas de Loja. Además, debido al crecimiento urbanístico que ha tenido la zona Nororiental, gran parte de esta carga se ha conectado al A/P Parque Industrial.

De la revisión de las factibilidades de servicio con cargas superiores a 250kW de la S/E Norte, se pudo verificar que únicamente existen registros de solicitudes para el A/P Parque Industrial. Para los A/P Chuquiribamba, Motupe y Carigán debido a sus características de carga solo se consideró el crecimiento vegetativo de la demanda.




Figura 4.34 C.D.E Carga Especial [E.P].

Una vez analizado el comportamiento histórico de la demanda, y en conjunto con las factibilidades de servicio solicitadas del A/P Parque Industrial, se consideró para el año 2025 el ingreso de una carga con una curva como la de la Fig. 4.34. Esta curva fue sumada a los resultados de la proyección de la demanda obtenidos del modelo con mejor MAPE, que para nuestro estudio fue el modelo SARIMA.

4.3.5 Proyección de la Demanda para el periodo 2022-2031

Una vez aplicados los modelos ARIMA y SARIMA de acuerdo a los procedimientos 4.3.2, 4.3.3 y 4.3.4, se obtuvieron las métricas de error de pronóstico detalladas en la Tabla 4.12. En esta tabla se puede observar que para todos los casos el Modelo SARIMA Optimizado, es el modelo que presenta mejores métricas, y además presentó una correcta dirección y ajuste entre los valores de prueba y entrenamiento en la validación cruzada.

Los modelos de estimación del procedimiento 4.3.2 y 4.3.3 correspondientes a los modelos de ARIMA de construcción manual y el ARIMA optimizado, presentaron las

métricas de error muy elevadas, y cuya diferencia entre ellas es mínima no superior a un 5% de desviación en el caso más crítico. Para el caso de los modelos SARIMA, los A/P Parque Industrial, Motupe y Chuquiribamba presentaron un MAPE inferior al 10%, únicamente para el A/P Carigán se obtuvo un MAPE del 12%, destacando que este alimentador es el de menor aporte de demanda para la S/E Norte, con lo cual su RMSE es 59.78 kW. Para el A/P Parque Industrial el MAPE es de 4.7%, siendo este valor la mejor métrica obtenida.

Tabla 4.12 Resultados de Métricas de Dispersión de Error de Pronóstico S/E Norte [E.P].

A/P	Modelo	MAPE	RMSE	MSE	R2
Parque Industrial	ARIMA CM (1,1,1)	0.1737	255.2733	195.0099	0.1704
	ARIMA OPT (3,0,1)	0.2204	275.4779	233.7664	0.0338
	SARIMA (2,1,2)x(0,1,1,24)	0.0470	74.5803	56.0728	0.9291
Motupe	ARIMA CM (1,1,1)	0.1865	379.5542	302.8489	-0.4836
	ARIMA OPT (2,0,1)	0.1732	390.7654	293.2365	-0.5725
	SARIMA (1,0,0)x(0,1,1,24)	0.0961	170.2127	145.3545	0.7016
Chuquiribamba	ARIMA CM (1,1,1)	0.1695	94.9053	67.6454	-0.2137
	ARIMA OPT (2,0,0)	0.1497	91.9484	61.7826	-0.1392
	SARIMA (1,0,0)x(1,1,0,24)	0.0710	23.6260	23.6260	0.8615
Carigán	ARIMA CM (1,1,1)	0.1640	87.5723	69.1619	0.2153
	ARIMA OPT (2,0,0)	0.1497	91.9484	61.7826	-0.1392
	SARIMA (0,1,1)x(2,1,0,24)	0.1225	59.7800	47.4327	0.6343

La proyección de la demanda para el periodo 2022-2031 del A/P Parque Industrial, Motupe, Chuquiribamba y Carigán se realizó mediante el modelo SARIMA Optimizado. Los resultados de la proyección se detallan en las Fig. 4.35, 4.36, 4.37 y 4.38.




Figura 4.35 Proyección de la Demanda A/P Parque Industrial periodo 2022-2031 [E.P].




Figura 4.36 Proyección de la Demanda A/P Chuquiribamba periodo 2022-2031 [E.P].




Figura 4.37 Proyección de la Demanda A/P Motupe periodo 2022-2031 [E.P].




Figura 4.38 Proyección de la Demanda A/P Carigán periodo 2022-2031 [E.P].

En la Figura 4.36 la proyección de la demanda del A/P Chuquiribamba presenta un comportamiento estacionario hasta el 2031, siendo su crecimiento anual casi nulo. Esto

se produce debido a que las curvas de demanda históricas durante el periodo del 2012-2017 registran una tendencia al crecimiento, pero para el año 2018 este crecimiento se ve abruptamente disminuido, y se establece una tendencia estacionaria.

4.4 Simulación de Resultados de la Demanda Proyectada

4.4.1 Diagrama Unifilar




Figura 4.39 Diagrama Unifilar S/E Norte [E.P].

