

ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL

Facultad de Ingeniería en Electricidad y Computación

Desarrollo de método por redes neuronales para proyección de demanda -
Caso de estudio SNI

PROYECTO INTEGRADOR

Previo la obtención del Título de:

Ingeniero en Electricidad

Presentado por:

Isaac Leonardo Gusqui Saltos

David Joel Rodas Herrera

GUAYAQUIL - ECUADOR

Año: 2022

AGRADECIMIENTOS

Mi más sincero agradecimiento a mi padre por la ayuda y paciencia que me ha dado, gracias a mi madre y hermana por el apoyo que me ha dado, gracias a los profesores, profesionales y tutor que nos ayudaron con la información necesario para completar este trabajo, por último, agradezco el apoyo que me dio mi pareja.

Isaac Gusqui

Agradezco a mis padres y amigos por la ayuda brindada y paciencia en cada momento durante mi vida académica. Gracias a los profesores, CENACE y tutor PhD. Manuel Álvarez por su ayuda prestada para completar este trabajo y el más importante va para Dios por siempre guiar mi camino.

David Rodas

DECLARACIÓN EXPRESA

"Los derechos de titularidad y explotación, nos corresponde conforme al reglamento de propiedad intelectual de la institución; Isaac Gusqui y David Rodas damos 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"



Isaac Gusqui Saltos



David Rodas Herrera

EVALUADORES

MSC. Ivan Endara Vélez

PROFESOR DE LA MATERIA

PhD. Manuel Álvarez Alvarado

PROFESOR TUTOR

RESUMEN

En distintas entidades de planificación se usan procesos anticuados, dejando los procesos sin muchas funcionalidades que aportan las nuevas tecnologías de programación. Los estudios de planificación se realizan en base a proyecciones realizadas con modelos econométricos, estos llegan a ser complejos. Este trabajo busca desarrollar un método con redes neuronales para la proyección de demanda potencias los estudios de planificación. El desarrollo empezó con el diseño de una red tipo MLP en el lenguaje de programación Python con una librería especializada en redes neuronales, la cual se entrenó con datos reales de demanda total de todas las unidades generadoras del Ecuador, después con la red entrenada se realizó una proyección hasta el 2029 que se usó como base para un estudio de confiabilidad de la generación del sistema nacional interconectado, teniendo presente las normas de CENACE con respecto a la reserva de generación. Los resultados mostraron una gran precisión de la proyección de los últimos meses del año 2022, y una confiabilidad alta usando el índice más representativo LOLE y a partir del año 2023 con la salida de servicio de COCA COCO SINCLAIR, el índice LOLE subió siendo mayor a su valor recomendado, por lo que es necesario tomar medidas preventivas ante posibles pérdidas de carga. El trabajo muestra la utilidad de las redes neuronales tipo MLP en la proyección de demanda a corto plazo para mejorarlas y dotarlas de funcionalidades.

Palabras Clave: Redes neuronales, proyección demanda, confiabilidad, LOLE, Monte Carlo no secuencial, MLP

ABSTRACT

In different planning entities outdated processes are used in which they are leaving the processes without many functionalities that new programming technologies provide. Planning studies are carried out based on projections made with econometric models becoming complex. This work seeks to develop a method with neural networks for the projection of demand that powers planning studies. The development began with the design of an MLP-type network in the Python programming language with a library specialized in neural networks, which was trained with real data of total demand from all the Ecuadorian generating units, then with the trained network it was carried out a projection until 2029 that was used as a basis for a reliability study of the generation of the national interconnected system, taking into account CENACE regulations regarding the 20% generation reserve. The results showed a great precision of the projection of the last months of the year 2022, and a high reliability using the most representative index LOLE. From year 2023 with the exit of service of COCA COCO SINCLAIR, the LOLE index was going up than its recommended value, so it is necessary to take preventive measures against possible load losses. The work shows the usefulness of MLP-type neural networks in the projection of short-term demand to improve them and provide them with functionalities.

Keywords: Neural Networks, Projection of demand, reliability, LOLE, non sequential Monte Carlo, MLP

ÍNDICE GENERAL

RESUMEN	i
ABSTRACT	ii
ÍNDICE GENERAL	iii
ABREVIATURAS	v
ÍNDICE DE FIGURAS	vi
ÍNDICE DE TABLAS	vii
CAPÍTULO 1	1
1. Introducción.....	1
1.1 Descripción del problema	1
1.2 Justificación del problema	2
1.3 Objetivos	3
1.3.1 Objetivo General.....	3
1.3.2 Objetivos Específicos.....	3
1.4 Series de tiempo	3
1.5 Proyección de demanda.....	4
1.5.1 ECUADOR: Metodología de la proyección de Demanda.	5
1.6 Redes neuronales	7
1.6.1 Modelo RNA MLP con algoritmo de retro propagación	9
1.6.2 Aplicación en la proyección de demanda	12
1.7 Confiabilidad	12
1.7.1 Modelo de Confiabilidad para la Evaluación de la Confiabilidad HL1	13
1.7.2 Técnica de Muestreo: Monte Carlo no secuencial.....	14
1.7.3 Índices de confiabilidad HL1	14
1.8 Proyección de la demanda vs confiabilidad del plan energético	15
CAPÍTULO 2	17
2. Metodología.....	17
2.1 Herramientas computacionales	18

2.2	Acondicionamiento de datos	18
2.3	Arquitectura de la red neuronal	19
2.3.1	Modelo Tendencia (Variables de entrada, capas y salida)	20
2.3.2	Modelo Estacionalidad (Variables de entrada, capas y salida).....	20
2.3.3	Modelo Residuo (Variables de entrada, capas y salida).....	20
2.4	Compilado de la RNA	20
2.5	Proyección de la demanda 2021-2025	22
2.6	Estudio de confiabilidad a nivel jerárquico HL1	23
2.6.1	Técnica de muestreo: Monte Carlo No secuencial	23
2.6.2	Índices de confiabilidad.....	24
CAPÍTULO 3		25
3.	Resultados Y ANÁLISIS	25
3.1	Descomposición de la demanda 2017-2022.....	25
3.2	Rendimiento RNA con distintitos pasos de días y conjunto de días.....	27
3.2.1	Numero de pasos 3	28
3.2.2	Número de pasos 6	29
3.2.3	Numero de pasos 13.....	30
3.2.4	Numero de pasos 28.....	31
3.3	Proyección sin considerando datos del 2020.....	32
3.4	Análisis de resultados proyección vs confiabilidad hasta finales de 2025....	33
CAPÍTULO 4		39
4.	Conclusiones Y Recomendaciones	39
	Conclusiones	39
	Recomendaciones	40
BIBLIOGRAFÍA		41
ANEXOS		43

ABREVIATURAS

ESPOL	Escuela Superior Politécnica del Litoral
RNA	Rede Neuronales Artificiales
MLP	Multi Layer Perceptron
CENACE	Operador Nacional De Electricidad
SNI	Sistema Nacional Interconectado
PME	Plan Maestro de Electricidad
CCS	Coca Codo Sinclair

ÍNDICE DE FIGURAS

Figura 1.1 Síntesis del proceso por CENACE en el PME para proyección de demanda (Ministerio de Energía y recursos no renovables, 2018).....	7
Figura 1.2 Arquitectura básica de una RNA	8
Figura 1.3 Modelo de Red Neuronal funciones y sus elementos. Obtenido de Fernando, L. 2016.....	11
Figura 3.1 Diferencial de crecimiento de la demanda.....	26
Figura 3.2 Descomposición temporal de la demanda 2017-2022.....	27
Figura 3.3 Resultados de proyección de demanda.....	29
Figura 3.4 Descomposición temporal 6 pasos.....	30
Figura 3.5 Descomposición temporal 13 pasos	31
Figura 3.6 Descomposición temporal 28 pasos	32
Figura 3.7 Descomposición temporal 6 pasos sin tomar año 2020 para análisis..	33
Figura 3.8 Curva de la demanda máxima proyectada vs la potencia efectiva menos el 20% de reserva	35
Figura 3.9 Curvas de los índices de confiabilidad a nivel jerárquico 1.	35
Figura 3.10 Curva Demanda Máxima vs Potencia efectiva menos 20% reserva (SIN CCS).....	37
Figura 3.11 Curvas de los índices de confiabilidad a nivel jerárquico 1 (SIN CCS).	38

ÍNDICE DE TABLAS

Tabla 1.1 Representa las características de los principales tipos de arquitectura de redes neuronales.	11
Tabla 1.2 Representa los índices de confiabilidad principales para el nivel jerárquico 1.....	14
Tabla 3.1 Resultados de precisión de los casos de estudio	28
Tabla 3.2 Datos de potencia efectiva total considerando 20% reserva vs Demanda máxima anual proyectada.....	34
Tabla 3.3 Datos de potencia efectiva total considerando 20% reserva vs Demanda máxima anual proyectada (SIN CCS).....	36

CAPÍTULO 1

1. INTRODUCCIÓN

A lo largo del tiempo la planificación de sistemas eléctricos de potencia ha conllevado a la aplicación de múltiples herramientas que permitan minimizar la cantidad de eventos fuera de lo normal o errores que provoquen una caída del sistema eléctrico parcial o en su totalidad.

En el Ecuador el organismo encargado de la planificación del sistema eléctrico es el CENACE [1] que elabora el denominado “Plan maestro de Electricidad”, documento el cual contiene una proyección del sistema eléctrico ecuatoriano tanto para generación, transmisión y distribución, para lo cual ha utilizado métodos lineales multivariados de predicción teniendo resultados con alta precisión.

Sin embargo, a medida que pasan los años y la tecnología revoluciona al mundo se han creado métodos computacionales basado en inteligencia artificial para la proyección de la demanda, estos nuevos métodos permiten minimizar tiempo y recursos, aumentar la precisión de la proyección, almacenar una inmensa cantidad de datos en cualquier temporalidad, autocorregir la proyección en cuestión de segundos con datos en tiempo real, este es el método de las redes neuronales artificiales aplicado al pronóstico de series de tiempo, aplicado por primera vez en 1964 por Jiang Hu [2].

El siguiente trabajo propone un método usando redes neuronales para simplificar el proceso de proyección de demanda. Como datos de entrada se tiene la generación hora-hora en el Ecuador desde el año 2017 al 2021, con estos datos la RNA va a ser entrenada para aprender y encontrar el patrón de consumo energético en el Ecuador. Se obtiene la proyección hasta el año 2029. Así se va a evaluar la confiabilidad de estudios de demanda y el plan de seguridad energética propuesto por el estado usando la proyección del CENACE dado en el plan maestro de electricidad.

1.1 Descripción del problema

El siguiente trabajo consiste en proponer un método inteligente que permita calcular la proyección de demanda eléctrica con una alta precisión debido a que antes se ha calculado la proyección mediante métodos estadísticos clásicos que involucran mucho tiempo y costos altos, y manejo de ecuaciones e inmensas cantidades de hoja electrónicas para poder calcular la proyección que para la aplicación en la electricidad es necesario garantizar la calidad y seguridad del suministro eléctrico a los usuarios, por esto en este trabajo se busca mejorar y facilitar la planificación de sistemas eléctrico de potencia de generación para lo cual se utiliza las redes neuronales artificiales como medio para la proyección de la demanda eléctrica.

1.2 Justificación del problema

La proyección de demanda realizada por el CENACE [1] para realizar el plan maestro electricidad es hecho empleando métodos econométricos lineales en algoritmos que usan datos históricos del perfil del Ecuador y distintas variables económicas para realizar la planificación de estrategias de seguridad energética en el SNI. Los métodos econométricos resultan complejos de ejecutar por la cantidad de variables y procesos usadas para el estudio, sumado a tiempos largos de estudio, resultan en un método pesado para los analistas. Visto las desventajas de los modelos econométricos se contempla la opción de aplicar las redes neuronales en la proyección de demanda. Las redes neuronales artificiales (RNAs) aportaran con una actualización de los procesos de estimación a nuevas tecnologías, como también reducir los recursos usados para el estudio, menor complejidad y estimaciones con la misma exactitud de los métodos clásicos, o incluso mejores. Las RNAs tienen como principal característica aprender comportamientos no lineales a medida que se ingresan datos, esto, en adición gran cantidad de funcionalidades que ofrece la ciencia de programación, les da la capacidad realizar proyecciones de demanda en tiempo real, dando la oportunidad de autoajustases a medida que ingresan los datos nuevos.

1.3 Objetivos

1.3.1 Objetivo General

Desarrollar un método de proyección de demanda utilizando redes neuronales para el mejoramiento de estudios de planificación y la confiabilidad a nivel de Generación del SNI.

1.3.2 Objetivos Específicos

1. Desarrollar una RNA de tipo perceptrón multicapa utilizado con algoritmo de aprendizaje de retro propagación a través de la selección de parámetros tratables para la estimación de la demanda eléctrica.
2. Entrenar la red neuronal a través de datos históricos de demanda hora-hora eléctrico del Ecuador desde el 2017 a 2022 para la proyección hora-hora de la demanda hasta el año 2025 y planificación de generación eléctrica del SNI.
3. Cuantificar la confiabilidad de la generación eléctrica del SNI a través de los indicadores de confiabilidad del nivel jerárquico uno tomando como proyección la realizada con la RNA propuesta en este documento.

1.4 Series de tiempo

Las series de tiempo se definen como un conjunto de observaciones tomadas en una secuencia de tiempo ordenada. El contar con una secuencia ordenada en el tiempo las dota de la característica que el comportamiento de las mediciones estará relacionadas a valores pasados cercanos, por lo que es posible antelar cierto calor conociendo los valores pasados. Para conocer los valores futuros es necesario comprender las características temporales de la serie, estas características varían con el tiempo de maneras diferentes y pueden ser modelados a través de modelos estadísticos de correlación.

Las principales características se denominan tendencia, estacionalidad, y el residuo. La estacionalidad explica el comportamiento creciente de una serie de tiempo, esta se relación a fuerzas constante que afectan sobre la serie de tiempo, generando un crecimiento continuo. La estacionalidad está compuesta por dos partes explicando el

comportamiento cíclico de los datos durante los mismos meses a través de los años, y por otra parte también explicarían el comportamiento sin relación a las estaciones de cada año. Por último, tenemos el residuo que representa los datos que no presentan ninguna correlación con el tiempo y son datos aleatorios [3].

La serie de tiempo que caracteriza el consumo eléctrico en Ecuador presenta patrones observables por distintos métodos de reconocimiento. La tendencia del consumo está relacionado al crecimiento económico del país, factores demográficos y cobertura de viviendas, generando un comportamiento estocástico que crece a medida que pasa el tiempo. Los patrones de comportamiento presentes son de periodicidad determinada dictados por las condiciones climáticas del Ecuador y la cultura propia mostrándose en temporadas específicas. La última característica es una componente aleatoria que depende de los sucesos que puedan afectar el consumo eléctrico. El resultado es un grafica con un perfil de comportamiento cíclicos, permitiendo a las redes neuronales analizarlas y aprender sobre los patrones presentes, dando la posibilidad de construir una proyección a base de los comportamientos observados [3].

1.5 Proyección de demanda

La estimación del consumo eléctrico en tiempos futuros forma parte de la gestión del consumo eléctrico de un país, por esto son necesarias para desarrollar medidas para controlar la carga en el futuro y evitar desbalances entre la generación y carga. La estimación es sujeta a conjeturas hechas a base del análisis de datos cuantitativos antiguos, como de modelos estocásticos autorregresivos integrados de media móvil, donde se ve necesario realizar distintos procesos probabilísticos para encontrar la correlación de las variables y determinar los valores principales de la ecuación base de un modelo autorregresivo; no obstante, este método presenta una complejidad que nuevas tecnologías han logrado reducir [4].

El método usado para la proyección de demanda en el Ecuador es a través de mínimos cuadrados ordinarios, el cual requiere de un proceso de evaluación para observar si el comportamiento de la demanda es el justo para aplicar este método, que sumado a los posteriores análisis estadísticos conforman la complejidad de los métodos autorregresivos dejando que el análisis de un volumen alto de datos se complique. La estimación por método de mínimos cuadrados tiene como objetivo buscar una ecuación

descriptiva del comportamiento de una serie de tiempo a través de la reducción de la suma al cuadro del error en entre la ecuación y los puntos reales, con la ventaja de presenta buenos resultados al proyectar series no estacionales que crecen en tiempo como la demanda. En el plan maestro se describe la estructura de los mínimos cuadrados como una ecuación básica (1) de los modelos autorregresivo, donde se tienen como variables explicativas el PBI, población nacional, el ingreso per cápita, cantidad de viviendas en Ecuador y cantidad de viviendas con servicio eléctrico, también se tiene un término que describe el inicio de la coordenada y por último se agrega el error.

$$Y_t = \alpha + \beta * X_t + \varepsilon_t \quad (1)$$
$$\varepsilon_t = Y_t - \hat{Y}_t$$

Una vez definida las variables aplicativas, es necesario evaluar el modelo resultante para observar que la proyección de demanda se ajusta de buena manera a los valores históricos y determinar que las variables escogidas tienen buen nivel de confianza. Por último, se realiza un análisis para definir el alcance de dar con proyecciones acertadas.

1.5.1 ECUADOR: Metodología de la proyección de Demanda.

De acuerdo con el Plan maestro de electricidad dado por el CENACE [1] donde muestra la Planificación del sistema eléctrico de potencia del Ecuador. En el plan maestro de Electricidad "PME" capítulo 3 trata sobre el estudio de la demanda eléctrica en el Ecuador acorde a "La elaboración de un pronóstico de la evolución de la demanda con una visión integral, en la que se considera a más del crecimiento tendencial de la población y del consumo, el cambio de la matriz productiva, la incorporación de cargas singulares...".

Esto indica que se lleva a cabo la planificación del sistema eléctrico ecuatoriano mediante el impacto en el crecimiento tendencial en la demanda y actualización de la proyección de usuarios, potencia y energía para empresas distribuidoras, clasificado por grupos de consumo y por nivel de voltaje. Incluso para la realización de la proyección de la demanda considera los requerimientos de demanda de potencia y energía en el periodo de estudio teniendo en cuenta variables de crecimiento de tipo macroeconómico en un rango medio, mayor y menor.

Para la evolución de la demanda eléctrica en el PME se coloca la metodología aplicada la proyección de la demanda realizada por el CENACE [1], la cual se muestra en el esquema conceptual de manera resumida en el **Anexo 1**. En el PME se observan 3 pasos a llevar a cabo para la proyección de demanda, considerando estos pasos como hipótesis para mantener la proyección dentro de rangos de variación como margen de seguridad ya sea media, alto o bajo.

La primera hipótesis considera todas las variables necesarias para llevar el estudio del crecimiento de la demanda como datos macroeconómicos, demográficos y datos en base al número de usuarios y consumo de energía eléctrica por sectores. Estas variables necesarias permiten la proyección de la demanda por categorías y grupos de consumo, que en conjunto conllevan a la proyección de la demanda de clientes finales de empresas de distribución.

En base a esta última proyección permite crear estrategias de venta de energía de cada distribuidora y su proyección para el número de usuarios, la venta de energía y minimizar las pérdidas de energía, con esto se obtiene el requerimiento de energía y potencia tanto en barras de subestaciones de entrega y en los bornes de generación. Estos 2 datos son muy importantes para llevar a cabo el plan de expansión de generación y distribución eléctrica.

La segunda hipótesis conocida como caso base es una adición a la hipótesis 1, donde se agrega las cargas singulares que son aquellas actividades que permiten reducir el consumo eléctrico de industrias básicas (carga y consumo energético) y el programa del plan nacional de eficiencia energética del Ecuador "PLANEE" que tiene 2 programas que permiten reducir el consumo de energía, el primero es el programa de recambio de equipos de mayor consumo de uso residencial, donde se incluye el uso de la cocina de inducción y alumbrado público "AP" y el otro es el programa de implementación de la norma ISO 50001 en industrias energointensivas.

Como tercera y última hipótesis conocida como caso de matriz productiva, que es el resultado de la hipótesis 2 y de actividad a gran escala como la actividad minera, cemento, siderúrgica, petrolera, permite obtener la proyección de la demanda final

en las barras de subestaciones de entrega del sistema nacional de transmisión “SNT” y la proyección de la demanda en bornes de generación. A continuación, se muestra un resumen de las etapas funcionales del sector eléctrico para el estudio de proyección de la demanda eléctrica.

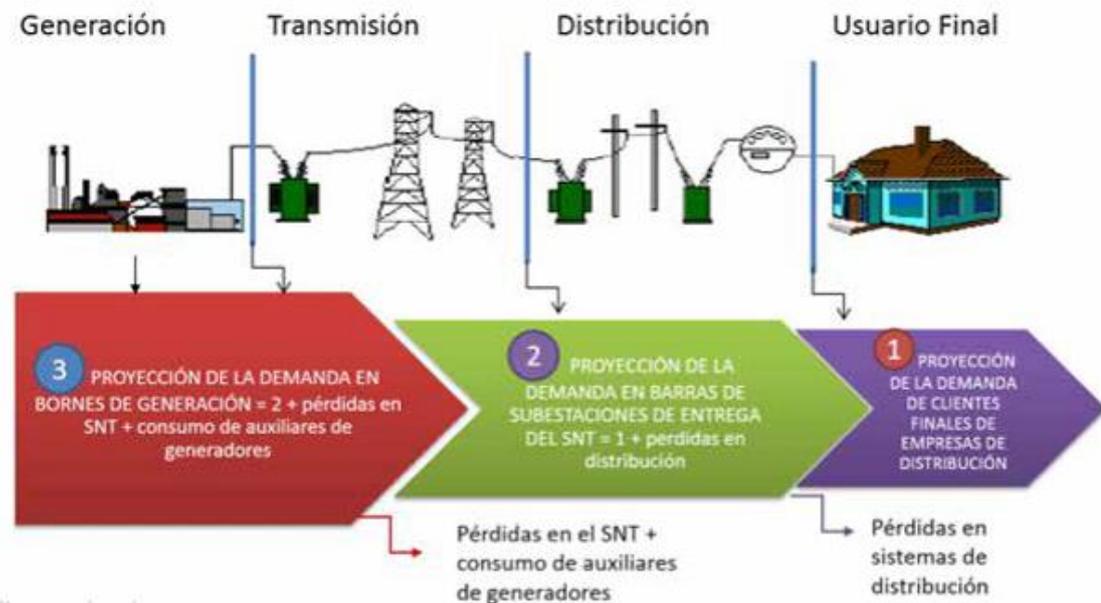


Figura 1.1 Síntesis del proceso por CENACE en el PME para proyección de demanda (Ministerio de Energía y recursos no renovables, 2018)

Para poder calcular la proyección de cada una de las variables mencionadas en las 3 hipótesis se realizaron distintos métodos de estimación y proyección, las cuales el PME menciona en el Apéndice A del Plan maestro de electrificación 2013-2022 [1]: “...La aplicación de los siguientes métodos en la estimación y proyección de la demanda de electricidad por uso del Ecuador como: Modelos econométricos, análisis de periodos anteriores, evolución tendencial e impulsores y esquemas analíticos”

1.6 Redes neuronales

Las redes neuronales son un conjunto de elementos sencillos que desempeñan procesos en paralelo con la capacidad de aplicar el conocimiento recolectado, por esto son útiles para resolver problemas complejos en distintas áreas multidisciplinarias de la actualidad; y gracias a estas características desarrolladas que son la base para la resolución de los retos del análisis de series de tiempo, se deben emplear para realizar proyecciones de la demanda eléctrica.

Una neurona artificial está basada en el comportamiento de una biológica, es decir, tener la función de recibir estímulos o entradas exteriores, estas entradas pasan por una zona de ponderación para atenuar o fortalecer las que se requieren para enviar una respuesta neta, para finalizar, la respuesta se envía a una función para evaluar la activación de la neurona y generar una salida que puede ser propagada a otras neuronas [5].

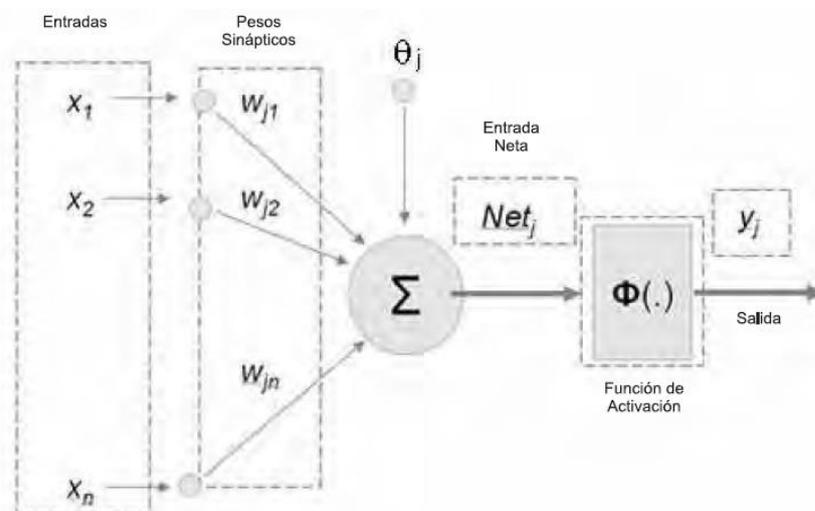


Figura 1.2 Arquitectura básica de una RNA

Las propiedades derivadas del comportamiento de una neurona biológica otorgan a las redes neuronales artificiales la capacidad de aprender patrones de comportamiento de un conjunto de datos, aun si no existe un modelo del comportamiento, y con este conocimiento adquirido poder usarlo en otras situaciones; por lo que son esenciales para realizar proyecciones de series de tiempo. Las capacidades son las siguientes; aprendizaje que permite aprender de los patrones de la demanda eléctrica y poder adaptarse a patrones diferentes que aparezcan a lo largo del tiempo; preselección de información esencial para descartar información que no es útil, optimizando los recursos de cómputo; segregación de información en grupos específicos; adaptación de la red a distintos problemas que se presenten para entregar el mejor desempeño; como parte final tenemos el funcionamiento en tiempo real, la combinación de hardware y software orientados a las redes neuronales permiten el procesamiento de información en tiempo real [5].

Los diferentes algoritmos de redes neuronales que se han desarrollado a lo largo de la historia han mejorado el rendimiento de las redes neurales artificiales para resolver problemas de alta complejidad, llegando a ser algoritmos de gran potencial. Entre los

algoritmos desarrollados encontramos: El Perceptrón, algoritmo poco desarrollado con una sola capa de neuronas, dando como resultado en una red neuronal poco funcional ante problemas no lineales; la red ADALINE, algoritmo que presenta rasgos parecidos con redes líneas, pero con una función de respuesta lineal y un método de aprendizaje basado gradiente descendiente; y al final el algoritmo de aprendizaje retro propagación logra resolver problemas complejos como consecuencia de innovar al aumentar la cantidad de capas de neuronas, y como aporte principal un método para entrenar una red a través de la regresión del error de las salidas hacia las capas anterior de neuronas para modificar las características de la red neuronal y mejorar su desempeño.

1.6.1 Modelo RNA MLP con algoritmo de retro propagación

El modelo de red neuronal retro propagación se denomina así debido a su algoritmo de aprendizaje supervisado; ésta emplea un ciclo de propagación-adaptación de dos fases. Al aplicar un patrón de entrada como respuesta al estímulo, éste se propaga por la primera capa hasta las capas superiores de la red y así hasta generar una salida. La señal de salida se compara con la salida deseada y se calcula una señal de error por cada una de las salidas, y este error se propaga de nuevo hacia las capas de entrada para actualizar los pesos sinápticos de cada capa [6].

Un modelo de una red neuronal artificial con retro propagación se aprecia en la siguiente imagen, donde tiene 3 capas con 3 redes perceptrón en cascada, una por capa y su salida de la red se encuentra embebida en la última capa [6].

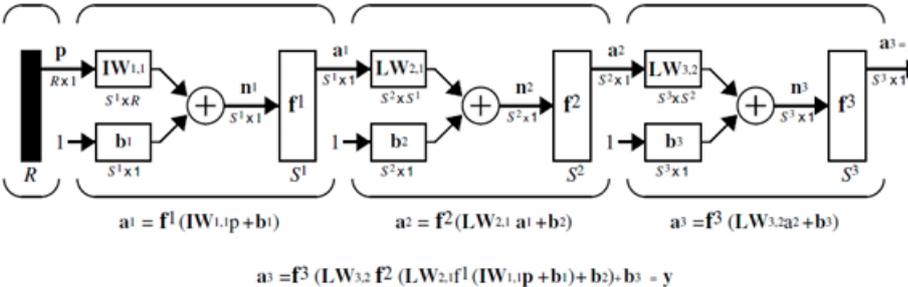


Figura 1.3 Modelo RNA de Retro propagación

Esta construcción de BP es adecuada para encontrar relaciones entre patrones de entrada y salida independientemente de las variables de tiempo, pero esto no

impide su uso en problemas de pronóstico de series de tiempo. Para datos anuales, se considera el uso de pronósticos en un paso de tiempo [6].

Para que se analicen los datos mensuales, considere usar el pronóstico de pasos de tiempo múltiple para observar una ventana deslizante entre los datos de entrada y salida y pronosticar una secuencia de comportamiento más allá del momento más reciente, o en un futuro lejano [6].

Para esta representación se establece la configuración de red neuronal artificial de retro propagación con retardo de tiempo TDNN, en la cual se establece el retardo entre la entrada y la primera capa de la red.

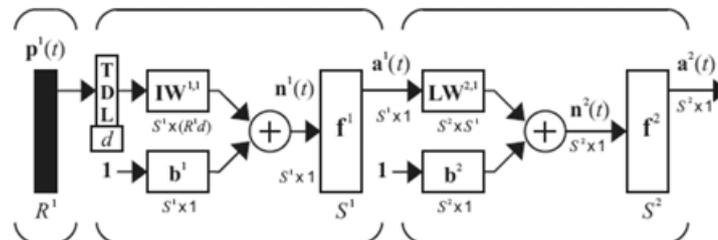


Figura 1.4 Modelo RNA de Retro propagación con retardo de tiempo

Con esto se puede determinar una red neuronal conociendo cómo funcionan los elementos dentro de la misma red neuronal. A continuación, se muestra una tabla con los elementos del modelo neuronal.

Modelo Neuronal	Elementos
Entrada	Analogicas, Digitales
Regla de propagación	Suma Ponderada, Distancia Euclidea
Función de activación	Puede depender del estado anterior y potencial postsinaptico. $a_i(t) = f_i[a_i(t - 1), h_i(t)]$ O solo postsinaptico. $a_i(t) = f_i[h_i(t)]$, donde las funciones más utilizadas son: Identidad, Escalón, Linea, Lineal por intervalo, sigmoidad, tansig, gaussiana.
Función de salida	Pueden ser las funciones identidad, escalón, estocástica, pero normalmente se utiliza la función identidad.
Pesos sinápticos	Exitadoras, Inhibidoras
Algoritmo de aprendizaje (Criterio de optimización)	Pueden ser mediante: Corrección de error, Boltzman, Ley Efectos de Thorndike, Regla de Hebb (Delta), Competitivo.
Métodos de solución al problema de optimización	Del Gradiente descendiente, De newton, De Gauss Seidel, De Mínimos Cuadrados, Levenberg-Marquard.
Paradigma de aprendizaje	Supervisado, Por reforzamiento, No supervisado, Hibrido

Figura 1.3 Modelo de Red Neuronal funciones y sus elementos. Obtenido de Fernando, L. 2016

Con base a estos elementos necesarios e indispensables en una red neuronal, en este caso se utiliza la entrada con datos de tipo real o digital, para lo cual existen 2 modelos de redes neuronales ya explicadas anteriormente, siendo uno una actualización del otro. Para esto se presenta la siguiente tabla con las características de ambos tipos de red neuronal.

Tabla 1.1 Representa las características de los principales tipos de arquitectura de redes neuronales.

RED NEURONAL ARTIFICIAL		
Característica	Retro propagación BP	Retardo de Tiempo TDNN
Entrada	Real	Real
Regla de propagación	Suma ponderada	Suma ponderada
Función de activación	Continua	Continua
Función de salida	Identidad	Identidad
Salida	Real	Real

Algoritmo aprendizaje	Regla delta generalizada	Regla delta generalizada
Método solución	Gradiente descendiente	Gradiente descendiente
Paradigma de aprendizaje	Supervisado	Supervisado
Numero de capas	Multicapa	Multicapa
Flujo de datos	Unidireccional	Unidireccional
Actualización estado	Síncrona	Síncrona
Tipo	Estática	Dinámica

1.6.2 Aplicación en la proyección de demanda

En tiempos actuales la aplicación de redes neuronales para la proyección de demanda ha sido tratado en varios artículos de investigación, en consecuencia, hay suficientes estudios que respaldan la idea de utilizar redes neuronales en la proyección de demanda eléctrica antes que métodos clásicos de econometría. Encontramos dos principales artículos que son bases de este trabajo. El primero, “Pronóstico de demanda por medio de redes neuronales artificiales” [6] que aporta con una metodología para encontrar la mejor selección del algoritmo de una red neuronal para la proyección de demanda; y el segundo “Series Temporales Avanzadas: Aplicación de Redes Neuronales para el Pronóstico de Series de Tiempo” [12], que muestra una comparación entre métodos clásicos de econometría y red neuronal para la proyección de demanda.

1.7 Confiabilidad

La gestión de demanda eléctrica es necesaria para la correcta planificación del sistema de potencia y mantener una buena confiabilidad del sistema presente, como en periodos de tiempos futuros. Álvarez M. [7] describe la confiabilidad en un sistema de potencia como la adecuación y la seguridad. La adecuación se describe como una adecuada manera de entregar la energía eléctrica a una carga, cuando se tienen eventos que condicionan la operación de un sistema de potencia. La adecuación muestra la importancia en la relación entre la demanda eléctrica de un país y su planificación energética para ofrecer un buen servicio. Por otro lado, para complementar la confiabilidad tenemos la seguridad que es descrita como la capacidad de un sistema eléctrico para lidiar con eventos que generan transitorios sobre su operación.

La confiabilidad de un sistema de potencia puede ser estudiado de manera numérica a través de las características operativa de los componentes del sistema. Para este análisis tenemos dos principales vías para desarrollar un estudio de confiabilidad: a través de métodos probabilísticos y analíticos. Los métodos en general siguen un esquema que busca analizar el histórico del funcionamiento de los componentes del sistema de potencia, como comportamientos pasados, para realizar medidas preventivas de posibles eventos que afecten la entrega de energía eléctrica a las cargas [7].

Para la evaluación de la adecuación de un sistema de potencia se tiene diversos niveles jerárquicos basado en la evaluación por partes del sistema de potencia. El primer nivel jerárquico conocido como Generación, valora la habilidad de la generación total del sistema para cumplir con lo que requiere la demanda total del sistema, es decir solo analiza la generación y la carga totales que pasa por una barra común. El segundo nivel jerárquico en cambio valora la habilidad del sistema de generación–transmisión para poder satisfacer la demanda en los puntos principales de carga por medio de un esquema existente y el impacto de esquemas de expansión. El tercer nivel jerárquico evalúa la adecuación en los principales puntos de carga ubicados en los circuitos primarios de distribución [7].

1.7.1 Modelo de Confiabilidad para la Evaluación de la Confiabilidad HL1

Para la evaluación de confiabilidad a nivel jerárquico 1 se necesita conocer la confiabilidad de las unidades generadoras en términos de indisponibilidad más conocido como tasa de interrupción forzada FOR, tasas de falla y tasa de reparación.

1.7.1.1 Método de muestreo de duración de estado para adecuación de la generación

Para la realización del muestro para el nivel jerárquico 1 requiere de 3 pasos importantes.

1. Generar historiales de operación de cada unidad generadora mediante los valores de tiempo de falla y tiempo de reparación de la unidad durante el año de estudio
2. La capacidad disponible del sistema se obtiene combinando el ciclo operativo de todas las unidades generadoras, luego junto con la curva de carga horaria se obtiene el margen disponible del sistema, donde un margen positivo indica que el sistema de generación es suficientemente capaz de satisfacer la demanda, mientras que un margen negativo implica que la carga del sistema debe reducirse.
3. Se calculan los índices de confiabilidad HL1

1.7.2 Técnica de Muestreo: Monte Carlo no secuencial

El método de Monte Carlo es aplicado a los sistemas de potencia para determinar el estado en que se encuentre cada componente para el periodo de análisis (anual). El proceso comienza con la generación de números aleatorios entre cero y uno para cada componente del sistema de potencia, donde el cero representa que no está en servicio y uno que representa que la generadora está en servicio. Luego continúa con el cálculo de la esperanza matemática de cada estado del sistema y esto se repite para el número de experimentos. Finalmente, el proceso converge con la determinación de la media de la muestra.

1.7.3 Índices de confiabilidad HL1

Para el desarrollo de este trabajo se utilizará los principales índices de confiabilidad HL1, mostrados en la siguiente tabla.

Tabla 1.2 Representa los índices de confiabilidad principales para el nivel jerárquico 1

Índices de Confiabilidad principales para HL1		
Índice	Descripción	Fórmula

LOLE	(Lost Of Load Expectation) Esperanza de pérdida de carga, mide el número esperado de períodos por tiempo de estudio donde no existirá reserva para atender un crecimiento de la demanda.	$LOLE = \frac{1}{NE} \sum_{i=1}^{NE} (LLDi)$ <p><i>NE = número de experimentos</i> <i>LLDi = tiempo de pérdida de carga</i></p>
LOLP	(Lost of Load Probabilty) Probabilidad de pérdida de carga, mide la probabilidad que la demanda sea mayor a la capacidad de generación disponible.	$LOLP = \frac{LOLE}{T}$ <p><i>T = tiempo de estudio</i></p>
EENS	(Expected Energy Not Supplied), es el valor anual esperado de energía no suministrada.	$EENS = \frac{1}{NE} \sum_{i=1}^{NE} (ENSi)$ <p><i>ENS = energía no suplida</i></p>
XLOL	Es el porcentaje entre la energía no suplida EENS y LOLE	$XLOL = \frac{EENS}{LOLE}$

1.8 Proyección de la demanda vs confiabilidad del plan energético

La proyección de demanda va a permitir crear estrategias para mantener un nivel alto de confiabilidad de un sistema de potencia, así como optimizar los costos de un plan energético. Un plan energético es una guía para las decisiones que se deben tomar sobre la inversión en nuevas generadoras, estrategias para controlar la demanda, e inversión en fuentes primarias, con el objetivo de suplir en todo momento la demanda, pero optimizando los recursos económicos y manteniendo una seguridad energética robusta.