En la Fig. 4.39 se observa el diagrama unifilar de la S/E Norte en el Software Cyme. El diagrama unifilar contempla los cuatro A/P Parque Industrial, Motupe, Carigán y Chuquiribamba modelados como cargas trifásicas concentradas. Además, se incluye el transformador de potencia 10MVA 69/13.8kV modelado de acuerdo a la base de datos facilitada por la EERSSA. Para el presente trabajo de titulación se utilizó esquema barra

infinita-carga, siendo el patio 69kV el punto de conexión a la barra infinita, y aguas abajo del transformador de potencia la carga. Se considero este criterio, ya que los resultados del flujo de potencia aguas arriba de la barra de 69kV de la S/E Norte no son interés para el presente trabajo.

4.4.2 Cargabilidad del Transformador de Potencia

Tabla 4.13 Demanda Máximas Proyectadas S/E Norte [E.P].

Año	Demanda [kW]				
	Parque Industrial	Chuquiribamba	Motupe	Carigán	Trafo
2022	1888.45	575.53	2184.61	655.67	5304.26
2023	1958.31	577.87	2233.45	681.21	5450.84
2024	2027.51	576.64	2282.28	719.20	5605.63
2025	2398.44	577.28	2331.12	747.72	6054.55
2026	2468.22	576.95	2379.95	776.65	6201.77
2027	2537.99	577.12	2428.79	808.60	6352.49
2028	2607.76	577.03	2477.62	838.93	6501.34
2029	2677.52	577.08	2526.46	869.02	6650.09
2030	2747.29	577.05	2575.29	899.79	6799.42
2031	2817.06	577.07	2624.13	930.30	6948.56

En la tabla 4.13 se encuentran los valores de demanda máxima de los A/P de la S/E Norte para el periodo 2022-2031. Estos valores fueron empleados para calcular la cargabilidad, pérdidas de potencia del transformador de potencia, caídas de voltaje en la barra de 13.8kV, y límites térmicos de los A/P.

De acuerdo al Plan de Expansión de la Transmisión del Plan Maestro de Electrificación 2013-2022, para la determinación de necesidades de ampliación de transformación, se utiliza como criterio la condición de que la cargabilidad de los equipamientos existentes haya alcanzado la capacidad FA (80% de la capacidad máxima). Por lo que, de acuerdo a la tabla 4.14 el transformador de potencia de la S/E Norte para el año 2031 no requerirá una ampliación de su capacidad, ya que este llegará a una cargabilidad de 76.3%.

Tabla 4.14 Resultados de cargabilidad, corriente máxima, pérdidas de potencia, y caídas de voltaje de la S/E Norte [E.P].

Año	Transformador de Potencia 10MVA/12.5MVA						Barraje 13.8 kV
	Pérdidas Totales [kW]	Corriente Máxima [A]	Cargabilidad [%]	S [MVA]	P [MW]	Caída de Voltaje [pu]	Vt [kV]
2022	36.6	243.2	57.8	5.84	5.37	0.05	13.76
2023	38.1	250.2	59.5	6.00	5.52	0.051	13.76
2024	39.8	257.9	61.2	6.18	5.69	0.053	13.75
2025	44.9	279.2	66.1	6.68	6.15	0.057	13.72
2026	46.7	286.5	67.8	6.86	6.31	0.058	13.71
2027	48.6	294	69.5	7.03	6.47	0.06	13.70
2028	50.6	301.3	71.2	7.20	6.62	0.061	13.69
2029	52.6	308.7	72.9	7.37	6.78	0.063	13.68
2030	54.6	316.1	74.6	7.54	6.94	0.064	13.67
2031	56.7	323.5	76.3	7.72	7.1	0.066	13.66




Figura 4.40 Corrientes máximas proyectadas S/E Norte periodo 2012-203 [E.P].

Las corrientes máximas proyectadas para el periodo de 2022-2031 no alcanzarán ningún valor de alarma ni de disparo. La corriente máxima para el año 2031 (323.5 A) estará al 72% del valor de la corriente de alarma. Estos resultados permiten saber que la S/E Norte no presenta ningún riesgo de disparo por sobrecarga en condiciones normales de operación.

4.4.3 Límites Térmicos de los A/P




Figura 4.41 Curva de Corriente Proyectada A/P Parque Industrial año 2031 [E.P].




Figura 4.42 Curva de Corriente Proyectada A/P Chuquiribamba año 2031 [E.P].




Figura 4.43 Curva de Corriente Proyectada A/P Chuquiribamba año 2031 [E.P].




Figura 4.44 Curva de Corriente Proyectada A/P Carigán año 2031 [E.P].

De acuerdo a los resultados de corrientes máximas proyectadas para los A/P de la S/E Norte, se determinó que para el año 2031 ningún A/P alcanza los límites térmicos,

corrientes de alarma ni de disparo. Cabe recalcar que los límites térmicos están establecidos por el conductor de menor calibre del tramo trifásico principal de cada alimentador.

De los resultados obtenidos se puede observar que los A/P Chuquiribamba y Carigán son los alimentadores que disponen de mayor holgura de corriente 27.68 (A) y 38.92 (A) respectivamente. Este comportamiento se da debido a que los dos alimentadores anteriormente mencionados, abastecen de energía eléctrica a sectores rurales y urbanos marginales donde el crecimiento de la demanda anual es mínimo.