La generación esperada para suplir la demanda repercutirá sobre la confiabilidad del sistema de potencia. Las estrategias para enfrentar las indisponibilidades de los componentes, que son agregados para suplir las nuevas cargas, condicionan el sistema agregando nuevas tasas de fallos, cambios en la planificación de unidades de generación, nuevas tasas de mantenimiento, entre otros factores que afectarán los principales índices de confiabilidad. Por otro lado, tenemos que las proyecciones realizadas determinan la cantidad de reservas que serán necesarias para mantener un constante suministro de energía, aun si se tiene eventos de indisponibilidad [1].

El sobredimensionamiento de los componentes del sistema de potencia permitirá mantener una confiabilidad alta y mantener la seguridad energética del plan, pero aumentará el costo del plan. Así el principal impacto un sobredimensionamiento realizado por una proyección con valores mayores a los reales resultara en un mayor costo de inversión en energía eléctrica no consumida, en caso contrario un dimensionamiento inferior al real generaría un desfalco en la energía eléctrica que se entrega, causando la toma de medidas emergentes para suplir la nueva carga.

CAPÍTULO 2

2. METODOLOGÍA

En Ecuador la empresa encargada de la planificación de la generación del SNI, CENACE, realiza su planificación en base a una proyección de demanda realizada con métodos econométricos multivariados, en otras palabras, usan métodos anticuados. Se precisa la necesidad de desarrollar un nuevo método para la proyección de demanda utilizando tecnologías de programación actuales para agilizar y dotar de funcionalidades que dinamicen el análisis de la confiabilidad, nivel jerárquico uno, del sistema de generación del SNI.

La metodología usada para desarrollar un método de proyección de demanda con un rendimiento alto empezó con la búsqueda de la tecnología más adecuada para el problema, después se pasó a realizar pruebas con datos reales de consumo total de las empresas eléctricas distribuidoras del Ecuador en el periodo 2017-2022, por último, se realizó un análisis de confiabilidad con la proyección realizada con nuestro método. La validación con el 30% de los datos de consumo del año 2022 tienen como fin verificar la precisión y rendimiento del modelo de la arquitectura interna de la RNA.

La tecnología para la proyección que se escogió entre las alternativas que ofrece la ciencia de la programación es la RNAs programadas en el lenguaje Python, además se hizo uso de la librería especializada para creación de RNAs llamada KERAS. Las RNA se escogió ya que en su literatura esta era la solución con mayor funcionalidad, mayor accesibilidad, baja complejidad para aprenderla, lenguaje de programación básico, y sea aplicable a la proyección de series de tiempo, de modo que la solución era capaz de entregar proyecciones con alta precisión y pueda ser aplicado en cualquier lugar con herramientas al alcance de cualquier empresa, sin necesidad de una inversión alta en recursos intelectuales o tecnológicos.

Para la confiabilidad se utilizaron los índices de confiabilidad a nivel jerárquico 1, puesto que este caso es Generación total vs Carga-Demanda total y para el muestreo de datos se utilizó la técnica de muestreo de Monte Carlo no secuencial para generación de números aleatorios para el estado de generación entre todas las unidades generadoras.

2.1 Herramientas computacionales

La RNA fue desarrollado en un ambiente de programación sencillo de comprender y con un lenguaje poco complejo e intuitivo, además todas las herramientas para el desarrollo de la RNA son de código abierto [10].

El ambiente usado para el desarrollo del método usa como lenguaje de programación base Python versión 3.7, y como entorno de desarrollo PyCharm. Entre las librerías usadas la más relevante es KERAS, una biblioteca especializada para el desarrollo de redes neuronales con la posibilidad de crear distintas arquitecturas, también se usaron otras librerías que se detallan a continuación.

- Keras 2.3.1
- graphviz 0.13
- matplotlib 3.5.3
- numpy 1.21.6
- pandas 1.3.5
- statsmodels 0.13.5
- tensorflow 2.1.0

2.2 Acondicionamiento de datos

Los datos de consumo se descompusieron en sus características temporales y se ingresaron a su respectivo modelo de RNA para el entrenamiento, estos se tuvieron que normalizar entre -0.90 y 0.90 con el objetivo de evitar que se sature la red con el aumento del consumo a través del tiempo, puesto que la función de activación de las neuronas solo toma valores entre 1 y - 1. Los datos con los que se va a entrenar la RNA son la demanda total en megavatios [MW] de todas las empresas eléctricas distribuidoras del Ecuador, estos datos son hora-hora del periodo 2017-2022. Los datos fueron proporcionados por CENACE a través del acuerdo de cooperación entre CENACE y ESPOL.

La RNA, no pudo analizar comportamientos crecientes, por lo que se descompusieron los datos de consumo en sus características temporales y creamos un modelo de RNA para cada característica temporal (tendencial, estacional, y residuo), esta descomposición se realizó a través de la librería *statsmodels*. La librería mencionada contenía funciones que permiten realizar análisis estadístico del comportamiento

temporal, siendo la función *seasonal_decompose* y un periodo de análisis de 8760 días, los usados para estudiar el comportamiento temporal la demanda en Ecuador. Como resultado del análisis se obtuvo la característica tendencial, estacional, y el residuo.

La característica tendencial necesito un ajuste adicional para que la red no se sature con el crecimiento de los valores. Como la tendencia de la demanda es creciente llegara un punto en el que la red se va a saturar, para evitar esto se restó cada demanda con la demanda de la siguiente hora. Con este proceso se obtiene el incremental en cada hora y el modelo solo analizaría como incrementa la demanda en cada hora. La característica estacional y el error no necesitaron un acondicionamiento adicional.

Los datos para el análisis de confiabilidad fueron las potencias efectivas de los generadores y horas de indisponibilidad, lo cuales también fueron proporcionados por CENACE para este proyecto. No se requirió un acondicionamiento para estos datos.

2.3 Arquitectura de la red neuronal

Las RNA presentan distintas arquitecturas para realizar proyecciones, por lo que se escogió la más general y básica para un fácil aprendizaje de su funcionamiento. La arquitectura fue basada en una red perceptrón multicapa o por sus siglas en inglés (MLP), este tipo de arquitectura es básica en el mundo de las RNAs, pero sumado a un algoritmo de aprendizaje por retro propagación se pudo crear un modelo capaz de reconocer el complejo comportamiento del consumo energético del Ecuador.

Los criterios usados para escoger la cantidad de neuronas y capas se basaron en la literatura revisada del libro mediante una aproximación practica a las redes neuronales, donde se recomendó una capa oculta por cada conjunto de variable de entrada. La cantidad de neuronas en las capas ocultas empezaron con la mitad de la cantidad de la capa de entrada y fueron aumentamos hasta encontrar la mejor precisión.

Los criterios mencionados permitieron crear el modelo del Anexo 2, este modelo fue la base para crear los modelos que iban a ser usados para analizar el incremental de la tendencia, la estacionalidad y el residuo de la demanda.

Las variables de entrada -día de la semana, día del año y mes- fueron usadas como variables categóricas. Las variables categóricas requerían pasar a una capa llamada embedding que permiten codificarlas para categorizarlas, luego a un simple redimensionamiento a 1D. La variable demanda dependerá de la característica temporal que se esté analizando.

2.3.1 Modelo Tendencia (Variables de entrada, capas y salida)

El modelo de tendencia sigue la arquitectura mostrada en la figura, pero la variable de demanda recibía los incrementales de la tendencia de cada una de las 24 horas de los 6 días anteriores al día de predicción, en otras palabras, recibía 144 datos. Estos datos ya fueron acondicionados y normalizados antes de ingresar a la red. Seguido a esto tenemos tres capas que representan una capa de entrada, oculta y salida.

En la última parte tenemos una capa oculta con la mitad de las neuronas de la capa que recolectaba todas las variables de entrada, para pasarlas a la última capa de salida que arrojará la información del incremental de cada una de las 24 horas del día que se va a predecir.

2.3.2 Modelo Estacionalidad (Variables de entrada, capas y salida)

El modelo de estacional no tuvo cambios en la arquitectura mostrada en la figura, pero la variable de demanda recibía solo la característica estacional de cada una de las 24 horas de los 6 días anteriores al día que se predecía. En la parte final la información sería de la característica estacional del día a predecir.

2.3.3 Modelo Residuo (Variables de entrada, capas y salida)

El modelo de estacional no tuvo cambios en la arquitectura mostrada en la figura, pero la variable de demanda recibía solo la característica residuo de cada una de las 24 horas de los 6 días anteriores al día que se predecía. En la parte final la información sería de la característica residuo del día a predecir.

2.4 Compilado de la RNA

La etapa de compilado correspondía al entrenamiento, retro propagación, y la validación de los tres modelos construidos. El entrenamiento se realizó con la función *fit()* de la

librería KERAS, el cual requirió especificar la cantidad de datos para el entrenamiento, las funciones de activación de las capas, la ecuación de error, un optimizador y la métrica que se usaría para medir el rendimiento de la red.

La función de activación tangente hiperbólico se escogió para las neuronas de todas las capas de los tres modelos, debido a que nuestros datos estarían entre 0.90 y -0.90; la función nos permite manejar valores entre 1 y -1.

Los datos que ingresan a los modelos se seccionaron entre datos de entrenamiento y validación, de modo que se tengan datos para validar la precisión de nuestro modelo con datos distintos a con los que se entrenó. El criterio para el porcentaje de separación se basó en la literatura que recomendaba un 70% para entrenamiento y 30% de validación, pero para cada modelo se cambió a través de prueba y error hasta obtener el mejor resultado. El modelo de tendencia se entrenó con el 80% de la componente tendencial de los datos de demanda hora-hora 2017-2022 y los datos restantes se usaron para la validación del modelo, modelo estacionalidad se entrenó con el 70% de la componente estacional de los datos de demanda hora-hora 2017-2022, y el modelo de residuo se entrenó con el 75% de la componente residual de los datos demanda hora-hora 2017-2022.

El optimizador es el mismo para los tres modelos, se escogió el gradiente descendiente (SGD) para buscar el mínimo de la función error y actualizar los pesos de las capas. El SGD es el optimizador más usado y básico que daba buenos resultados en tareas de reconocimientos de patrones, en adición no representa una carga computacional alta.

La función de error es diferente para cada modelo, gracias a que los datos que ingresaban a los modelos tenían distintos comportamientos, siendo el residuo y la estacionalidad con una varianza alta y dispersión. El residuo, al ser valores poco usuales en el comportamiento, tienen un comportamiento errático, por lo que se escogió el error absoluto medio para tratar de reducir los valores dispersos, ya que al estar elevado al cuadrado tendríamos un error alto que el optimizador debe reducir. La función huber loss fue seleccionada para el modelo tendencial, ya que esta función es parecida al error absoluto medio, pero con la ventaja de tener una condición que permite usar el error cuadrático medio cuando el error pasa un umbral prediseñado. Por último, el modelo estacional uso el error cuadrático medio ya que es el que mejor se ajusta al SGD.

La métrica usada es la precisión, así se podía observar que tan preciso son las predicciones de los modelos, esta métrica debía mantenerse por debajo de un 95 % y mayor a un 80% para que la RNA presente una buena generalización, la cual es la cualidad de generar buenas predicciones con valores diferentes. Además, con la métrica de precisión se revisó que la precisión de los datos de validación no sea mayor a la precisión de entrenamiento, ni muy menor, así descartábamos sobre-entrenamiento y sub-entrenamiento de la RNA.

Por último, se realizaron pruebas con distintas cantidades de días que entran como histórico a la red para realizar la predicción del siguiente día. Se tomo como paso tres, seis, trece, veinte y nueve, cincuenta y nueve. En cada prueba fue necesario cambiar la cantidad de neuronas para las capas ocultas, ya que deben ser el doble de la cantidad de datos hora-hora que entran.

2.5 Proyección de la demanda 2021-2025

Los modelos entregaban las predicciones de las características temporales de la demanda para un modelo aditivo, por lo tanto, para reconstruir la demanda proyectada había que sumar las características temporales de cada hora, pero los modelos tendencial y residuo requerirían un ajuste.

El modelo tendencial nos entrega el incremental de la demanda, por lo que es necesario sumar el valor anterior para obtener la predicción de la hora del día a predecir, además se multiplico los resultados por un factor para simular un aumento de la demanda menor o mayor al esperado, con el objetivo de analizar la confiabilidad del sistema bajo supuestos de un crecimiento de demanda fuertemente elevado o bajo al esperado.

El modelo residuo solo se multiplico un factor en 0 y 1 para disminuir el efecto del residuo en la proyección final, permitiendo obtener una curva más limpia sin efectos de los valores aberrantes del residuo, en este caso el factor que se escogió es 0.75 para reducir los valores aleatorios y obtener una curva limpia con el comportamiento de la demanda puro.

La curva proyectada de demanda se consiguió con la suma de los tres componentes en MW, las 3 componentes fueron obtenidas a través de los modelos entrenados usando la red neuronal de cada una de las componentes.

$$D_i = \sum_{i=1}^{NDP} CT \text{ en } MW_i * (F_1) + CE \text{ en } MW_i + CR \text{ en } MW_i * (F_2)$$

Donde: $CT =$ Componente tendencia, $CE =$ Componente estacionalidad,
 $CR =$ Componente residuo, $NDP =$ número de datos proyectados,
 $F_1 =$ Factor de crecimiento de tendencia,
 $F_2 =$ Factor de amortiguamiento del residuo

De esta ecuación anterior, se obtuvieron 35064 datos que consistieron en las horas proyectadas (NDP) desde el 01 de Enero del 2022 a las 00:00 en pasos de una hora hasta el 31 de Diciembre del 2025 a las 23:00, sabiendo que el 2024 es un año bisiesto.

2.6 Estudio de confiabilidad a nivel jerárquico HL1

Se escogió el nivel jerárquico HL1 porque este nivel analiza la confiabilidad de un sistema de potencia compuesto de una generación total que alimenta a una carga total (demanda) a través de una barra común, es decir solo importa que tan confiable es que la potencia llegue desde la generadora hasta la carga.

2.6.1 Técnica de muestreo: Monte Carlo No secuencial

Para la técnica de Monte Carlo se realizó un código de programación en Matlab R2021a con el siguiente pseudocódigo:

1. Procedimiento de Monte Carlo
2. For e=1 to NE (número de experimentos)
3. Aleatorizar los estados de todos los componentes: $Se = (S1, S2, \dots, Sn)$
4. Definir EXF y P
5. Evaluar EXF y P en Se
6. Determinar EXSe usando la ecuación $EXSe = EXF(Se) * P(Se)$, donde EXF y P representan la función del experimento y la probabilidad de función de evento
7. End For

8. Determinar EXS usando la ecuación $EXS = \frac{1}{NE} \sum_{e=1}^{NE} EXSe$

2.6.2 Índices de confiabilidad

Para la obtención de los índices de confiabilidad se realizó un modelo de confiabilidad de las unidades generadoras en términos de indisponibilidad conocido como tasa de interrupción forzada FOR o tasas de falla λ y tasa de reparación μ . Los datos obtenidos por CENACE para este caso fueron dados en términos de horas de indisponibilidad por falla por año MTTR para lo cual se consideró escoger el valor máximo de horas de indisponibilidad para obtener una confiabilidad más efectiva, y sobre la cual se le multiplicó por un factor debido a envejecimiento de las unidades del 5% para cada año, para lo que se realizó el siguiente cálculo:

$$MTTF = \text{Horas por año de estudio} - MTTR$$

$$\text{Tasa de falla } \lambda = \frac{1}{MTTF} \left[\frac{f}{h} \right]$$

Para la tasa de reparación de cada una de las unidades generadoras se realizó el siguiente cálculo:

$$\text{Tasa de reparacion } \mu = \frac{1}{MTTR} \left[\frac{r}{h} \right]$$

Con estos datos obtenidos se procedió a calcular el parámetro FOR, puesto que es un valor de entrada necesario para la determinación de los índices de confiabilidad mediante la siguiente formula:

$$FOR = \frac{\lambda}{\lambda + \mu}$$

Luego de esto, se aplicó el método de Monte Carlo no secuencial para la generación de números aleatorios entre el estado de unidades generadoras, y se obtuvo la generación de estado operacional, la generación disponible, la reserva de energía, la consecuencia de fallas y con estos datos los índices de probabilidad LOLE, LOLP, EENS, XLOL para cada año de proyección desde el 2022 hasta el 2025

CAPÍTULO 3

3. RESULTADOS Y ANÁLISIS

Los siguientes resultados se obtuvieron de las pruebas para obtener la RNA con mejor rendimiento, las pruebas realizadas se realizaron modificando la arquitectura, cantidad de días históricos para la proyección, cantidad de veces que pasaron todos los datos por la RNA, y ciertas variantes más. Con los datos proyectados de la demanda hora a hora, los datos de las capacidades efectivas en MW y las horas de indisponibilidad por falla por año de todas las unidades generadoras otorgados por CENACE se realizó el análisis de confiabilidad a nivel jerárquico 1 mediante la técnica de muestreo de Monte Carlo no secuencial, y así se obtuvieron los índices de confiabilidad para cada año y se tuvo en cuenta que desde el 2023 la Central Coca Codo Sinclair no entrará más en servicio debido a la gran cantidad de fallas en su sistema, además que de acuerdo al PME en la sección de Expansión de la Generación se consideró el margen 20% de reserva de potencia.

3.1 Descomposición de la demanda 2017-2022

Las características obtenidas por la descomposición de la demanda en un modelo aditivo se presentan en la Figura 3.2, estas nos permitieron corroborar que existía una tendencia que aumentaba con el tiempo.

Por otra parte, tenemos en la Figura 3.1 siguiente figura el resultado del diferencial de crecimiento de la tendencia por cada hora. El diferencial de crecimiento muestra un comportamiento limitado entre 0.20 y -0.15, indicándonos que la tendencia en gran parte del histórico aumento por cada hora. Los valores donde la tendencia decrecía correspondían a la época de la pandemia, y por último se corroboró que los datos que ingresaban al modelo tendencial iban a comportarse de manera casi periódica.

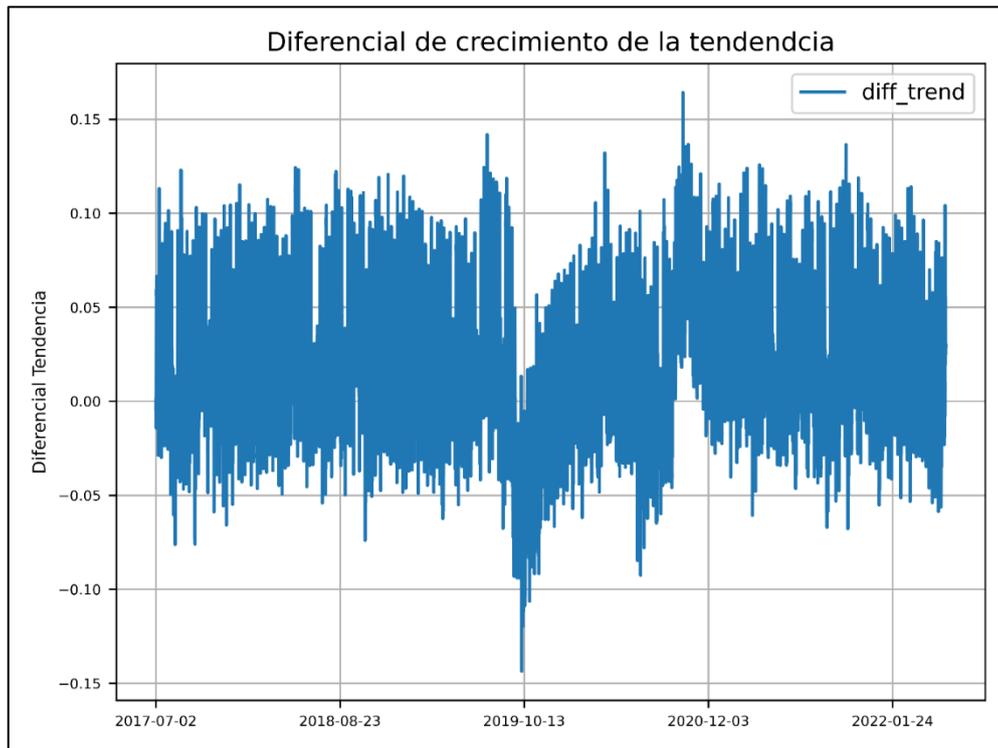


Figura 3.1 Diferencial de crecimiento de la demanda

La tendencia de la demanda en gran parte de los años aumentaba, a excepción del año 2020 de la pandemia. Los resultados sugerían que el año 2020 no debería tomarse en cuenta, pero se realizaron dos pruebas, una incluyendo los datos del 2020 y en la otra no, mostrando que había que considerar los datos, los resultados se muestran adelante. Además, con lo observado en la tendencia se prefirió usar el diferencial de crecimiento de la tendencia de los datos históricos como variable de entrada, por lo que el modelo de la tendencia se construyó pensando en esto.

La estacionalidad de la demanda presentaba un comportamiento ondulatorio, representando la periodicidad con la que la demanda fluctúa, repitiéndose en todos los años estudiados de los datos históricos. La estacionalidad presentaba picos de alta demanda al inicio y finales de los años, y un mínimo entre medio. Los resultados sugerían un comportamiento periódico, por lo que el modelo de la RNA para la estacionalidad debería ser básico, ya que una estructura básica es capaz de reconocer un patrón periódico sencillo.

El residuo no presentaba patrones visibles que la RNA pueda aprender, lo que era de esperarse ya que el residuo representa la componente aleatoria de la serie de tiempo. La falta de patrones visibles sugería que el modelo de RNA para el residuo no tendría

una precisión alta sin importar el cambio que se realice, por lo que se optó por multiplicar por un factor para reducir su efecto.

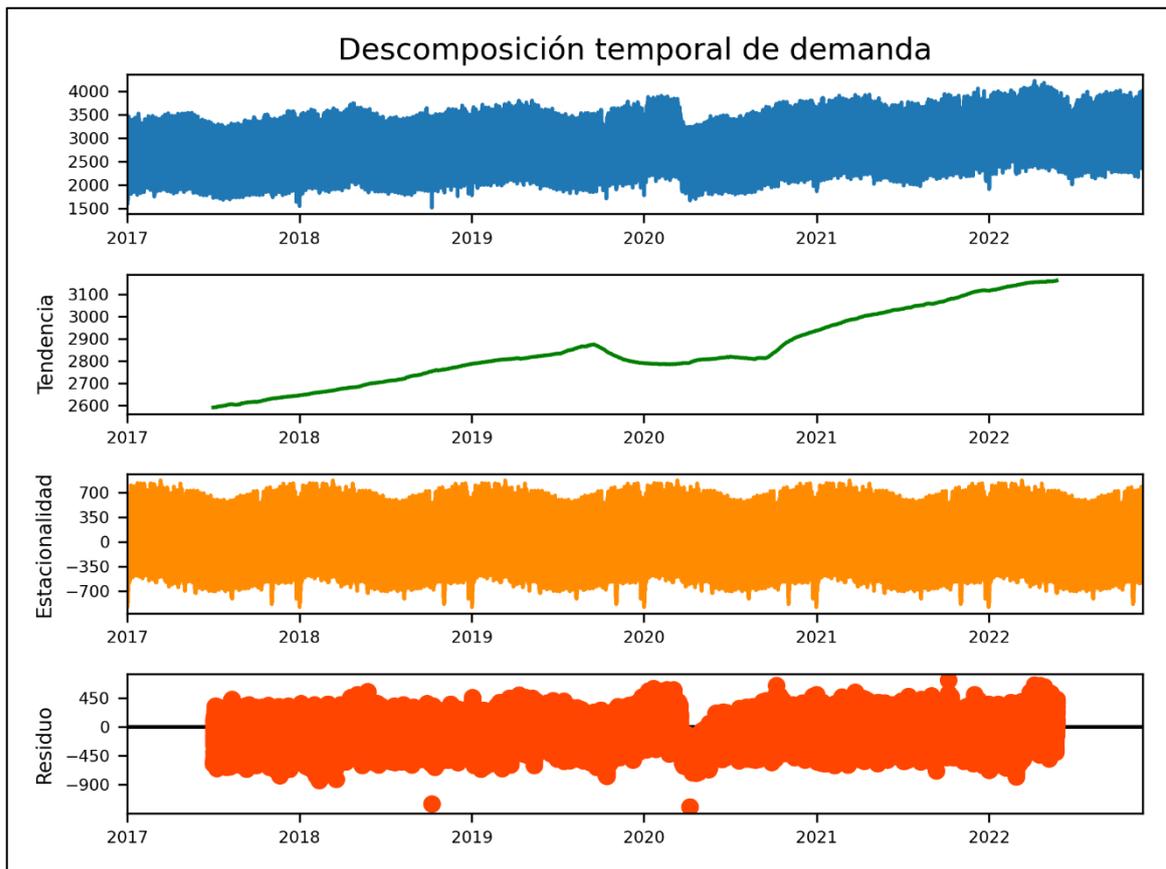


Figura 3.2 Descomposición temporal de la demanda 2017-2022

3.2 Rendimiento RNA con distintitos pasos de días y conjunto de días

La forma de la curva resultante de la proyección mostró el punto de funcionamiento óptimo de la red para obtener la proyección con mejor coherencia, siendo que el rendimiento no ha sido un buen factor para considerar. A medida que se aumentaban la cantidad de días que ingresan a la red como datos históricos, las proyecciones pierdan coherencia y no seguían el comportamiento esperado. Con la cantidad de 6 días, los modelos entregaban las proyecciones más coherentes, además es de notar que la precisión y el error de la red sobre los últimos meses del 2022 eran buenos, indicando que podía predecir los datos con alta confiabilidad. No obstante, esta métrica no es un indicador de que tan coherente es la proyección resultante.

Los resultados de las pruebas hechas solo escogiendo el mismo día de la semana, anexo 13 hasta 15, no presentaron buenos resultados en alguno de los casos, es de señalar que la proyección fue mala a pesar de obtener buenos resultados en precisión como se

ve en la tabla, esto debido a que los modelos estaban diseñados para analizar un tipo de datos.

Tabla 3.1 Resultados de precisión de los casos de estudio

	Tendencial		Estacional		Residuo	
	<i>Train</i>	<i>Valid.</i>	<i>Train</i>	<i>Valid.</i>	<i>Train</i>	<i>Valid.</i>
3 pasos	93.20	95.51	94.71	89.89	36.44	21.91
6 pasos	93.40	94.38	91.41	89.89	38.00	17.98
13 pasos	93.82	94.73	93.15	90.28	39.18	19.78
28 pasos	94.24	95.08	94.88	90.68	40.36	21.59
lunes	82.00	97.30	92.00	64.52	58.96	8.00
Martes	82.96	93.24	90.83	66.13	67.16	6.00
Miércoles	83.92	89.19	89.66	67.74	75.36	4.00

3.2.1 Numero de pasos 3

La proyección generada cuando se usó 3 datos anteriores como histórico se observa en la Figura 3.2, en la que se pierde en cierta manera el comportamiento ondulatorio y periódico desde el año 2024 en adelante. Mostrando que el modelo no genera proyecciones con el comportamiento parecido al de los datos originales, esto a pesar de tener un alto nivel de precisión en los dos modelos más importantes (tendencia y estacionalidad).

La tendencia tiene una pendiente en promedio de 0.019 [MW/h] por año. Con respecto a su comportamiento para los años siguientes al 2023 disminuye su crecimiento hasta el 2028. La estacionalidad proyectada por su parte no mantuvo el comportamiento de los datos reales, presenta un comportamiento menos sinusoidal, con picos fuera de lo normal. El residuo proyectado redujo los datos aberrantes del límite inferior, dejando los datos limitados entre valores acordes al residuo de los datos originales.

El Anexo 9 muestra que el error de validación después de la interacción, mostrando altos niveles de precisión, a excepción del modelo residuo. La precisión de los modelos para predecir los valores restantes del año 2022 sobrepasa el 80 %, a excepción del residuo que tiene un 17%.

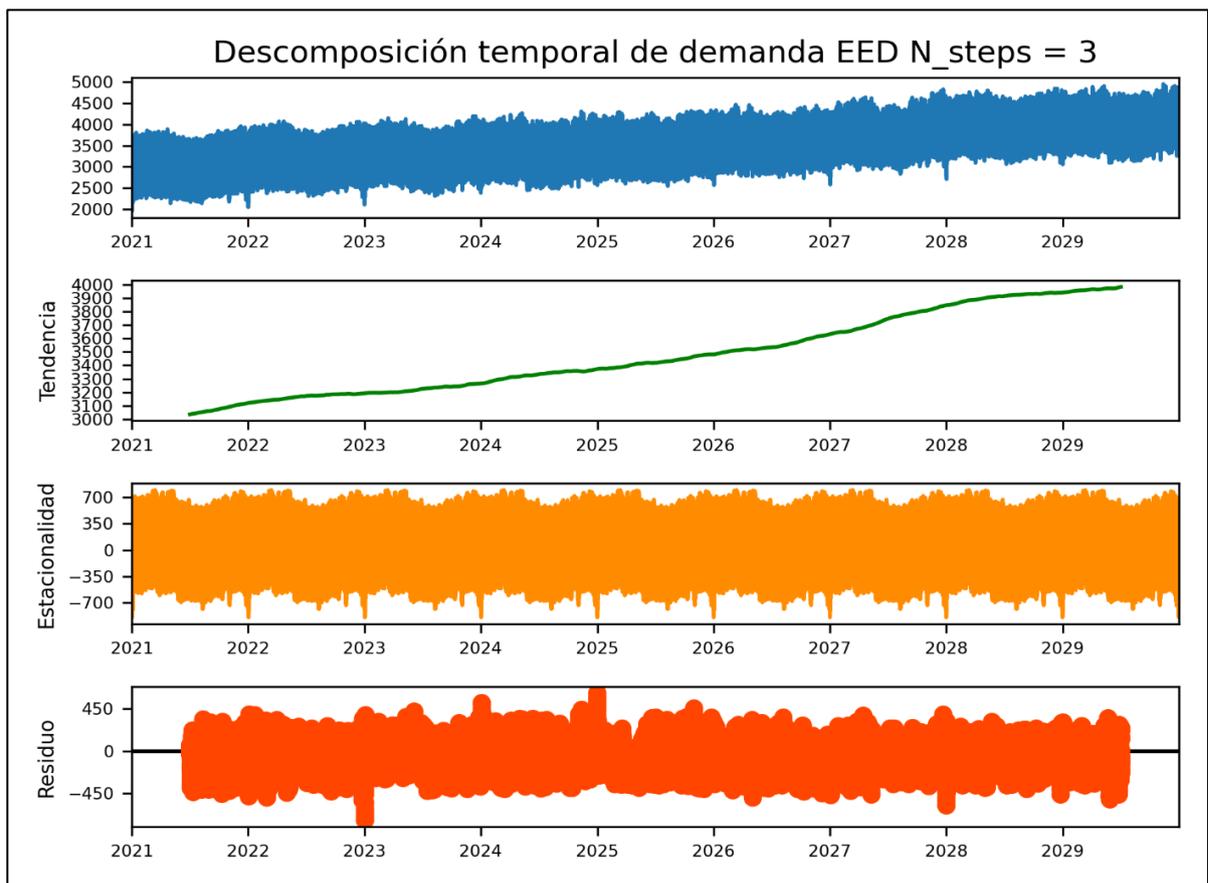


Figura 3.3 Resultados de proyección de demanda.

3.2.2 Número de pasos 6

La proyección realizada considerando 6 días de histórico presento la proyección más estable y coherente con el comportamiento de los datos originales. La tendencia aumenta de forma lineal con un crecimiento de uniforme con una pendiente mayor al caso de 3 pasos, en este caso tenemos una pendiente de 0.02 [MW/h]. La forma de la curva de la estacionalidad es la más parecida a la de los datos originales. El residuo presenta una mayor concentración de datos entre 450 y -450 MW. Con lo observado la proyección realizada con 6 días de datos históricos logro generar una curva de demanda con un comportamiento con mayor consistencia a los datos históricos del Ecuador.

El Anexo 10 nos presentó el proceso de entrenamiento y precisión de los datos, dejando como resultado que la precisión de los modelos se encuentra mayor al 90%, siendo la precisión de los modelos de este caso ligeramente mayor a la precisión del caso cuando se usó 3 pasos. El proceso de entrenamiento para el modelo de tendencia dio a conocer una reducción entre el error de validación,

sugiriendo que el error global entre las predicciones y los datos de los últimos meses del 2022 se redujo.

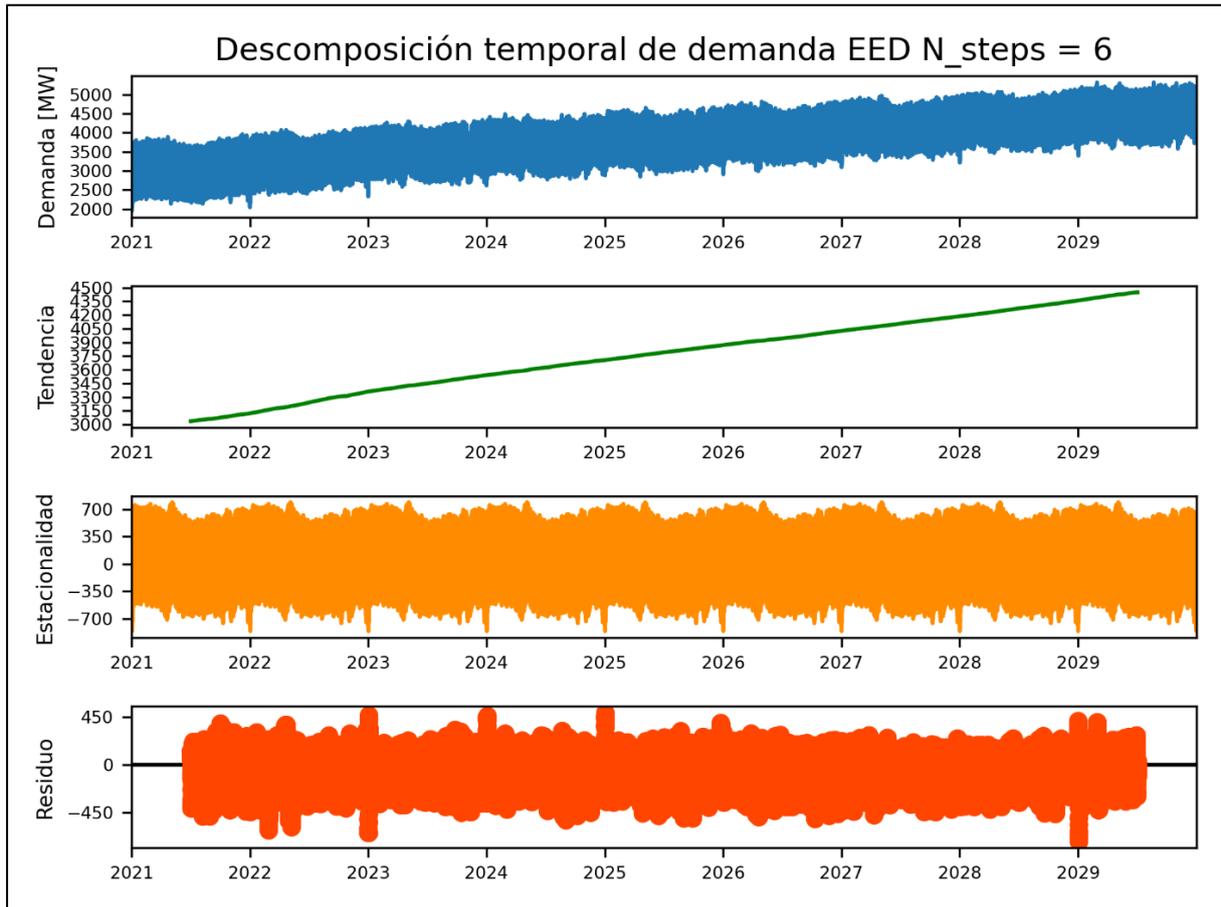


Figura 3.4 Descomposición temporal 6 pasos

3.2.3 Numero de pasos 13

La proyección realizada considerando 13 días de histórico presento una proyección con comportamientos fuera de lo esperado. La tendencia aumenta de forma lineal con un crecimiento más pronunciado y pendiente mayor los casos anteriores, en este caso tenemos una pendiente de 0.025 [MW/h]. La forma de la curva de la estacionalidad perdió la forma de los datos originales, siendo menos sinusoidal. El residuo se mantenía entre 450 y -450 MW y sin cambios significativos. Con lo observado la proyección realizada con 13 días de datos históricos logro generar una curva de demanda con un comportamiento distintito al de los datos originales, crece con una inclinación alta y menos fluctuaciones estacionales, pareciendo una sola franja.

El Anexo 11 nos presentó el proceso de entrenamiento y precisión de los datos, dejando como resultado que la precisión de los modelos se encuentra igual a los casos anteriores, con una diferencia de +/-1%, siendo la precisión de los modelos

para este caso ligeramente mayor al anterior. El proceso de entrenamiento para el modelo de tendencia dio a conocer una reducción ligera en el error de validación, sugiriendo que el error global entre las predicciones y los datos de los últimos meses del 2022 se redujo, no obstante, ahora las curvas del error y presión presentan más ruido.