Por otro lado, para el año 2031 los A/P Parque Industrial y Motupe tendrán valores de máximos de corriente de 117.86 (A) y 103.66 (A) respectivamente. Para ambos casos, el límite térmico es de 130 (A), por lo que el A/P Parque Industrial estará al 90.66% y el A/P Motupe al 79.74%. Es importante considerar que estos A/P abastecen a las principales cargas residenciales, comerciales e industriales del norte de la ciudad de Loja.

4.4.4 Caídas de Voltaje y Pérdidas de Potencia

Las caídas de voltaje para la barra de 13.8kV de la S/E Norte para el periodo de 2022-2031 no superan el límite inferior mínimo (6%) permitido por la regulación ARCERNNR 002/20. Cabe que destacar, que la S/E Norte se encuentra cerca de los puntos de entrega del SNI, por lo esto facilita su regulación de voltaje a nivel de 69kV.

Para el año 2031 de acuerdo a las demandas proyectadas se espera que, en la barra del devanado secundario del transformador de potencia se tenga un voltaje de 13.66 kV en condiciones de demanda máxima.

De acuerdo a la Tabla 4 de la NTC 380, que estipula los valores máximos permisibles de corrientes sin carga, pérdidas sin carga, pérdidas con carga y tensión de cortocircuito de Transformadores de Potencia Trifásicos en aceite de 15kV-46kV (primario) y 15kV (secundario); las pérdidas de potencia totales del transformador de potencia de la S/E Norte (56.7 kW) se encuentran dentro de los límites establecidos para el año 2031.




Figura 4.45 Caídas de Voltaje en pu barra 13.8kV S/E Norte periodo 2022-2031 [E.P].




Figura 4.46 Caídas de Voltaje en kV barra 13.8kV S/E Norte periodo 2022-2031 [E.P]




Figura 4.47 Pérdidas de Potencia del Transformador Potencia de la S/E Norte periodo 2022-2031[E.P]

CAPITULO 5

5. CONCLUSIONES

5.1 Conclusiones

- La aplicación de la presente metodología de LTLF es una alternativa que mejora sustancialmente los resultados de la proyección de la demanda. Ya que mediante métricas de estimación de error permite saber si el modelo utilizado es el más adecuado, y minimiza el error de pronóstico.
- El procedimiento de normalización de los registros históricos permite el descarte de valores aberrantes, y atípicos del comportamiento de la demanda eléctrica de los A/P. Por lo que, los criterios técnicos empleados para la depuración deben ser amplios, pero a su vez precisos con el fin de obtener una base de datos consolidada que únicamente incluya curvas de demanda diarias características.
- La aplicación del algoritmo GMM permitió encontrar las funciones de distribución con el mejor ajuste a la base datos depurada, y cuyos centroides representan los escenarios operativos de mayor representatividad probabilística.
- En los alimentadores de distribución en donde el crecimiento de la demanda eléctrica tiene un comportamiento vegetativo, y la carga es de tipo residencial, se determinó que el número óptimo de componentes de la función gaussiana mixta por cada año histórico es tres.
- Las curvas de demanda diaria del A/P Parque Industrial para el año 2020, tienen un comportamiento diferente en comparación a las del periodo 2012-2019 y 2021. Este comportamiento se debió, a que el año 2020 fue el pico de la pandemia por Covid-19, y gran parte de la población tuvo que encerrarse en sus hogares, y la actividad del sector productivo se vio disminuida. Por este motivo, los resultados obtenidos de la aplicación del algoritmo GMM para este año, no fueron tomados en cuenta para la proyección de la demanda futura del A/P Parque Industrial.
- De acuerdo a los resultados de la validación cruzada en una proporción 80:20 para datos de entrenamiento y prueba, se determinó que el modelo que presenta las mejores métricas de error es el modelo SARIMA. Ya que, para los A/P Parque

Industrial, Chuquiribamba y Motupe se obtuvo un MAPE inferior al 10%, y para el A/P Carigán alrededor del 12%.

- En alimentadores de distribución en donde la demanda eléctrica tiene un crecimiento vegetativo constante, el modelo SARIMA se ajusta de mejor manera a la base de datos, y permite que la proyección de la demanda sea más precisa y tenga una tendencia coherente.
- La proyección de la demanda del A/P Chuquiribamba que presenta un crecimiento casi estacionario hasta el 2031. Esto se debe a que durante el periodo 2012-2017 venía teniendo un aumento constante, y luego sufre una disminución abrupta, que provoca que el modelo obtenido mediante optimización del AIC, sea incorrecto.
- De acuerdo a los resultados de proyección de la demanda, la cargabilidad (76.4%) del transformador de potencia de la S/E Norte no requerirá la ampliación de su capacidad, ya que no se supera el 80% de la capacidad nominal. En cuanto a las caídas de voltaje y pérdidas de potencia para el año 2031 la S/E Norte se encontrará dentro de los límites establecidos por la regulación ARCERNR 002/20 y NTC-380 respectivamente.

5.2 Recomendaciones

De los resultados obtenidos se puede recomendar lo siguiente:

- Una adecuada estructuración y homologación del formato de los archivos extraídos del Sistema ADMS de la EERSSA, facilita considerablemente los tiempos de procesamiento y depuración de la base datos.
- Para la aplicación del algoritmo GMM a la base de datos de la S/E Norte se lo realizó de manera separada por cada A/P, ya que permite reducir los tiempos de procesamiento y recurso computacional.
- Al determinar los parámetros del modelo ARIMA de acuerdo a los resultados de las gráficas de autocorrelación parcial y autocorrelación, es preferible tener un criterio conservador para evitar el sobreajuste de parámetros.

REFERENCIAS


- [1] R. J. Hyndman and S. Fan, "Density forecasting for long-term peak electricity demand," *IEEE Trans. Power Syst.*, vol. 25, no. 2, pp. 1142–1153, 2010, doi: 10.1109/TPWRS.2009.2036017.
- [2] Willis, H. L., *Power Distribution Planning Reference Book*. CRC Press, 1997.
- [3] H. Seifi and M. S. Sepasian, *Electric Power System Planning: Issues, Algorithms and Solutions*. Springer Science and Business Media, 2011.
- [4] A. Chaturvedi, M. B. R. Murthy, R. Ranjan, and K. Prasad, "A Novel Scheme of Load Forecasting pertaining to long term Planning of a distribution system," in *TENCON 2005 - 2005 IEEE Region 10 Conference*, Melbourne, Australia, Nov. 2005, pp. 1–6. doi: 10.1109/TENCON.2005.301338.
- [5] E.-C. Yeh and H. Tram, "Information integration in computerized distribution system planning," *IEEE Trans. Power Syst.*, vol. 12, no. 2, pp. 1008–1013, May 1997, doi: 10.1109/59.589811.
- [6] M. Dong and L. Grumbach, "A Hybrid Distribution Feeder Long-Term Load Forecasting Method Based on Sequence Prediction," *IEEE Trans. Smart Grid*, vol. 11, no. 1, pp. 470–482, Jan. 2020, doi: 10.1109/TSG.2019.2924183.
- [7] A. K. Singh, Ibraheem, S. Khatoon, Md. Muazzam, and D. K. Chaturvedi, "Load forecasting techniques and methodologies: A review," in *2012 2nd International Conference on Power, Control and Embedded Systems*, Allahabad, Uttar Pradesh, India, Dec. 2012, pp. 1–10. doi: 10.1109/ICPCES.2012.6508132.
- [8] G. A. N. Mbamalu and M. E. El-Hawary, "Load forecasting via suboptimal seasonal autoregressive models and iteratively reweighted least squares estimation," *IEEE Trans. Power Syst.*, vol. 8, no. 1, pp. 343–348, Feb. 1993, doi: 10.1109/59.221222.
- [9] H. Al-Shaikh, Md. A. Rahman, and A. Zubair, "Short-Term Electric Demand Forecasting for Power Systems using Similar Months Approach based SARIMA," in *2019 IEEE International Conference on Power, Electrical, and Electronics and Industrial Applications (PEEIACON)*, Dhaka, Bangladesh, Nov. 2019, pp. 122–126. doi: 10.1109/PEEIACON48840.2019.9071939.
- [10] Liu, K. *et al.*, "Comparison of very short-term load forecasting." *IEEE Transactions on Power Systems*.
- [11] M. J. Damborg, M. A. El-Sharkawi, M. E. Aggoune, and R. J. Marks, "Potential of artificial neural networks in power system operation," in *IEEE International Symposium on Circuits and Systems*, New Orleans, LA, USA, 1990, pp. 2933–2937. doi: 10.1109/ISCAS.1990.112625.
- [12] H. Chen and L. Wu, "A new measure of forecast accuracy," in *2010 2nd IEEE International Conference on Information and Financial Engineering*, Chongqing, China, Sep. 2010, pp. 710–712. doi: 10.1109/ICIFE.2010.5609455.
- [13] U. Khair, H. Fahmi, S. A. Hakim, and R. Rahim, "Forecasting Error Calculation with Mean Absolute Deviation and Mean Absolute Percentage Error," *J. Phys. Conf. Ser.*, vol. 930, p. 012002, Dec. 2017, doi: 10.1088/1742-6596/930/1/012002.
- [14] T. Chai and R. R. Draxler, "Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature," *Geosci. Model Dev.*, vol. 7, no. 3, pp. 1247–1250, Jun. 2014, doi: 10.5194/gmd-7-1247-2014.