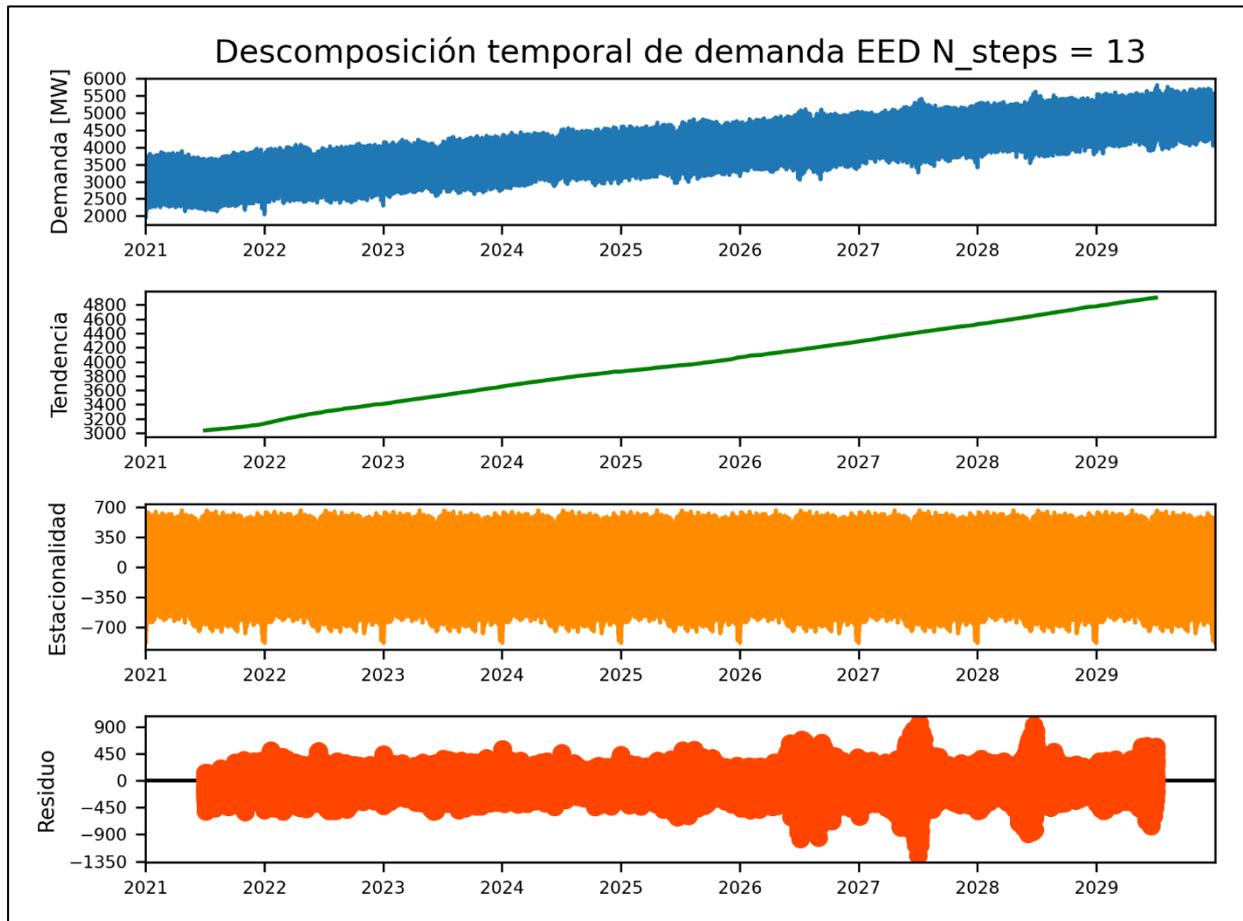


Figura 3.5 Descomposición temporal 13 pasos

3.2.4 Numero de pasos 28

La proyección realizada considerando 28 días de histórico presento una proyección sin ningún parecido al comportamiento de los datos históricos de demanda. La tendencia aumenta bruscamente hasta el año 2024 una pendiente de 0.037 [MW/h], después se mantiene casi constante. La forma de la curva de la estacionalidad perdió la forma de los datos originales, moviendo el rango de los valores entre 350 y -1050 [MW]. El residuo se mantenía entre 450 y -450 MW y sin cambios significativos. Con lo observado la proyección realizada con 28 días de datos históricos logro generar una curva de demanda con un comportamiento totalmente distinto e inconsistente con los datos históricos.

El Anexo 12 nos presentó el proceso de entrenamiento y precisión de los datos, dejando como resultado que la precisión de los modelos se encuentra igual a los casos anteriores, con una diferencia de $\pm 1\%$, además es de recalcar que el proceso de entrenamiento es parecido a los casos anteriores, nos obstante la proyección no tiene sentido.

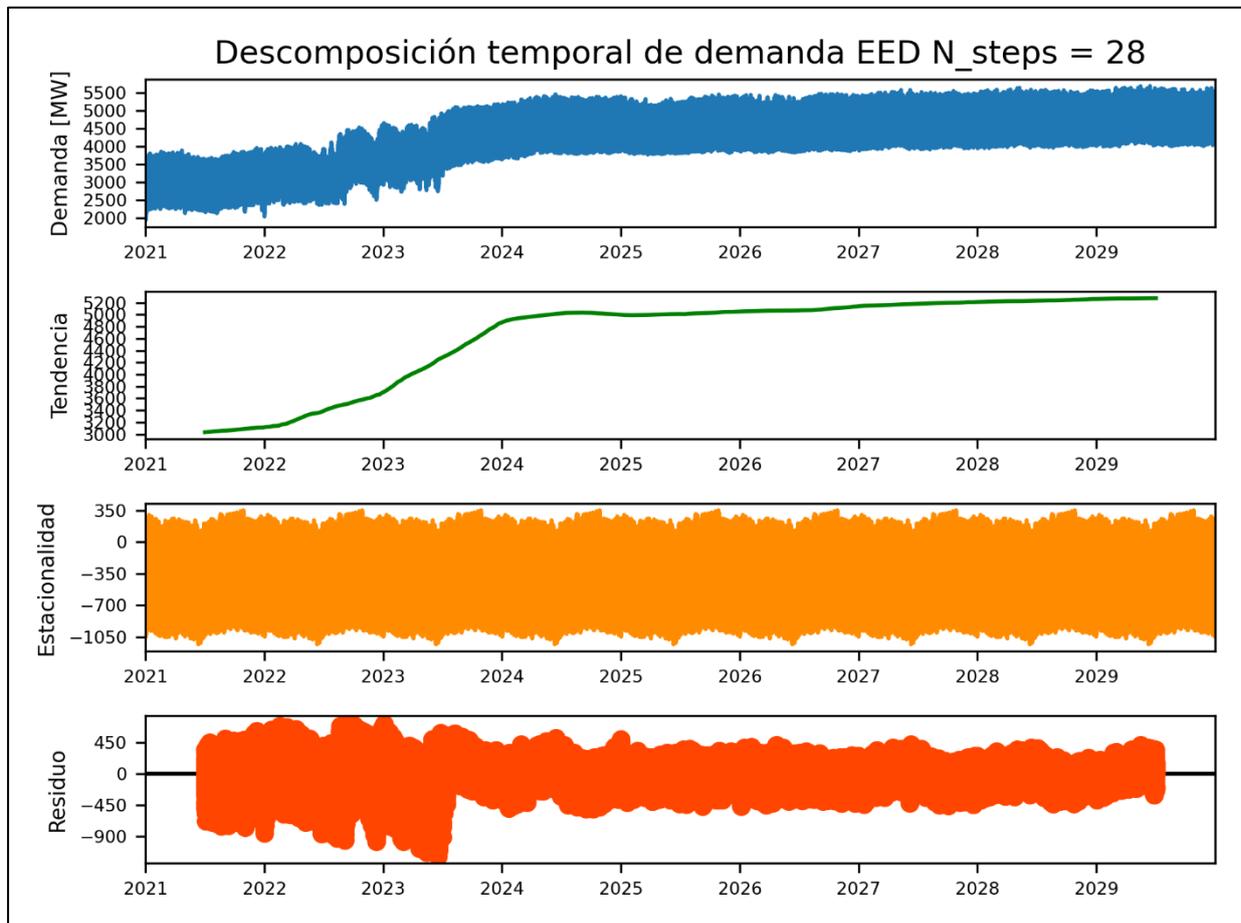


Figura 3.6 Descomposición temporal 28 pasos

3.3 Proyección sin considerar datos del 2020

La proyección realizada sin considerar los datos de 2020 días presentaba resultados más estable y coherente con el comportamiento de los datos originales, como ya se había visto cuando se utilizan todos los datos, pero esta vez crece con menos rapidez y tiene una estacionalidad más estable. La tendencia no crecía de manera lineal, en promedio crecía con una pendiente de 0.006 [MW/h] el cual es menor al caso contrario usando los datos del 2020 para el entrenamiento. La forma de la curva de la estacionalidad presentó un mejor parecido con la estacionalidad de los datos históricos. El residuo presentó una mayor concentración de datos entre 450 y -450 MW. Con lo

observado la proyección realizada sin considerar los datos del 2020 no es una buena proyección ya que no crece de manera coherente al crecimiento de los datos históricos.

El Anexo 13 nos presentó el proceso de entrenamiento y precisión de los datos, dejando como resultado que la precisión de los modelos era altos, parecidos a los casos revisados. El proceso de entrenamiento es igual de bueno, ya que el error se deduce rápido y se llega hasta el 90 % en todos los modelos.

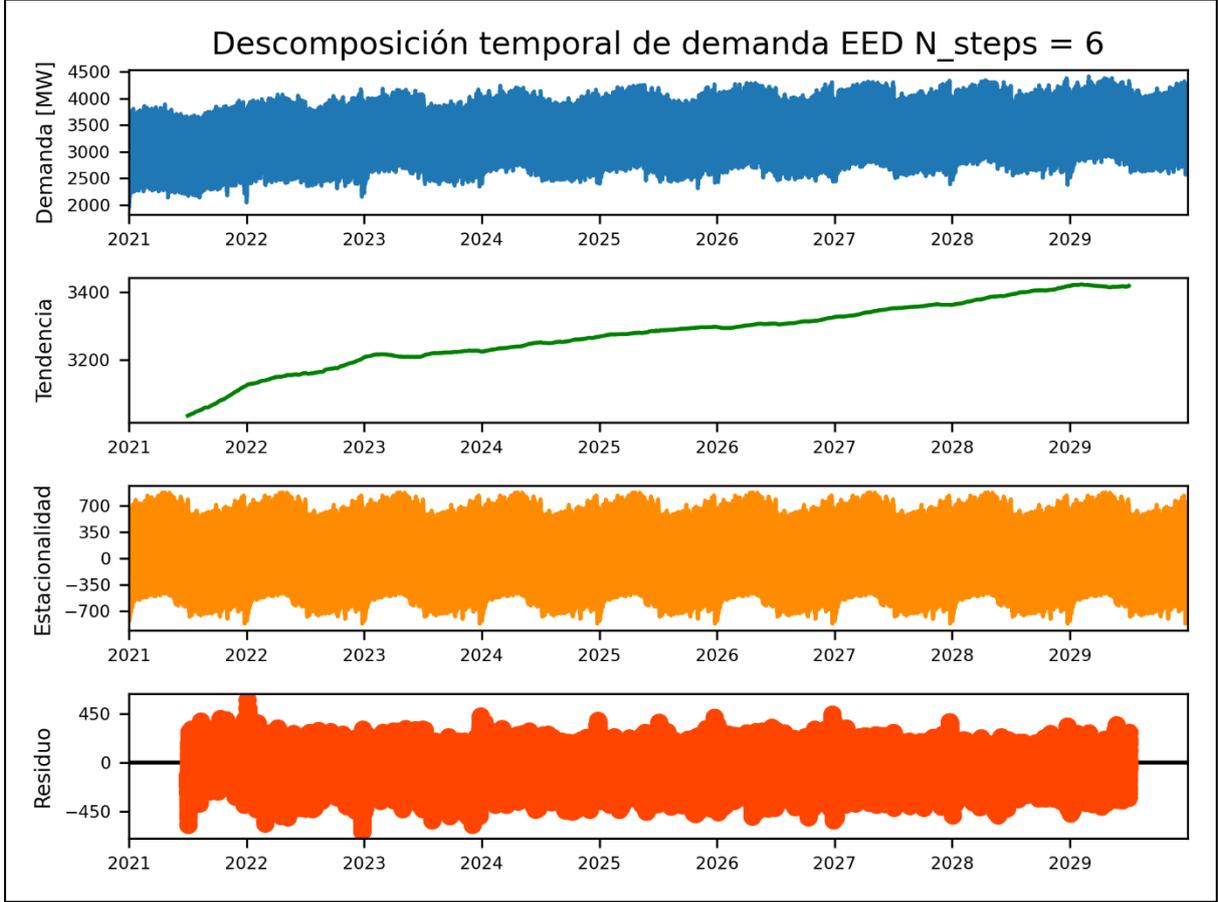


Figura 3.7 Descomposición temporal 6 pasos sin tomar año 2020 para análisis

3.4 Análisis de resultados proyección vs confiabilidad hasta finales de 2025.

Los resultados del desempeño de la red mostro que el modelo con 6 días como datos históricos y considerando los datos del 2020 es el mejor modelo para hacer una proyección, por lo tanto, se escogió la proyección realizada por ese modelo.

Con los datos obtenidos de la proyección de demanda hora–hora se realizó una proyección hasta el año 2029 para comparar la evolución de los índices de confiabilidad, para esto se tomó en cuenta el análisis preliminar de las potencias efectivas de todas las

unidades generadoras presente en Ecuador vs la demanda máxima proyectada hasta 2029.

Tabla 3.2 Datos de potencia efectiva total considerando 20% reserva vs Demanda máxima anual proyectada

Tipo Combustible	Potencia Efectiva MW	Potencia efectiva menos 20% reserva MW	Años	DEMANDA MÁXIMA ANUAL PROYECTADA MW
AGUA - EMBALSE	1600,96		2022	4130,5
AGUA - PASADA	3573,35		2023	4335,4
AIRE	29,25		2024	4493,4
Bagazo	96,5		2025	4670,2
Biogas	6,69		2026	4816,3
Diesel	78,15		2027	4967,4
Diesel-Turbo Gas	340,92		2028	5134,5
Fuel Oil 4	466		2029	5319,5
Fuel Oil 6	547,81			
Gas Natural	231,6			
Radiación Solar	2			
Total General MW	6973,23	5878,6		

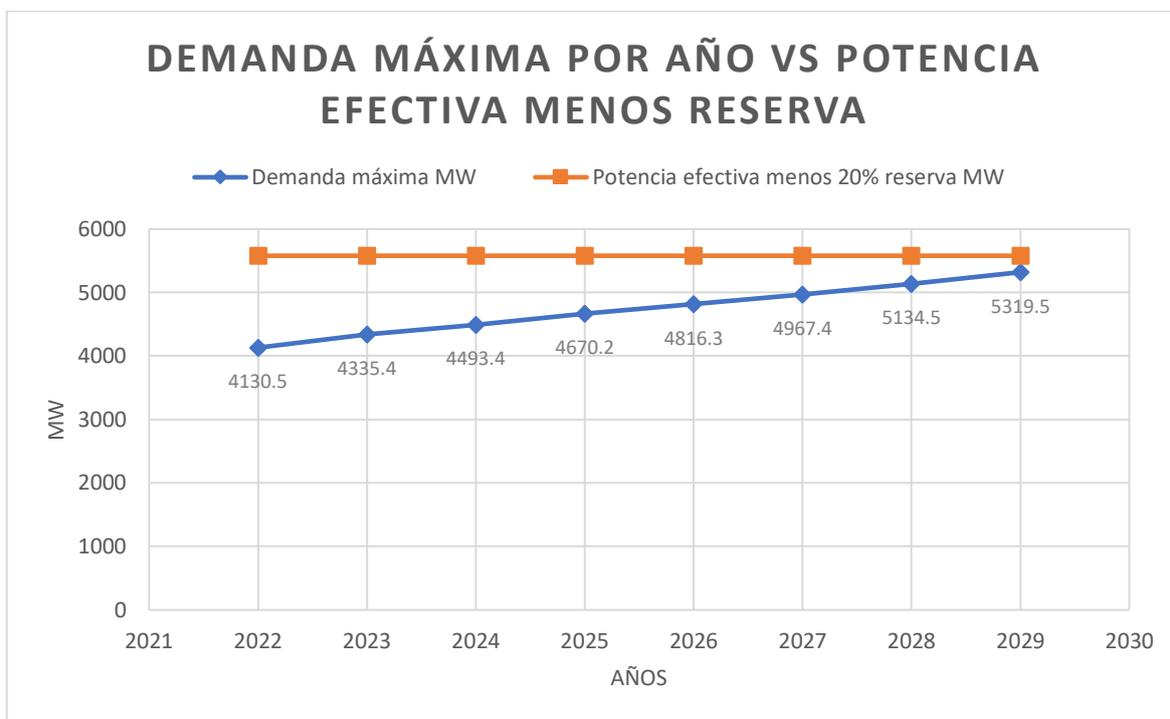


Figura 3.8 Curva de la demanda máxima proyectada vs la potencia efectiva menos el 20% de reserva

Con estos resultados se observó que la generación total efectiva en el Ecuador va satisfacer el crecimiento de la demanda hasta el año 2029, por lo que a partir del año 2030 se deberá tener un plan para satisfacer la demanda. La siguiente gráfica muestra los índices de confiabilidad obtenidos en este caso hasta el año 2029.

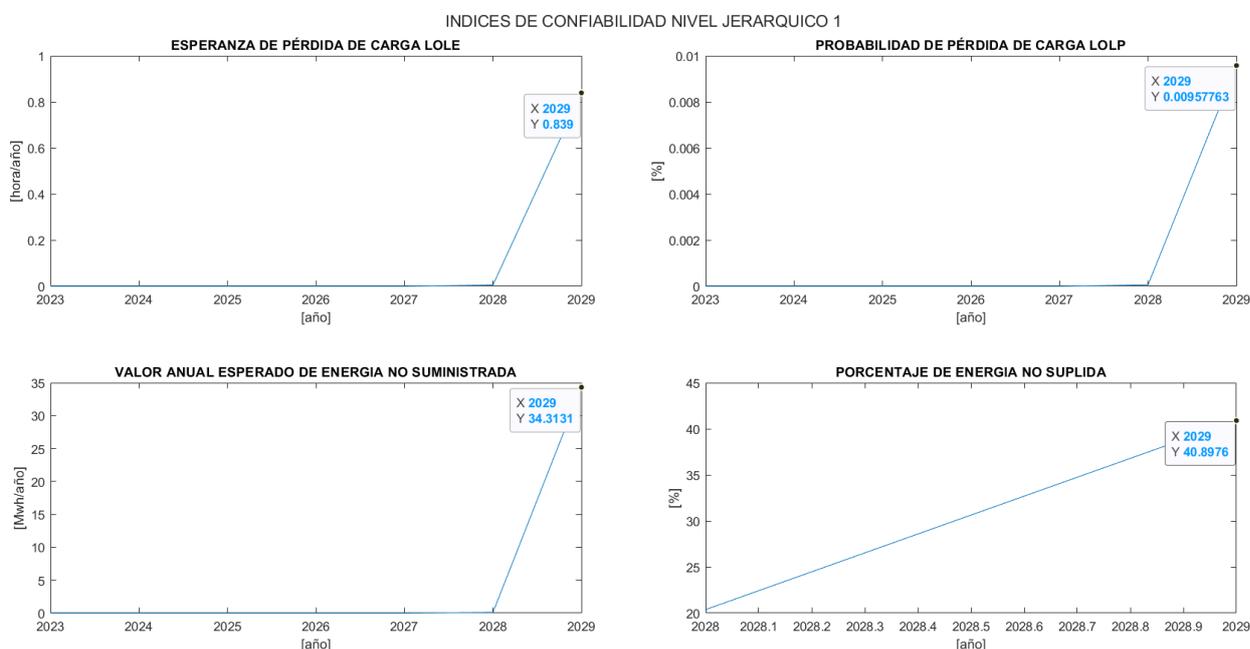


Figura 3.9 Curvas de los índices de confiabilidad a nivel jerárquico 1.