- [15] J. E. Díaz Pinzón, "Precisión del pronóstico de la propagación del COVID-19 en Colombia," *Rev. Repert. Med. Cir.*, May 2020, doi: 10.31260/RepertMedCir.01217372.1045.
- [16] D. Chicco, M. J. Warrens, and G. Jurman, "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation," *PeerJ Comput. Sci.*, vol. 7, p. e623, Jul. 2021, doi: 10.7717/peerj-cs.623.
- [17] J. Ding, V. Tarokh, and Y. Yang, "Bridging AIC and BIC: A New Criterion for Autoregression," *IEEE Trans. Inf. Theory*, vol. 64, no. 6, pp. 4024–4043, Jun. 2018, doi: 10.1109/TIT.2017.2717599.
- [18] X. Jing, C. Qinggui, Q. Haiqin, X. Zhenbo, and C. Na, "Assessment of aero-engine service reliability based on Akaike information criterion," in *2020 5th International Conference on Mechanical, Control and Computer Engineering (ICMCCE)*, Harbin, China, Dec. 2020, pp. 636–639. doi: 10.1109/ICMCCE51767.2020.00141.
- [19] Z. Lu and A. M. Zoubir, "Source enumeration using the pdf of sample eigenvalues via information theoretic criteria," in *2012 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Kyoto, Japan, Mar. 2012, pp. 3361–3364. doi: 10.1109/ICASSP.2012.6288636.
- [20] R. Singh, B. C. Pal, and R. A. Jabr, "Statistical Representation of Distribution System Loads Using Gaussian Mixture Model," *IEEE Trans. Power Syst.*, vol. 25, no. 1, pp. 29–37, Feb. 2010, doi: 10.1109/TPWRS.2009.2030271.
- [21] K. Goswami and A. B. Kandali, "Electricity Demand Prediction using Data Driven Forecasting Scheme: ARIMA and SARIMA for Real-Time Load Data of Assam," in *2020 International Conference on Computational Performance Evaluation (ComPE)*, Shillong, India, Jul. 2020, pp. 570–574. doi: 10.1109/ComPE49325.2020.9200031.
- [22] Y. Kareem and A. Majeed, "Monthly Peak-load Demand Forecasting for Sulaimany Governorate Using SARIMA.," in *2006 IEEE/PES Transmission & Distribution Conference and Exposition: Latin America*, Caracas, Venezuela, 2006, pp. 1–5. doi: 10.1109/TDCLA.2006.311383.
- [23] Y. Li, D. Han, and Z. Yan, "Long-term system load forecasting based on data-driven linear clustering method," *J. Mod. Power Syst. Clean Energy*, vol. 6, no. 2, pp. 306–316, Mar. 2018, doi: 10.1007/s40565-017-0288-x.