En este caso, se tiene en cuenta la actividad de las 8 Unidades Generadoras de la Central Hidroeléctrica COCA CODO SINCLAIR que tiene una potencia efectiva total de 1500 MW, sin embargo, de acuerdo a CELEC EP a fin de preservar sus derechos y los del Estado Ecuatoriano esta central generadora no está al servicio a partir de finales del 2022 debido a su gran cantidad de fallas en su sistema (estructuras).

De acuerdo a esto, se llevó el análisis de confiabilidad para el nivel jerárquico 1 considerando la salida de servicio de la Central Eléctrica COCA CODO SINCLAIR, teniendo así la nueva tabla de generación efectiva menos reserva del 20% y las proyecciones de demanda hasta 2029.

Tabla 3.3 Datos de potencia efectiva total considerando 20% reserva vs Demanda máxima anual proyectada (SIN CCS)

Tipo Combustible	Potencia Efectiva MW	Potencia efectiva menos 20% reserva MW	Años	DEMANDA MÁXIMA ANUAL PROYECTADA MW
AGUA -- EMBALSE	1600,96		2022	4130,5
AGUA -- PASADA	2073,35		2023	4335,4
AIRE	29,25		2024	4493,4
Bagazo	96,5		2025	4670,2
Biogas	6,69		2026	4816,3
Diesel	78,15		2027	4967,4
Diesel-Turbo Gas	340,92		2028	5134,5
Fuel Oil 4	466		2029	5319,5
Fuel Oil 6	547,81			
Gas Natural	231,6			
Radiación Solar	2			
Total General MW	5473,23	4378,6		

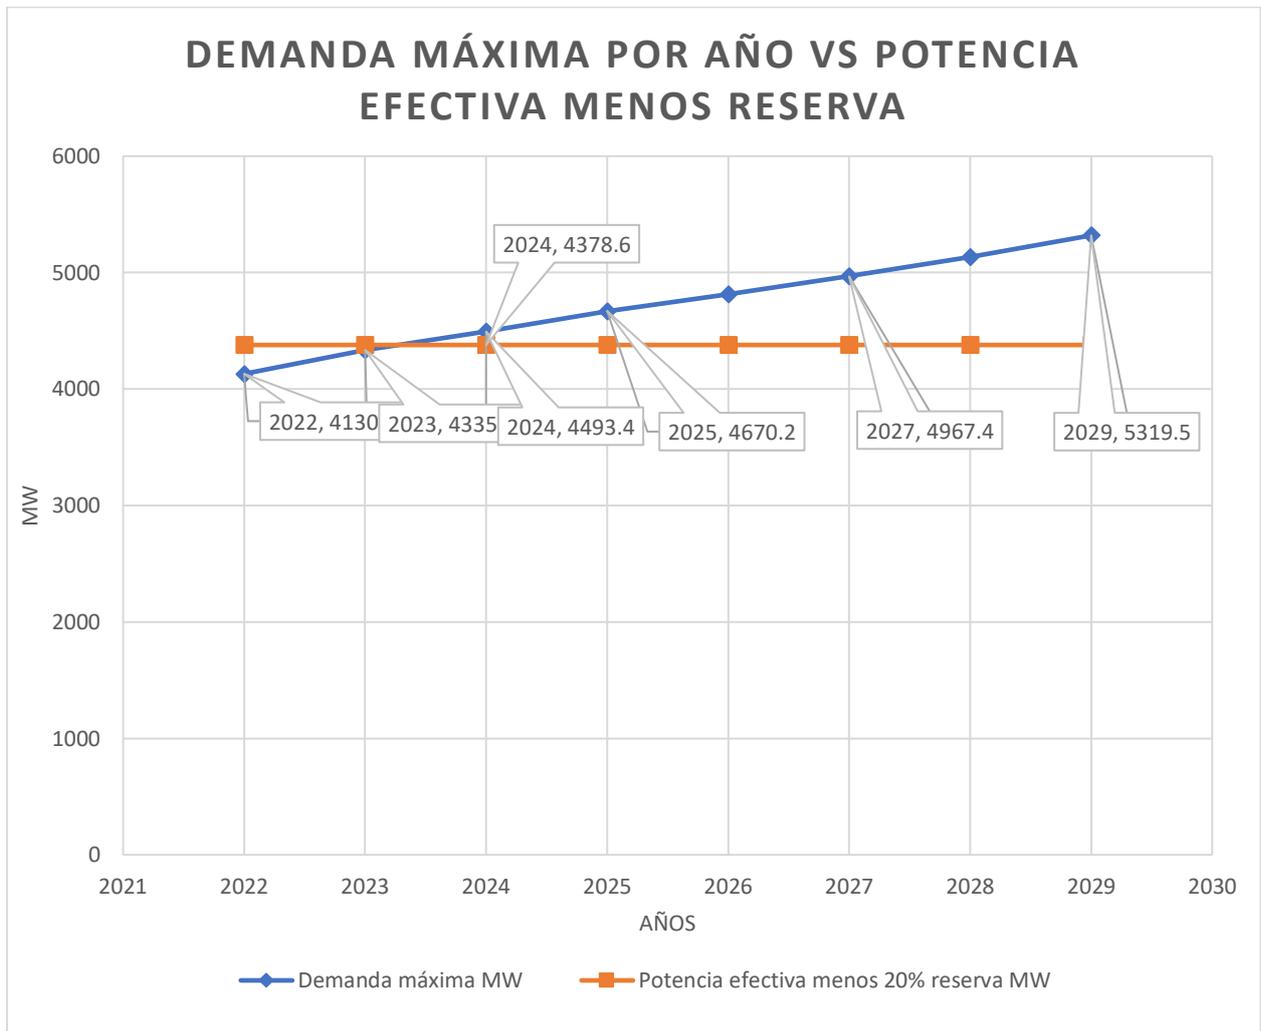


Figura 3.10 Curva Demanda Máxima vs Potencia efectiva menos 20% reserva (SIN CCS)

Con estos resultados se observó que la generación total efectiva en el Ecuador va satisfacer el crecimiento de la demanda hasta el año 2023 siendo la demanda máxima proyectada de 4335 MW aproximadamente vs la potencia efectiva considerando la reserva del 20% de 4378 MW aproximadamente por lo que la generación cubriría la demanda hasta el 2023. A partir del 2024 en adelante pasó lo contrario, ya que la demanda proyectada superó a la generación, por lo que los índices de confiabilidad obtenidos a través de Matlab R2021b y procesados en una tabla de Excel fueron de:

Tabla 3.4 Índices de Confiabilidad hasta año 2025

Índices	2022	2023	2024	2025
LOLE [hora/año]	0,2100	29,4520	324,5580	1146
LOLP [%]	0,0024	0,3362	3,6949	13,0843
EENS [Mwh/año]	6,4245	1346,4	25364	147770
XLOL [MW]	30,5928	45,7157	78,1505	128,9235

De acuerdo a los índices de confiabilidad se tuvo que desde el año 2023 los valores de estos índices no están dentro de los rangos adecuados o que representen una alta valoración de la confiabilidad. Para el año 2023 el LOLE o la esperanza de pérdida de carga se tuvo un valor de 27,035 horas/año, siendo recomendable tener este valor menor a 2,4 horas/año, el LOLP o probabilidad de pérdida de carga se tuvo 0,3086%, para EENS o valor anual esperado de energía no suministrada se tuvo 1228,7 MWh/año, el XLOL o valor esperado de pérdida de carga se tuvo de 45,4472 MW, y así aumentando considerablemente hasta el año 2025. A continuación, se presentó una gráfica con la curva con cada uno de los índices y su evolución hasta 2028.

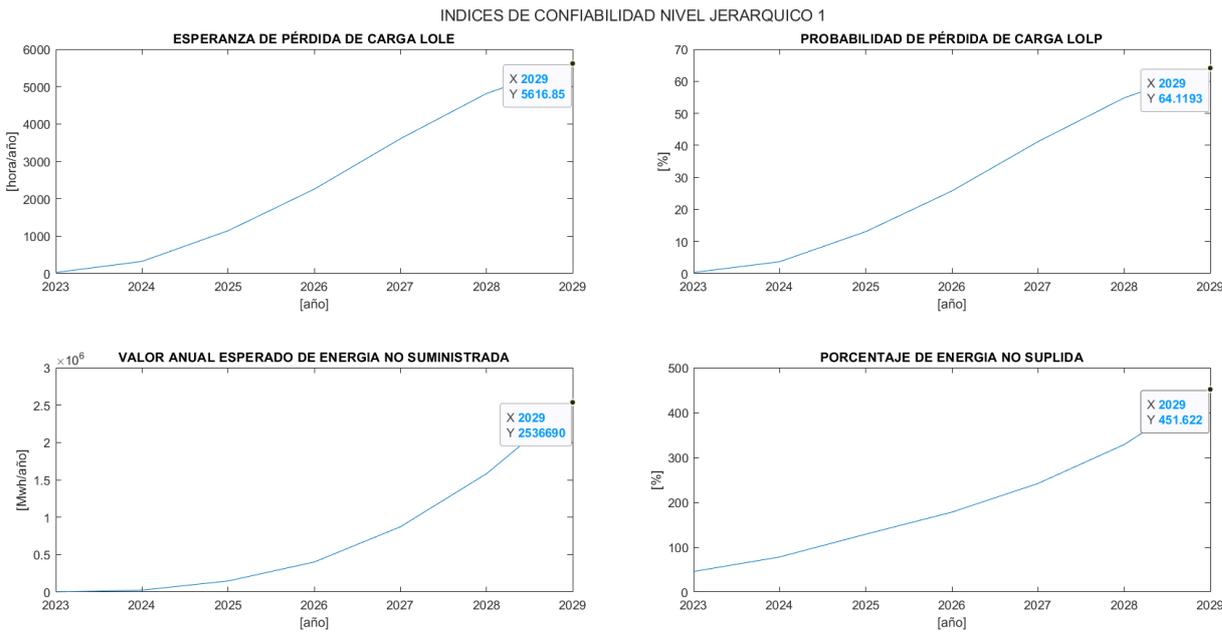


Figura 3.11 Curvas de los índices de confiabilidad a nivel jerárquico 1 (SIN CCS).

CAPÍTULO 4

4. CONCLUSIONES Y RECOMENDACIONES

Las redes neuronales son una tecnología con distintas ventajas para automatizar procesos, esta tecnología en el campo de la planificación se usa en la proyección de demanda. En este trabajo se desarrolló un método para proyección de demanda usando redes neuronales de tipo MLP con un algoritmo de entrenamiento de retro propagación con el fin de obtener una proyección coherente con el perfil de carga de un país y una buena precisión. Por otro lado, se buscaba actualizar a nuevas tecnologías el proceso de proyección de demanda para obtener un proceso que cuente con más funcionalidades y sea automatizado.

Los resultados muestran una buena predicción para proyecciones de corto plazo, por otro lado, en estudios a largo plazos se pierde confiabilidad en la proyección por falta de datos reales que entren como datos históricos, en cambio el modelo construido puede ser alimentado constantemente con datos que suceden al día para predecir el día siguiente.

Conclusiones

La aplicación de redes neuronales tipo MLP en proyecciones de demanda para estudios a corto plazo permiten obtener una buena predicción, con la ventaja de evitar el uso de modelos econométricos y automatizar el proceso para la posterior aplicación con datos a tiempos reales. El proceso de entrenamiento para los modelos presentados en el Anexo 10, nos muestran que la precisión de la red para predecir los últimos meses del 2022, validación, están por encima de 90%, a excepción del residuo que es una componente aleatoria, además el proceso solo requiere ingresar los 6 datos históricos anteriores a día que se predice para generar una salida.

Los estudios de proyección de demanda a largo plazo deben ser realizados con redes neuronales más complejas. La red para predecir de mejor manera un valor en el futuro muy distante requiere una ventana más grande de datos históricos, lo que genera que la red necesite mayor cantidad de neuronas para cada variable que entra generando un desempeño peor al tener muchos datos, como se observa en

la proyección generada por la red con 28 días históricos en la Figura 3.5, que, a pesar de tener una precisión de validación alta, la proyección no es coherente.

De acuerdo a los datos proyectados y el análisis de confiabilidad indican que para el año 2023 se tiene una potencia efectiva de 4379 MW aproximadamente y una demanda pico o máxima creciente de 4336 MW, por lo que aún la generación puede suplir a la demanda. Sin embargo, por el índice de confiabilidad siendo más representativo para el nivel jerárquico 1, el LOLE indica que se tiene un valor alto (29horas/año) del valor recomendado (2.4 horas/año), por lo que durante el año 2023 se esperaría una pérdida de carga de 29 horas, que en términos de potencia con ayuda del índice XLOL equivale a 45MW aproximadamente, por lo que se tiene que tomar medidas preventivas como el aumento de la generación o utilizar parte del 20% de la reserva de potencia.

Recomendaciones

Utilizar modelos de red neuronal con memoria, como las rede tipo Long-Short Term Memory (LSTM) para estudios a largo plazo, debido a que estas guardan datos en una memoria interna y los utilizan para hace predicción, permitiendo que la red mejore su proyección en estudios de largo plazo.

Utilizar un modelo con datos a tiempo real para alimentar la red neuronal, con esto se aprovecharía la cantidad de funcionalidades que ofrecen las tecnologías de programación para mostrar proyecciones a tiempo real y automatizar los despachos económicos.

Filtrar los datos para obtener un comportamiento representativo, la red podría aprender de mejor manera los patrones de comportamiento.

Para la confiabilidad se recomienda tener en consideración posible salida de servicio de centrales ya sea por deterioro o daños en sus estructuras, además que para una adecuada y segura planificación se debe considerar como valores de tasa de falla y de reparación aquellos que sean mayores, para así tener un margen seguro o nivel de confianza elevado.

BIBLIOGRAFÍA

- [1] M. De energía y recursos no renovables, “Plan Maestro De electricidad”, 2018. [Online]. Disponible en: <https://www.recursoyenergia.gob.ec/plan-maestro-de-electricidad/>
- [2] A. Salaza y M. Cabrera, “Pronóstico de demanda por medio de redes neuronales artificiales”, ResearchGate, 2007. [Online]. Disponible en: https://www.researchgate.net/publication/236028213_Pronostico_de_demanda_por_medio_de_redes_neuronales_artificiales
- [3] E. George, M. Gwilym, C. Gregory, y M. Greta, Time series analysis forecasting and control. Wiley, 2016.
- [4] E. Bee, “Time Series Modelling and Decomposition”, ResearchGate, 2013. [Online]. Disponible en: https://www.researchgate.net/publication/307663962_Time_Series_Modelling_and_Decomposition
- [5] E. Francisco y J. Alfonso, Una aproximación practica a las redes neuronales artificiales. Programa Editorial, 2009.
- [6] L. Fernando, “Proyección de la demanda de energía eléctrica a corto plazo, mediante redes neuronales artificiales”, ESPOL, Ecuador, 2016. [Online]. Disponible en: <https://www.dspace.espol.edu.ec/retrieve/98973/D-103279.pdf>
- [7] M. Álvarez, “Power System Reliability Enhancement with Reactive Power Compensation and Operational Risk Assessment with Smart Maintenance for Power Generators”, Birmingham, 2020. [Online]. Disponible en: <https://etheses.bham.ac.uk/id/eprint/10234/1/Alvarez-Alvarado2020PhD.pdf>
- [8] A. Mora, S. Toaquiza, y D. Peña, “Predicción de demanda eléctrica utilizando redes neuronales artificiales para CNEL EP – unidad de negocios agencia Quevedo”, UTEQ, Ecuador, 2021. [Online]. Disponible en: <https://repositorio.uteq.edu.ec/handle/43000/6595>

[9] C. Zapata, “Confiabilidad de sistemas eléctricos de potencia. Universidad Técnica Estatal de Quevedo”, UTEQ, Ecuador, 2011. [Online]. Disponible en: https://www.feis.unesp.br/Home/departamentos/engenhariaeletrica/lapsee/curso_2011_zapata_2.pdf

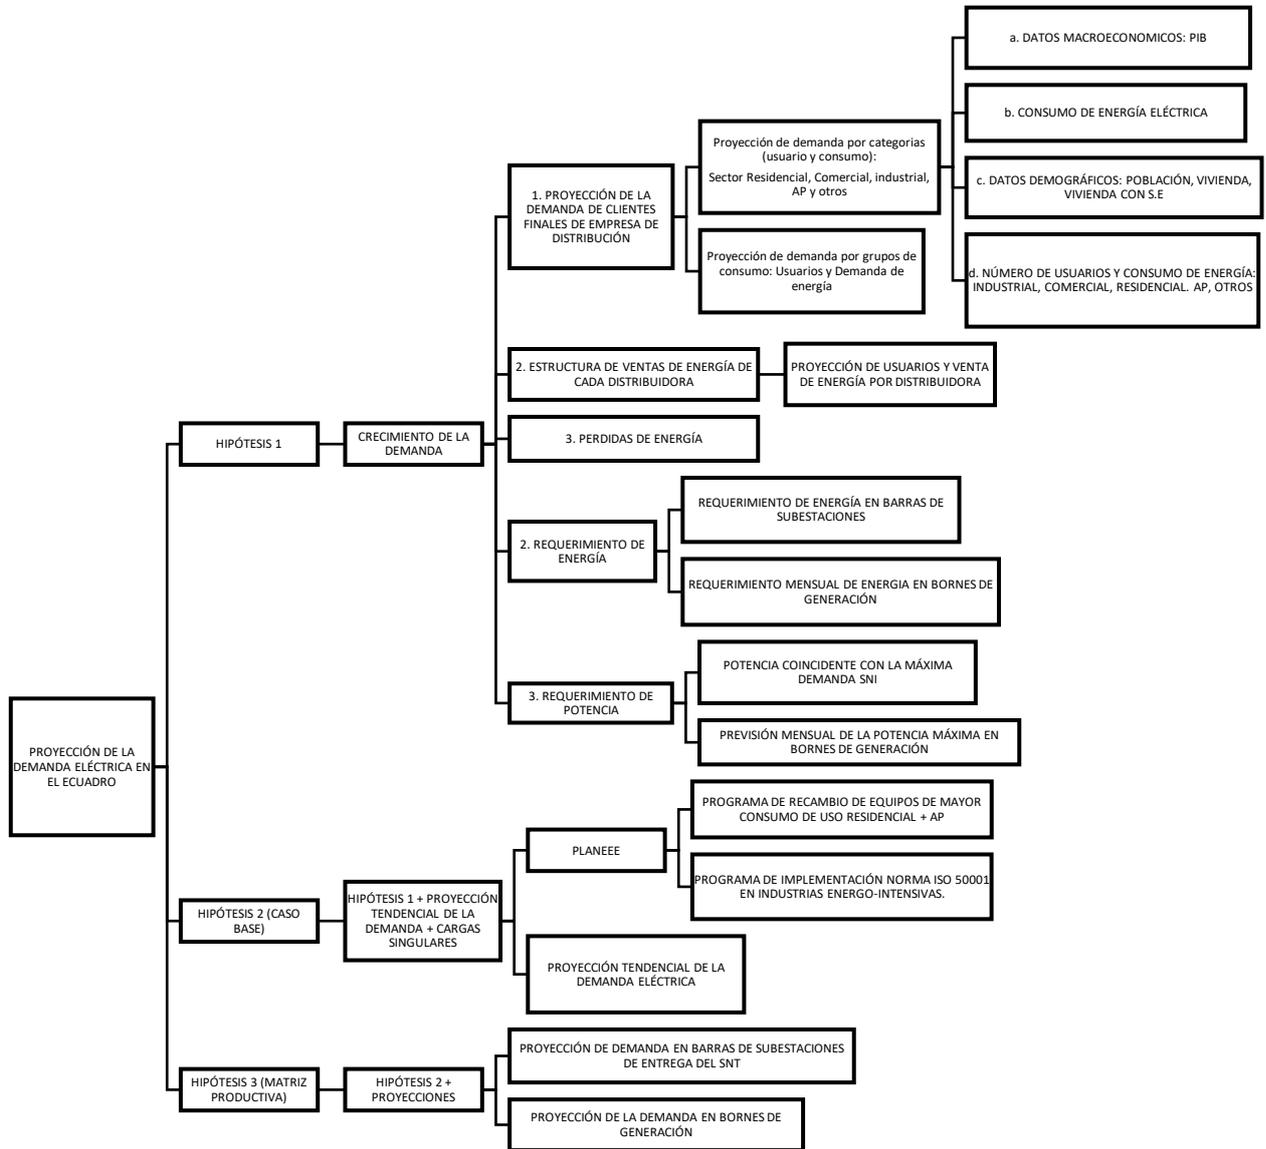
[10] T. Point., “Keras”, 2019. [Online]. Disponible en: https://www.tutorialspoint.com/keras/keras_tutorial.pdf

[11] E. Ruelas y L. J., “Comparación de predicción basada en redes neuronales contra métodos estadísticos en el pronóstico de ventas. Ingeniería industrial actualidad y tendencias”, Revista de ingenieros industriales, 2013. [Online]. Disponible en: <http://servicio.bc.uc.edu.ve/ingenieria/revista/Inge-Industrial/vol12/art07.pdf>

[12] R. Fernández, “Series Temporales Avanzadas: Aplicación de Redes Neuronales para el Pronóstico de Series de Tiempo”, Universidad de Granada Departamento de Estadística e Investigación Operativa, Granada, 2021. [Online]. Disponible en: https://masteres.ugr.es/estadistica-aplicada/sites/master/moea/public/inline-files/TFM_Fernandez%20SalgueroRicardo%20Alonzo.pdf

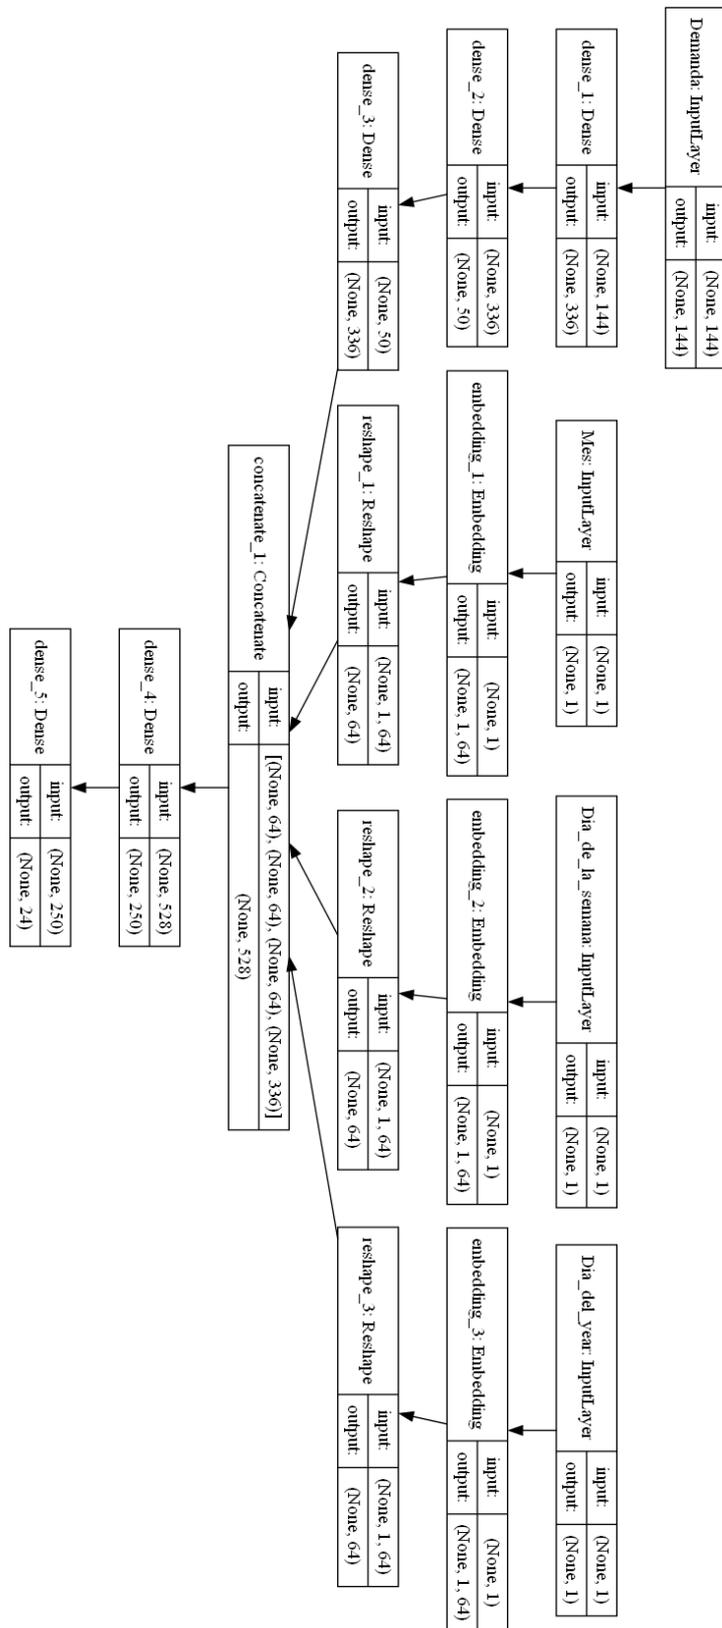
ANEXOS

Anexo 1: Esquema conceptual sobre la metodología aplicada en el Plan Maestro de Electricidad para proyección de demanda



(Creado por David Rodas & Isaac Gusqui)

Anexo 2: Esquema sobre la arquitectura base de los modelos de RNA



(Creado por David Rodas & Isaac Gusqui)

Anexo 3: Código en Python de RNA modelo tendencial

```
def crear_modelo_trend(n_input, n_steps):
    # Se crean capas de entrada para recibir la fecha como variable
    # categorica

    meta_embedding_dims = 64

    months_input = Input(shape=(1,), name='Mes')
    months_embedding = Embedding(13, meta_embedding_dims)(months_input)
    months_reshape = Reshape((meta_embedding_dims,))(months_embedding)

    dayofweeks_input = Input(shape=(1,), name='Dia_de_la_semana')
    dayofweeks_embedding = Embedding(8,
    meta_embedding_dims)(dayofweeks_input)
    dayofweeks_reshape =
    Reshape((meta_embedding_dims,))(dayofweeks_embedding)

    dayofyears_input = Input(shape=(1,), name='Dia_del_year')
    dayofyears_embedding = Embedding(367,
    meta_embedding_dims)(dayofyears_input)
    dayofyears_reshape =
    Reshape((meta_embedding_dims,))(dayofyears_embedding)

    # Se crea otra capa de entrada para recibir las demandas
    in_cli = Input(shape=[n_input], name='Demanda')
    capa_1 = Dense(24 * n_steps + 64 * 3, activation='tanh')(in_cli)

    # Se realiza un concatenacion de las 3 entradas categoricas y se
    # redimensiona en un vector
    concatenacion = concatenate([(months_reshape), (dayofweeks_reshape),
    (dayofyears_reshape), (capa_1)])
    capa_2 = Dense(150, activation='tanh')(concatenacion)
    outp = Dense(24, activation='tanh')(capa_2)
    # Se crea el modelo de la red con 3 capas, entrada, hidden, salida
    model = Model(inputs=[months_input, dayofweeks_input, dayofyears_input,
    in_cli], outputs=outp)
    # Se compila el modelo
    model.compile(loss='huber_loss',
                  optimizer=optimizers.SGD(learning_rate=0.1),
                  metrics=['accuracy'])
    model.summary()
    return model
```

(Creado por David Rodas & Isaac Gusqui)

Anexo 4: Código en Python de RNA modelo estacional

```
def crear_modelo_seasonal(n_input,n_steps):
    # Se crean capas de entrada para recibir la fecha como variable
    # categorica
    meta_embedding_dims = 64

    months_input = Input(shape=(1,), name='Mes')
    months_embedding = Embedding(13, meta_embedding_dims)(months_input)
    months_reshape = Reshape((meta_embedding_dims,))(months_embedding)

    dayofweeks_input = Input(shape=(1,), name='Dia_de_la_semana')
    dayofweeks_embedding = Embedding(8,
    meta_embedding_dims)(dayofweeks_input)
    dayofweeks_reshape =
    Reshape((meta_embedding_dims,))(dayofweeks_embedding)

    dayofyears_input = Input(shape=(1,), name='Dia_del_year')
    dayofyears_embedding = Embedding(367,
    meta_embedding_dims)(dayofyears_input)
    dayofyears_reshape =
    Reshape((meta_embedding_dims,))(dayofyears_embedding)

    # Se crea otra capa de entrada para recibir las demandas
    in_cli = Input(shape=[n_input], name='Demanda')
    capa_1 = Dense(24*n_steps+64*3, activation='tanh')(in_cli)
    oculta_1 = Dense((24*n_steps+64*3)*2, activation='tanh')(capa_1)

    # Se realiza un concatenacion de las 3 entradas categoricas y se
    # redimensiona en un vector
    concatenacion = concatenate([(months_reshape), (dayofweeks_reshape),
    (dayofyears_reshape), (oculta_1)])

    # Se crea el modelo de la red con 3 capas, entrada, hidden, salida
    oculta_2 = Dense(100, activation='tanh')(concatenacion)
    oculta_2 = BatchNormalization()(oculta_2)
    outp = Dense(24, activation='tanh')(oculta_2)
    model = Model(inputs=[months_input, dayofweeks_input, dayofyears_input,
    in_cli], outputs=outp)

    # Se compila el modelo
    model.compile(loss='mse',
    optimizer=optimizers.SGD(learning_rate=0.05,
    momentum=0.02),
    metrics=['accuracy'])
    model.summary()
    return model
```

(Creado por David Rodas & Isaac Gusqui)

Anexo 5: Código en Python de RNA modelo residuo

```
def crear_modelo_resid(n_input, n_steps):
    # Se crean capas de entrada para recibir la fecha como variable
    # categorica

    meta_embedding_dims = 64

    months_input = Input(shape=(1,), name='Mes')
    months_embedding = Embedding(13, meta_embedding_dims)(months_input)
    months_reshape = Reshape((meta_embedding_dims,))(months_embedding)

    dayofweeks_input = Input(shape=(1,), name='Dia_de_la_semana')
    dayofweeks_embedding = Embedding(8,
    meta_embedding_dims)(dayofweeks_input)
    dayofweeks_reshape =
    Reshape((meta_embedding_dims,))(dayofweeks_embedding)

    dayofyears_input = Input(shape=(1,), name='Dia_del_year')
    dayofyears_embedding = Embedding(367,
    meta_embedding_dims)(dayofyears_input)
    dayofyears_reshape =
    Reshape((meta_embedding_dims,))(dayofyears_embedding)

    # Se crea otra capa de entrada para recibir las demandas
    in_cli = Input(shape=[n_input], name='Demanda')
    capa_1 = Dense(24*n_steps+64*3, activation='tanh')(in_cli)
    capa_1 = Dense(50, activation='tanh')(capa_1)
    capa_1 = Dense(24*n_steps+64*3, activation='tanh')(capa_1)
    # Se realiza un concatenacion de las 3 entradas categoricas y se
    # redimensiona en un vector
    concatenacion = concatenate([(months_reshape), (dayofweeks_reshape),
    (dayofyears_reshape), (capa_1)])

    # Se crea el modelo de la red con 3 capas, entrada, hidden, salida
    capa_2 = Dense(250, activation='tanh')(concatenacion)
    outp = Dense(24, activation='tanh')(capa_2)
    model = Model(inputs=[months_input, dayofweeks_input, dayofyears_input,
    in_cli], outputs=outp)

    # Se compila el modelo
    model.compile(loss='mae',
                  optimizer=optimizers.SGD(learning_rate=0.99),
                  metrics=['accuracy'])
    model.summary()
    return model
```

(Creado por David Rodas & Isaac Gusqui)

Anexo 6: Código en Matlab R2021a para análisis de confiabilidad

```
%DAVID RODAS & ISAAC GUSQUI
% EVALUACION DE LA CONFIABILIDAD DEL SISTEMA EN HL1
% Adecuación de la Generación de la usando Monte Carlo No Secuencial
clear all
clc

% Datos de entrada:
% Datos de cada unidad de los generadores
% Datos de carga (Demanda pico MW/yr)

T=readtable("DEM_2021_2029.csv");
Tabla=T(:,[7 6]);
%perfil de carga anual
filtro22=T.datetime>=datetime('2022-01-01') & T.datetime<datetime('2023-01-01');
T_2022= Tabla(filtro22,:);

filtro23=T.datetime>=datetime('2023-01-01') & T.datetime<datetime('2024-01-01');
T_2023=Tabla(filtro23,:);

filtro24=T.datetime>=datetime('2024-01-01') & T.datetime<datetime('2025-01-01');
T_2024=Tabla(filtro24,:);

filtro25=T.datetime>=datetime('2025-01-01') & T.datetime<datetime('2026-01-01');
T_2025=Tabla(filtro25,:);

filtro26=T.datetime>=datetime('2026-01-01') & T.datetime<datetime('2027-01-01');
T_2026=Tabla(filtro26,:);

filtro27=T.datetime>=datetime('2027-01-01') & T.datetime<datetime('2028-01-01');
T_2027=Tabla(filtro27,:);

filtro28=T.datetime>=datetime('2028-01-01') & T.datetime<datetime('2029-01-01');
T_2028=Tabla(filtro28,:);
```

```

filtro29=T.datetime>=datetime('2029-01-01') & T.datetime<datetime('2030-01-01');
T_2029=Tabla(filtro29,:);

num_datos=table2array(T(:, "Var1"));
%datos de carga de cada año
peak_demand2022=max(T_2022.Demanda_Total)
peak_demand2023=max(T_2023.Demanda_Total)
peak_demand2024=max(T_2024.Demanda_Total)
peak_demand2025=max(T_2025.Demanda_Total)
peak_demand2026=max(T_2026.Demanda_Total)
peak_demand2027=max(T_2027.Demanda_Total)
peak_demand2028=max(T_2028.Demanda_Total)
peak_demand2029=max(T_2029.Demanda_Total)

%datos de potencia de generadores
TG=readtable("Capacidad Efectivas 2022-11-23.xlsx");
U_gen=TG(:, [2 4 8]);
m_UnidadGen=transpose(double(1:height(U_gen)));
m_pot_efectiva=table2array(U_gen(:, "PotenciaEfectiva"));
m_U_gen=[m_UnidadGen,m_pot_efectiva.*0.8]; %reserva minima 20% resolución
CENACE

%PLAN EXPANSIÓN PME 2018-2027
I=readtable("Horas de Indisponibilidad por falla 2018 - 2022.xlsx");
m_hrs_i_porfalla=table2array(I(:, "M_ximoValor"));
m_horas_ind_por_falla=[m_UnidadGen,m_hrs_i_porfalla];

%obtención tasa de falla
%se considera una tasa de envejecimiento de generadoras de 5% para cada año
m_lambda_2022=(1).*(1./(height(T_2022)-m_horas_ind_por_falla(:,2))); % [f/h]
m_lambda_2023=(1.05).*(1./(height(T_2023)-m_horas_ind_por_falla(:,2))); % [f/h]
m_lambda_2024=(1.10).*(1./(height(T_2024)-m_horas_ind_por_falla(:,2))); % [f/h]
m_lambda_2025=(1.15).*(1./(height(T_2025)-m_horas_ind_por_falla(:,2))); % [f/h]
m_lambda_2026=(1.20).*(1./(height(T_2026)-m_horas_ind_por_falla(:,2))); % [f/h]
m_lambda_2027=(1.25).*(1./(height(T_2027)-m_horas_ind_por_falla(:,2))); % [f/h]
m_lambda_2028=(1.30).*(1./(height(T_2028)-m_horas_ind_por_falla(:,2))); % [f/h]
m_lambda_2029=(1.35).*(1./(height(T_2029)-m_horas_ind_por_falla(:,2))); % [f/h]

%obtención tasa de reparacion
m_u=(1./m_horas_ind_por_falla(:,2)); % [r/h]

%obtencion del FOR tasa de interrupcion forzada
mU_FOR_2022=m_lambda_2022./(m_u+m_lambda_2022); % [-]
mU_FOR_2023=m_lambda_2023./(m_u+m_lambda_2023); % [-]
mU_FOR_2024=m_lambda_2024./(m_u+m_lambda_2024); % [-]
mU_FOR_2025=m_lambda_2025./(m_u+m_lambda_2025); % [-]
mU_FOR_2026=m_lambda_2026./(m_u+m_lambda_2026); % [-]
mU_FOR_2027=m_lambda_2027./(m_u+m_lambda_2027); % [-]
mU_FOR_2028=m_lambda_2028./(m_u+m_lambda_2028); % [-]