ANEXOS

ANEXO A.1


Curva de Demanda Histórica A/P Parque Industrial 2012




Curva de Demanda Histórica A/P Parque Industrial 2013




Curva de Demanda Histórica A/P Parque Industrial 2014




Curva de Demanda Histórica A/P Parque Industrial 2015




Curva de Demanda Histórica A/P Parque Industrial 2016




Curva de Demanda Histórica A/P Parque Industrial 2017




Curva de Demanda Histórica A/P Parque Industrial 2018




Curva de Demanda Histórica A/P Parque Industrial 2019



Curva de Demanda Histórica A/P Parque Industrial 2020




Curva de Demanda Histórica A/P Parque Industrial 2021




ANEXO A.2


Curva de Demanda Histórica A/P Chuquiribamba 2012




Curva de Demanda Histórica A/P Chuquiribamba 2013




Curva de Demanda Histórica A/P Chuquiribamba 2014




Curva de Demanda Histórica A/P Chuquiribamba 2015




Curva de Demanda Histórica A/P Chuquiribamba 2016




Curva de Demanda Histórica A/P Chuquiribamba 2017




Curva de Demanda Histórica A/P Chuquiribamba 2018




Curva de Demanda Histórica A/P Chuquiribamba 2019





Curva de Demanda Histórica A/P Chuquiribamba 2020




Curva de Demanda Histórica A/P Chuquiribamba 2021




ANEXO A.3




Curva de Demanda Histórica A/P Motupe 2014




Curva de Demanda Histórica A/P Motupe 2015




Curva de Demanda Histórica A/P Motupe 2016




Curva de Demanda Histórica A/P Motupe 2017




Curva de Demanda Histórica A/P Motupe 2018




Curva de Demanda Histórica A/P Motupe 2019





Curva de Demanda Histórica A/P Motupe 2020




Curva de Demanda Histórica A/P Motupe 2021




ANEXO A.4




Curva de Demanda Histórica A/P Carigán 2014




Curva de Demanda Histórica A/P Carigán 2015




Curva de Demanda Histórica A/P Carigán 2016




Curva de Demanda Histórica A/P Carigán 2017




Curva de Demanda Histórica A/P Carigán 2018




Curva de Demanda Histórica A/P Carigán 2019






Curva de Demanda Histórica A/P Carigán 2020









Curva de Demanda Histórica A/P Carigán 2021




ANEXO B.1










Distribución Predicciones GMM A/P Parque Industrial 2021




ANEXO B.2




Número Óptimo de Componentes para Demanda A/P Parque Industrial 2014




Número Óptimo de Componentes para Demanda A/P Parque Industrial 2015





Número Ótimo de Componentes para Demanda A/P Parque Industrial 2016




Número Ótimo de Componentes para Demanda A/P Parque Industrial 2017









Número Óptimo de Componentes para Demanda A/P Parque Industrial 2020






Número Óptimo de Componentes para Demanda A/P Parque Industrial 2021




ANEXO B.3







Distribución Predicciones GMM A/P Chuquiribamba 2018




Distribución Predicciones GMM A/P Chuquiribamba 2019





Distribución Predicciones GMM A/P Chuquiribamba 2020





Distribución Predicciones GMM A/P Chuquiribamba 2021




ANEXO B.4







Número Óptimo de Componentes para Demanda A/P Chuquiribamba 2016




Número Óptimo de Componentes para Demanda A/P Chuquiribamba 2017




Número Óptimo de Componentes para Demanda A/P Chuquiribamba 2018




Número Óptimo de Componentes para Demanda A/P Chuquiribamba 2019






Número Óptimo de Componentes para Demanda A/P Chuquiribamba 2020




Número Óptimo de Componentes para Demanda A/P Chuquiribamba 2021




ANEXO B.5




Distribución Predicciones GMM A/P Motupe 2015




Distribución Predicciones GMM A/P Motupe 2016



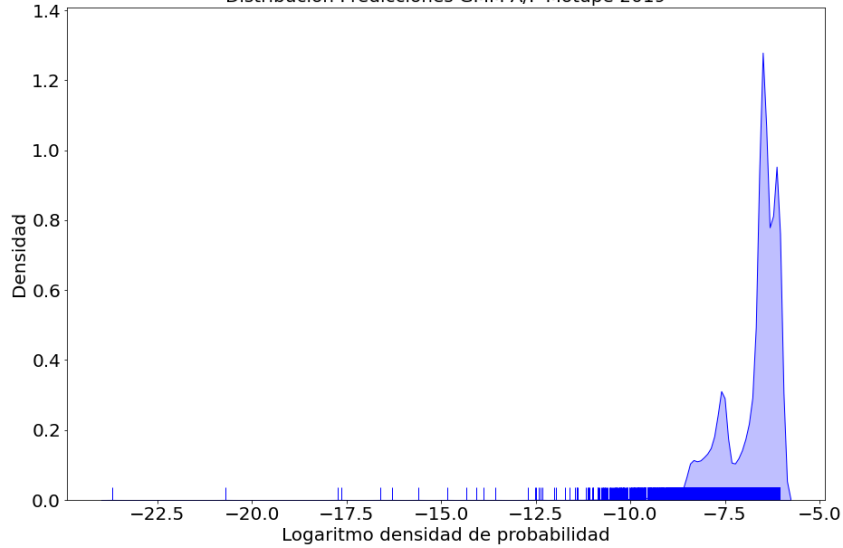
Distribución Predicciones GMM A/P Motupe 2017




Distribución Predicciones GMM A/P Motupe 2018




Distribución Predicciones GMM A/P Motupe 2019



Distribución Predicciones GMM A/P Motupe 2020




Distribución Predicciones GMM A/P Motupe 2021




ANEXO B.6


Número Ótimo de Componentes para Demanda A/P Motupe 2013




Número Ótimo de Componentes para Demanda A/P Motupe 2014




Número Óptimo de Componentes para Demanda A/P Motupe 2015




Número Óptimo de Componentes para Demanda A/P Motupe 2016




Número Óptimo de Componentes para Demanda A/P Motupe 2017




Número Óptimo de Componentes para Demanda A/P Motupe 2018




Número Óptimo de Componentes para Demanda A/P Motupe 2019






Número Óptimo de Componentes para Demanda A/P Motupe 2020




Número Óptimo de Componentes para Demanda A/P Motupe 2021




ANEXO B.7




Distribución Predicciones GMM A/P Carigán 2015






Distribución Predicciones GMM A/P Carigán 2016




Distribución Predicciones GMM A/P Carigán 2017






Distribución Predicciones GMM A/P Carigán 2021




ANEXO B.8


Número Óptimo de Componentes para Demanda A/P Carigán 2012




Número Óptimo de Componentes para Demanda A/P Carigán 2013




Número Óptimo de Componentes para Demanda A/P Carigán 2014




Número Óptimo de Componentes para Demanda A/P Carigán 2015




Número Óptimo de Componentes para Demanda A/P Carigán 2016




Número Óptimo de Componentes para Demanda A/P Carigán 2017




Número Óptimo de Componentes para Demanda A/P Carigán 2018




Número Óptimo de Componentes para Demanda A/P Carigán 2019



Número Óptimo de Componentes para Demanda A/P Carigán 2020



Número Óptimo de Componentes para Demanda A/P Carigán 2021



ANEXO B.9

Resultados Medias, Covarianzas y Pesos para el A/P Parque Industrial			
Año	Covarianzas	Pesos	Medias
2012	0.4148	2073.3701	529.6531
	0.4297	1821.7006	407.4166
	0.1555	4843.6328	739.3198
2013	0.4076	2499.3470	573.2329
	0.4270	2296.7052	443.2148
	0.1653	6348.7401	803.0980
2014	0.4577	3752.3300	496.9604
	0.1518	8991.0086	908.5522
	0.3905	4602.9991	660.1258
2015	0.0590	13212.7677	1371.3758
	0.3627	4121.7037	715.0157
	0.2784	7983.1128	958.4627
	0.3000	4171.3541	538.2740
2016	0.4368	6218.9707	978.8564
	0.1668	15984.8569	1375.3721
	0.3964	6306.6629	753.5264
2017	0.4252	5694.0975	1014.1733
	0.4079	6755.3950	776.1097
	0.1669	17063.2347	1410.6398
2018	0.1628	16195.2900	1451.8162
	0.4377	6009.7913	1046.9638
	0.3995	6821.7471	804.8637
2019	0.4412	6806.0376	1096.6795
	0.4063	8333.9632	845.4147
	0.1525	12268.7932	1458.6331
2020	0.0959	1298.2210	1014.5320
	0.0657	2155.2267	1369.5230
	0.0953	1423.6351	734.3288
	0.0567	2885.2787	1644.2707
	0.1022	1175.6928	1111.6934
	0.1611	1035.3774	843.3947
	0.1180	1151.0638	1270.4268
	0.0495	3066.6123	1506.9274
	0.1069	1287.2550	926.8209
	0.0152	14737.4907	636.9379
	0.0021	14884.5356	2044.8646
2021	0.1314	960.3286	1191.9321
	0.2174	2432.8942	1265.2239

	0.1908	1521.8929	876.6013
	0.0939	6493.3278	1626.0059
	0.1133	3036.6547	1143.9626
	0.1260	3771.9218	1384.3845
	0.1120	2269.1929	750.6004
	0.1428	2420.1951	991.1161
	0.0038	5039.8949	399.1284

Resultados Medias, Covarianzas y Pesos para el A/P Chuquiribamba			
Año	Covarianzas	Pesos	Medias
2012	0.2006	1311.5131	275.4415
	0.1190	1552.8446	428.2740
	0.6803	378.7592	208.5046
2013	0.1208	1827.4387	454.8454
	0.6839	346.4495	224.4488
	0.1953	1473.3400	294.9778
2014	0.6862	438.0752	234.9643
	0.1230	2062.9853	478.6399
	0.1909	1720.9188	312.4445
2015	0.6936	2077.2869	234.1844
	0.1752	3407.5567	282.5322
	0.1313	3131.1308	472.8359
2016	0.6568	664.7020	250.2849
	0.1187	2100.3635	502.4566
	0.1579	1960.3153	342.9644
	0.0667	2538.0296	110.6299
2017	0.1237	1748.9295	500.3155
	0.7042	493.7584	258.7909
	0.1721	1833.1230	342.1110
2018	0.7079	683.7609	263.7666
	0.1174	1400.7058	503.9939
	0.1746	2022.8873	352.1996
2019	0.3908	218.6234	254.7078
	0.1254	1206.0593	371.4876
	0.3703	345.7506	294.9610
	0.1135	860.5961	482.3201
2020	0.1409	1522.5743	345.3901
	0.1471	1509.6012	480.2075
	0.7119	417.7485	286.6448
2021	0.7074	390.6505	300.2081
	0.1483	1253.9509	483.4483
	0.1443	1436.7202	356.9053

Resultados Medias, Covarianzas y Pesos para el A/P Motupe			
Año	Covarianzas	Pesos	Medias
2012	0.5918	5356.1453	948.3653
	0.2372	1482.3684	753.5235
	0.1710	13703.6428	1350.5514
2013	0.3128	4356.5831	794.3940
	0.1665	13543.5625	1409.6645
	0.5207	5408.8717	1007.4281
2014	0.5271	5634.1723	1042.9977
	0.1730	16685.8557	1476.0891
	0.3000	3370.4057	835.2330
2015	0.2510	2314.8879	848.1007
	0.1689	15887.7193	1537.3481
	0.5801	7482.9017	1082.8505
2016	0.2366	4783.5829	1178.8893
	0.2804	3772.9951	877.4499
	0.1626	15311.0275	1579.2499
	0.3205	3829.2550	1073.3280
2017	0.2933	4420.6348	930.8253
	0.1698	16369.3664	1616.7379
	0.5369	5859.4889	1156.1931
2018	0.2954	5369.7289	964.1698
	0.1664	15353.2586	1652.6976
	0.5382	5950.1729	1190.0262
2019	0.1582	13197.8930	1740.1610
	0.3233	4366.8461	1238.0107
	0.2231	5913.9038	1369.1865
	0.2954	6092.1428	1051.4461
2020	0.4563	9550.5672	1350.7078
	0.3842	8723.8500	1036.3018
	0.1595	21678.8946	1758.7930
2021	0.3640	7515.0744	1104.0292
	0.4776	10543.3116	1420.9178
	0.1584	12438.8493	1826.2023

Resultados Medias, Covarianzas y Pesos para el A/P Carigán			
Año	Covarianzas	Pesos	Medias
2012	0.7410	343.9492	151.4179
	0.2590	668.6199	218.0101
2013	0.2963	2220.4809	234.9958
	0.7037	549.8847	165.9202
2014	0.7708	480.1657	182.4976
	0.2292	963.4200	269.4508
2015	0.6825	754.6431	194.8816
	0.3175	2607.3288	289.3019
2016	0.3158	2549.8182	291.3519
	0.6842	771.3011	204.0228
2017	0.3039	330.3643	217.2599
	0.1955	573.9613	270.0811
	0.0777	1981.1075	304.2734
	0.4229	329.9592	183.3812
	0.0493	1727.4111	344.3899
2018	0.3136	399.8346	231.8355
	0.4318	345.2934	194.3413
	0.2053	577.5292	287.6759
	0.4950	451.1130	300.9241
2019	0.1618	1383.2709	443.1215
	0.2447	687.4510	351.9514
	0.0986	984.1513	235.1660
	0.1925	2170.1784	439.6734
2020	0.0923	2.3401	6.2462
	0.7152	981.4040	312.9325
	0.0677	186.8516	455.8631
2021	0.1520	120.7911	332.5635
	0.0494	315.8250	535.8923
	0.1554	80.6613	378.7516
	0.0296	3214.8909	289.7365
	0.0608	244.9083	493.3681
	0.0915	119.0196	424.9258
	0.0896	294.7053	301.5589
	0.1605	85.4317	356.7132
	0.0249	970.0445	572.5417
	0.1186	82.6879	400.2111

ANEXO B.10

Selección Óptima de Componentes A/P Parque Industrial					
Caso 1			Caso 2		
Fecha	Nro. Comp	Demanda (kW)	Fecha	Nro. Comp	Demanda (kW)
2012-09-07 20:15:00	3	887.00	2012-12-19 20:00:00	5	932.00
2013-03-13 20:15:00	3	963.00	2013-11-18 20:00:00	5	1001.00
2014-11-17 20:15:00	3	1090.00	2014-11-25 20:00:00	5	1129.00
2015-11-11 20:00:00	4	1612.00	2015-11-25 19:29:00	5	1646.00
2016-11-07 21:15:00	3	1649.00	2016-01-13 21:00:00	5	1752.00
2017-11-10 20:00:00	3	1690.00	2017-06-30 10:29:00	5	1797.00
2018-09-17 20:45:00	3	1667.00	2018-04-17 21:45:00	5	1738.00
2019-09-30 20:00:00	3	1731.14	2019-08-30 14:45:00	5	1784.06
2020-06-05 20:45:00	12	1946.67	2020-06-04 19:15:00	11	2287.88
2021-08-03 20:15:00	8	1807.00	2021-03-15 09:45:00	11	1841.39

Selección Óptima de Componentes A/P Chuquiribamba					
Caso 1			Caso 2		
Fecha	Nro. Comp	Demanda (kW)	Fecha	Nro. Comp	Demanda (kW)
2012-12-31 20:30:00	3	510.00	2012-12-31 20:00:00	5	527.00
2013-10-20 19:45:00	3	543.00	2013-12-31 19:15:00	5	563.00
2014-10-27 19:30:00	3	573.00	2014-12-31 20:45:00	5	592.00
2015-10-09 20:15:00	4	550.00	2015-12-31 20:45:00	5	606.00
2016-08-17 19:15:00	3	602.00	2016-12-31 20:15:00	5	611.00
2017-02-28 19:45:00	3	598.00	2017-02-25 19:15:00	5	627.00
2018-09-27 19:45:00	3	554.00	2018-10-02 19:00:00	5	570.00
2019-12-31 19:15:00	3	575.85	2019-12-31 19:15:00	5	575.85
2020-11-26 19:00:00	12	572.12	2020-05-14 19:00:00	11	586.31
2021-05-28 19:15:00	8	580.00	2021-07-22 19:30:00	11	594.00

Selección Óptima de Componentes A/P Motupe					
Caso 1			Caso 2		
Fecha	Nro. Comp	Demanda (kW)	Fecha	Nro. Comp	Demanda (kW)
2012-11-27 19:45:00	3	1607.00	2012-12-11 19:45:00	5	1648.00
2013-11-18 18:45:00	3	1691.00	2013-11-18 19:45:00	5	1701.00
2014-04-23 19:15:00	3	1765.00	2014-06-03 15:00:00	5	1788.00
2015-10-20 19:30:00	3	1835.00	2015-10-20 19:30:00	5	1835.00
2016-10-24 19:30:00	3	1816.00	2016-01-24 10:45:00	5	1880.00
2017-12-12 19:29:00	3	1906.00	2017-12-12 19:29:00	5	1906.00
2018-09-30 19:15:00	6	1954.00	2018-09-30 20:00:00	8	2008.00
2019-11-04 19:45:00	3	2048.03	2019-11-04 19:45:00	5	2048.03
2020-10-29 19:15:00	8	2021.67	2020-12-30 18:45:00	11	3742.68
2021-10-26 19:15:00	3	2188.00	2021-10-26 19:15:00	5	2188.00

Selección Óptima de Componentes A/P Carigán					
Caso 1			Caso 2		
Fecha	Nro. Comp	Demanda (kW)	Fecha	Nro. Comp	Demanda (kW)
2012-12-31 19:30:00	2	261.00	2012-12-28 19:15:00	5	283.00
2013-12-28 20:45:00	2	281.00	2013-12-17 20:45:00	5	328.00
2014-12-30 20:15:00	2	323.00	2014-01-06 20:15:00	5	349.00
2015-12-17 20:00:00	2	347.00	2015-12-07 19:30:00	5	427.00
2016-11-04 20:00:00	2	349.00	2016-03-31 19:45:00	5	445.00
2017-12-06 20:00:00	4	346.00	2017-08-03 20:15:00	5	403.00
2018-10-19 20:45:00	4	370.00	2018-05-02 20:14:00	5	430.00
2019-05-08 20:15:00	4	534.09	2019-11-25 20:15:00	5	540.90
2020-09-10 20:45:00	3	527.73	2020-08-25 19:30:00	5	552.98
2021-10-14 18:45:00	11	676.00	2021-10-06 19:00:00	12	686.00

ANEXO B.10