```

```

mU_FOR_2029=m_lambda_2029./(m_u+m_lambda_2029); % [-]

% Agrupación de información de generadores en una matriz
% P[MW] FOR[-]
Gen_2022=[m_U_gen(:,2) mU_FOR_2022];
Gen_2023=[m_U_gen(:,2) mU_FOR_2023];
Gen_2024=[m_U_gen(:,2) mU_FOR_2024];
Gen_2025=[m_U_gen(:,2) mU_FOR_2025];
Gen_2026=[m_U_gen(:,2) mU_FOR_2026];
Gen_2027=[m_U_gen(:,2) mU_FOR_2027];
Gen_2028=[m_U_gen(:,2) mU_FOR_2028];
Gen_2029=[m_U_gen(:,2) mU_FOR_2029];

% Monte Carlo No Secuencial
NE=1000; % Número de experimentos
TS_2022= height(T_2022); % Tiempo de estudio 2022
TS_2023= height(T_2023); % Tiempo de estudio 2023
TS_2024= height(T_2024); % Tiempo de estudio 2024
TS_2025= height(T_2025); % Tiempo de estudio 2025
TS_2026= height(T_2026); % Tiempo de estudio 2026
TS_2027= height(T_2027); % Tiempo de estudio 2027
TS_2028= height(T_2028); % Tiempo de estudio 2028
TS_2029= height(T_2029); % Tiempo de estudio 2029

% Matriz FOR para el tiempo de estudio
FOR_2022= repmat(Gen_2022(:,2),1,TS_2022);
FOR_2023= repmat(Gen_2023(:,2),1,TS_2023);
FOR_2024= repmat(Gen_2024(:,2),1,TS_2024);
FOR_2025= repmat(Gen_2025(:,2),1,TS_2025);
FOR_2026= repmat(Gen_2026(:,2),1,TS_2026);
FOR_2027= repmat(Gen_2027(:,2),1,TS_2027);
FOR_2028= repmat(Gen_2028(:,2),1,TS_2028);
FOR_2029= repmat(Gen_2029(:,2),1,TS_2029);

for e=1:NE

    %2022
    % Obtener dimensión de la matriz
    [u,v]=size(Gen_2022);% size for generation
    % Generación de probabilidades: filas-> componente; columnas->horas
    Operation_r_2022 = rand(u,TS_2022);
    % Generación de estado operacional-> 1-> opera; 0-> fuera de servicio
    Operation_g_2022 = Operation_r_2022>FOR_2022; % Possibilities of generation
    % Generación disponible
    generation_P_2022=sum(Operation_g_2022.*Gen_2022(:,1));
    % Reserva de energía
    T_2022_n=T_2022.Demanda_Total;
    T_2022_m=transpose(T_2022_n);
    Reserve_P_2022=generation_P_2022-T_2022_m;
    % Consecuencia de las fallas
    R_P_2022=find(Reserve_P_2022<0);
    [r_P_2022,c_P_2022]=size(R_P_2022); % number rows out range maximum

```

```

% rows -> experiments % column -> years
% LOLE: Loss of Load Expectation
LOLE_2022(e) = c_P_2022; % [hora/año]
% LOLP: Loss of Load Probability [%]
LOLP_2022(e) = (LOLE_2022(e)/TS_2022)*100; % [%]
% EENS: Expected Energy Not Supplied [MWh/año]
EENS_2022(e) = abs(sum(Reserve_P_2022(R_P_2022))); % [MWh/año]

%2023
% Obtener dimensión de la matriz
[u,v]=size(Gen_2023);% size for generation
% Generación de probabilidades: filas-> componente; columnas->horas
Operation_r_2023 = rand(u,TS_2023);
% Generación de estado operacional-> 1-> opera; 0-> fuera de servicio
Operation_g_2023 = Operation_r_2023>FOR_2023; % Possibilities of generation
% Generación disponible
generation_P_2023=sum(Operation_g_2023.*Gen_2023(:,1));
% Reserva de energía
T_2023_n=T_2023.Demanda_Total;
T_2023_m=transpose(T_2023_n);
Reserve_P_2023=generation_P_2023-T_2023_m;
% Consecuecna de las fallas
R_P_2023=find(Reserve_P_2023<0);
[r_P_2023,c_P_2023]=size(R_P_2023); % number rows out range maximum
% rows -> experiments % column -> years
% LOLE: Loss of Load Expectation
LOLE_2023(e) = c_P_2023; % [hora/año]
% LOLP: Loss of Load Probability [%]
LOLP_2023(e) = (LOLE_2023(e)/TS_2023)*100; % [%]
% EENS: Expected Energy Not Supplied [MWh/año]
EENS_2023(e) = abs(sum(Reserve_P_2023(R_P_2023))); % [MWh/año]

%2024
% Obtener dimensión de la matriz
[u,v]=size(Gen_2024);% size for generation
% Generación de probabilidades: filas-> componente; columnas->horas
Operation_r_2024 = rand(u,TS_2024);
% Generación de estado operacional-> 1-> opera; 0-> fuera de servicio
Operation_g_2024 = Operation_r_2024>FOR_2024; % Possibilities of generation
% Generación disponible
generation_P_2024=sum(Operation_g_2024.*Gen_2024(:,1));
% Reserva de energía
T_2024_n=T_2024.Demanda_Total;
T_2024_m=transpose(T_2024_n);
Reserve_P_2024=generation_P_2024-T_2024_m;
% Consecuecna de las fallas
R_P_2024=find(Reserve_P_2024<0);
[r_P_2024,c_P_2024]=size(R_P_2024); % number rows out range maximum
% rows -> experiments % column -> years
% LOLE: Loss of Load Expectation
LOLE_2024(e) = c_P_2024; % [hora/año]
% LOLP: Loss of Load Probability [%]
LOLP_2024(e) = (LOLE_2024(e)/TS_2024)*100; % [%]

```

```

% EENS: Expected Energy Not Supplied [MWh/año]
EENS_2024(e) = abs(sum(Reserve_P_2024(R_P_2024))); % [MWh/año]

%2025
% Obtener dimensión de la matriz
[u,v]=size(Gen_2025);% size for generation
% Generación de probabilidades: filas-> componente; columnas->horas
Operation_r_2025 = rand(u,TS_2025);
% Generación de estado operacional-> 1-> opera; 0-> fuera de servicio
Operation_g_2025 = Operation_r_2025>FOR_2025; % Possibilities of generation
% Generación disponible
generation_P_2025=sum(Operation_g_2025.*Gen_2025(:,1));
% Reserva de energía
T_2025_n=T_2025.Demanda_Total;
T_2025_m=transpose(T_2025_n);
Reserve_P_2025=generation_P_2025-T_2025_m;
% Consecuecna de las fallas
R_P_2025=find(Reserve_P_2025<0);
[r_P_2025,c_P_2025]=size(R_P_2025); % number rows out range maximum
% rows -> experiments % column -> years
% LOLE: Loss of Load Expectation
LOLE_2025(e) = c_P_2025; % [hora/año]
% LOLP: Loss of Load Probability [%]
LOLP_2025(e) = (LOLE_2025(e)/TS_2025)*100; % [%]
% EENS: Expected Energy Not Supplied [MWh/año]
EENS_2025(e) = abs(sum(Reserve_P_2025(R_P_2025))); % [MWh/año]

%2026
% Obtener dimensión de la matriz
[u,v]=size(Gen_2026);% size for generation
% Generación de probabilidades: filas-> componente; columnas->horas
Operation_r_2026 = rand(u,TS_2026);
% Generación de estado operacional-> 1-> opera; 0-> fuera de servicio
Operation_g_2026 = Operation_r_2026>FOR_2026; % Possibilities of generation
% Generación disponible
generation_P_2026=sum(Operation_g_2026.*Gen_2026(:,1));
% Reserva de energía
T_2026_n=T_2026.Demanda_Total;
T_2026_m=transpose(T_2026_n);
Reserve_P_2026=generation_P_2026-T_2026_m;
% Consecuecna de las fallas
R_P_2026=find(Reserve_P_2026<0);
[r_P_2026,c_P_2026]=size(R_P_2026); % number rows out range maximum
% rows -> experiments % column -> years
% LOLE: Loss of Load Expectation
LOLE_2026(e) = c_P_2026; % [hora/año]
% LOLP: Loss of Load Probability [%]
LOLP_2026(e) = (LOLE_2026(e)/TS_2026)*100; % [%]
% EENS: Expected Energy Not Supplied [MWh/año]
EENS_2026(e) = abs(sum(Reserve_P_2026(R_P_2026))); % [MWh/año]

%2027
% Obtener dimensión de la matriz

```

```

[u,v]=size(Gen_2027);% size for generation
% Generación de probabilidades: filas-> componente; columnas->horas
Operation_r_2027 = rand(u,TS_2027);
% Generación de estado operacional-> 1-> opera; 0-> fuera de servicio
Operation_g_2027 = Operation_r_2027>FOR_2027; % Possibilities of generation
% Generación disponible
generation_P_2027=sum(Operation_g_2027.*Gen_2027(:,1));
% Reserva de energía
T_2027_n=T_2027.Demanda_Total;
T_2027_m=transpose(T_2027_n);
Reserve_P_2027=generation_P_2027-T_2027_m;
% Consecuecna de las fallas
R_P_2027=find(Reserve_P_2027<0);
[r_P_2027,c_P_2027]=size(R_P_2027); % number rows out range maximum
% rows -> experiments % column -> years
% LOLE: Loss of Load Expectation
LOLE_2027(e) = c_P_2027; % [hora/año]
% LOLP: Loss of Load Probability [%]
LOLP_2027(e) = (LOLE_2027(e)/TS_2027)*100; % [%]
% EENS: Expected Energy Not Supplied [MWh/año]
EENS_2027(e) = abs(sum(Reserve_P_2027(R_P_2027))); % [MWh/año]

%2028
% Obtener dimensión de la matriz
[u,v]=size(Gen_2028);% size for generation
% Generación de probabilidades: filas-> componente; columnas->horas
Operation_r_2028 = rand(u,TS_2028);
% Generación de estado operacional-> 1-> opera; 0-> fuera de servicio
Operation_g_2028 = Operation_r_2028>FOR_2028; % Possibilities of generation
% Generación disponible
generation_P_2028=sum(Operation_g_2028.*Gen_2028(:,1));
% Reserva de energía
T_2028_n=T_2028.Demanda_Total;
T_2028_m=transpose(T_2028_n);
Reserve_P_2028=generation_P_2028-T_2028_m;
% Consecuecna de las fallas
R_P_2028=find(Reserve_P_2028<0);
[r_P_2028,c_P_2028]=size(R_P_2028); % number rows out range maximum
% rows -> experiments % column -> years
% LOLE: Loss of Load Expectation
LOLE_2028(e) = c_P_2028; % [hora/año]
% LOLP: Loss of Load Probability [%]
LOLP_2028(e) = (LOLE_2028(e)/TS_2028)*100; % [%]
% EENS: Expected Energy Not Supplied [MWh/año]
EENS_2028(e) = abs(sum(Reserve_P_2028(R_P_2028))); % [MWh/año]

%2029
% Obtener dimensión de la matriz
[u,v]=size(Gen_2029);% size for generation
% Generación de probabilidades: filas-> componente; columnas->horas
Operation_r_2029 = rand(u,TS_2029);
% Generación de estado operacional-> 1-> opera; 0-> fuera de servicio
Operation_g_2029 = Operation_r_2029>FOR_2029; % Possibilities of generation

```

```

% Generación disponible
generation_P_2029=sum(Operation_g_2029.*Gen_2029(:,1));
% Reserva de energía
T_2029_n=T_2029.Demanda_Total;
T_2029_m=transpose(T_2029_n);
Reserve_P_2029=generation_P_2029-T_2029_m;
% Consecuecna de las fallas
R_P_2029=find(Reserve_P_2029<0);
[r_P_2029,c_P_2029]=size(R_P_2029); % number rows out range maximum
% rows -> experiments % column -> years
% LOLE: Loss of Load Expectation
LOLE_2029(e) = c_P_2029; % [hora/año]
% LOLP: Loss of Load Probability [%]
LOLP_2029(e) = (LOLE_2029(e)/TS_2029)*100; % [%]
% EENS: Expected Energy Not Supplied [Mwh/año]
EENS_2029(e) = abs(sum(Reserve_P_2029(R_P_2029))); % [MWh/año]

```

end

% Respuestas

```

LOLE_m_2022 = mean(LOLE_2022) % [hora/año]
LOLP_m_2022 = mean(LOLP_2022) % [%]
EENS_m_2022 = mean(EENS_2022) % [Mwh/año]
XLLOL_m_2022 = EENS_m_2022/LOLE_m_2022 % [MW]

```

```

LOLE_m_2023 = mean(LOLE_2023) % [hora/año]
LOLP_m_2023 = mean(LOLP_2023) % [%]
EENS_m_2023 = mean(EENS_2023) % [Mwh/año]
XLLOL_m_2023 = EENS_m_2023/LOLE_m_2023 % [MW]

```

```

LOLE_m_2024 = mean(LOLE_2024) % [hora/año]
LOLP_m_2024 = mean(LOLP_2024) % [%]
EENS_m_2024 = mean(EENS_2024) % [Mwh/año]
XLLOL_m_2024 = EENS_m_2024/LOLE_m_2024 % [MW]

```

```

LOLE_m_2025 = mean(LOLE_2025) % [hora/año]
LOLP_m_2025 = mean(LOLP_2025) % [%]
EENS_m_2025 = mean(EENS_2025) % [Mwh/año]
XLLOL_m_2025 = EENS_m_2025/LOLE_m_2025 % [MW]

```

```

LOLE_m_2026 = mean(LOLE_2026) % [hora/año]
LOLP_m_2026 = mean(LOLP_2026) % [%]
EENS_m_2026 = mean(EENS_2026) % [Mwh/año]
XLLOL_m_2026 = EENS_m_2026/LOLE_m_2026 % [MW]

```

```

LOLE_m_2027 = mean(LOLE_2027) % [hora/año]
LOLP_m_2027 = mean(LOLP_2027) % [%]
EENS_m_2027 = mean(EENS_2027) % [Mwh/año]
XLLOL_m_2027 = EENS_m_2027/LOLE_m_2027 % [MW]

```

```

LOLE_m_2028 = mean(LOLE_2028) % [hora/año]
LOLP_m_2028 = mean(LOLP_2028) % [%]
EENS_m_2028 = mean(EENS_2028) % [Mwh/año]
XLLOL_m_2028 = EENS_m_2028/LOLE_m_2028 % [MW]

LOLE_m_2029 = mean(LOLE_2029) % [hora/año]
LOLP_m_2029 = mean(LOLP_2029) % [%]
EENS_m_2029 = mean(EENS_2029) % [Mwh/año]
XLLOL_m_2029 = EENS_m_2029/LOLE_m_2029 % [MW]

indice_conf_anual=tiledlayout(2,2)
title(indice_conf_anual,'INDICES DE CONFIABILIDAD NIVEL JERARQUICO 1')
time=[2023,2024,2025,2026,2027,2028,2029]

nexttile
LOLE=[LOLE_m_2023,LOLE_m_2024,LOLE_m_2025,LOLE_m_2026,LOLE_m_2027,LOLE_m_2028,
LOLE_m_2029]
plot(time,LOLE)
title('ESPERANZA DE PÉRDIDA DE CARGA LOLE'), xlabel('[año]'),
ylabel('[hora/año]')

nexttile
LOLP=[LOLP_m_2023,LOLP_m_2024,LOLP_m_2025,LOLP_m_2026,LOLP_m_2027,LOLP_m_2028,
LOLP_m_2029]
plot(time,LOLP)
title('PROBABILIDAD DE PÉRDIDA DE CARGA LOLP'), xlabel('[año]'), ylabel('[%]')

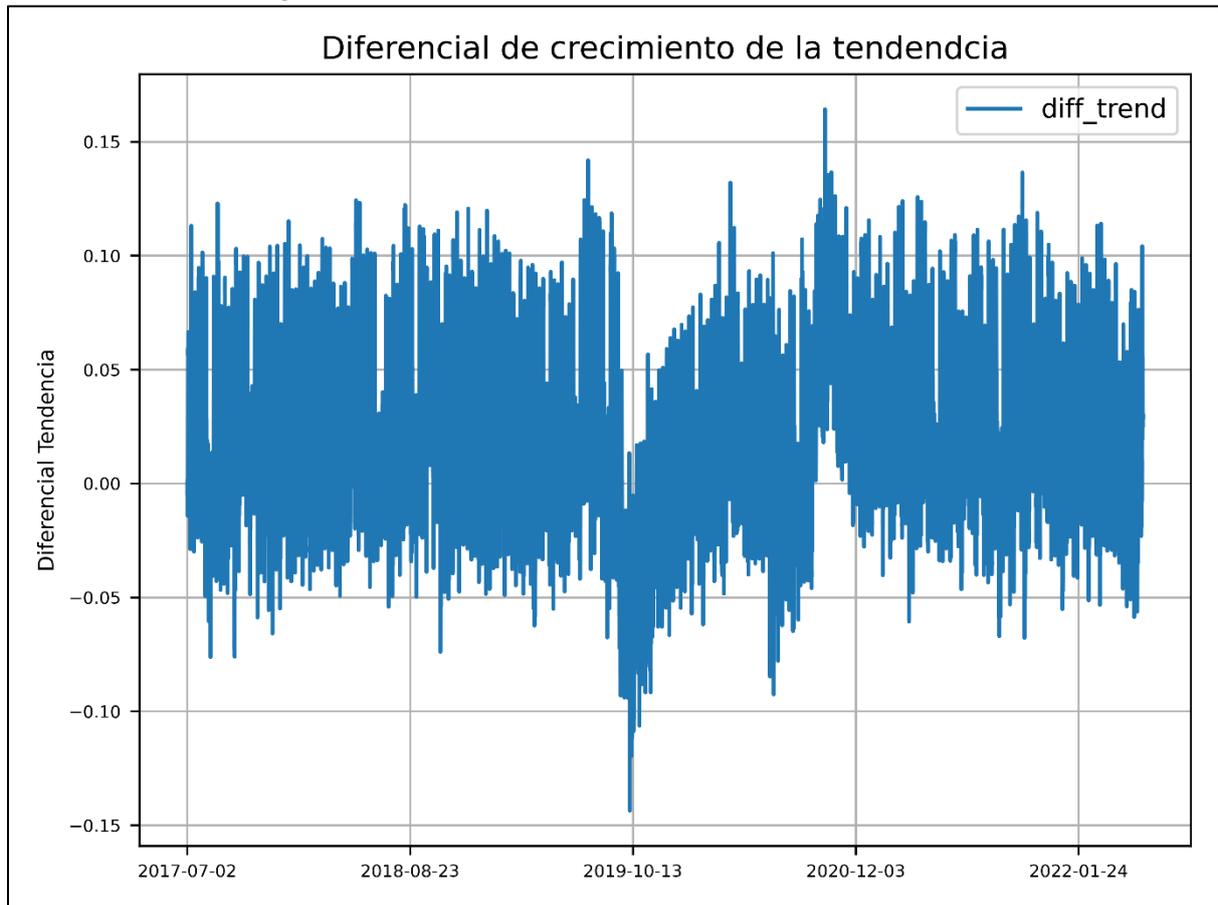
nexttile
EENS=[EENS_m_2023,EENS_m_2024,EENS_m_2025,EENS_m_2026,EENS_m_2027,EENS_m_2028,
EENS_m_2029]
plot(time,EENS)
title('VALOR ANUAL ESPERADO DE ENERGIA NO SUMINISTRADA'), xlabel('[año]'),
ylabel('[Mwh/año]')

nexttile
XLLOL=[XLLOL_m_2023,XLLOL_m_2024,XLLOL_m_2025,XLLOL_m_2026,XLLOL_m_2027,XLLOL_m_2028,
XLLOL_m_2029]
plot(time,XLLOL)
title('PORCENTAJE DE ENERGIA NO SUPLIDA'), xlabel('[año]'), ylabel('[%]')

```

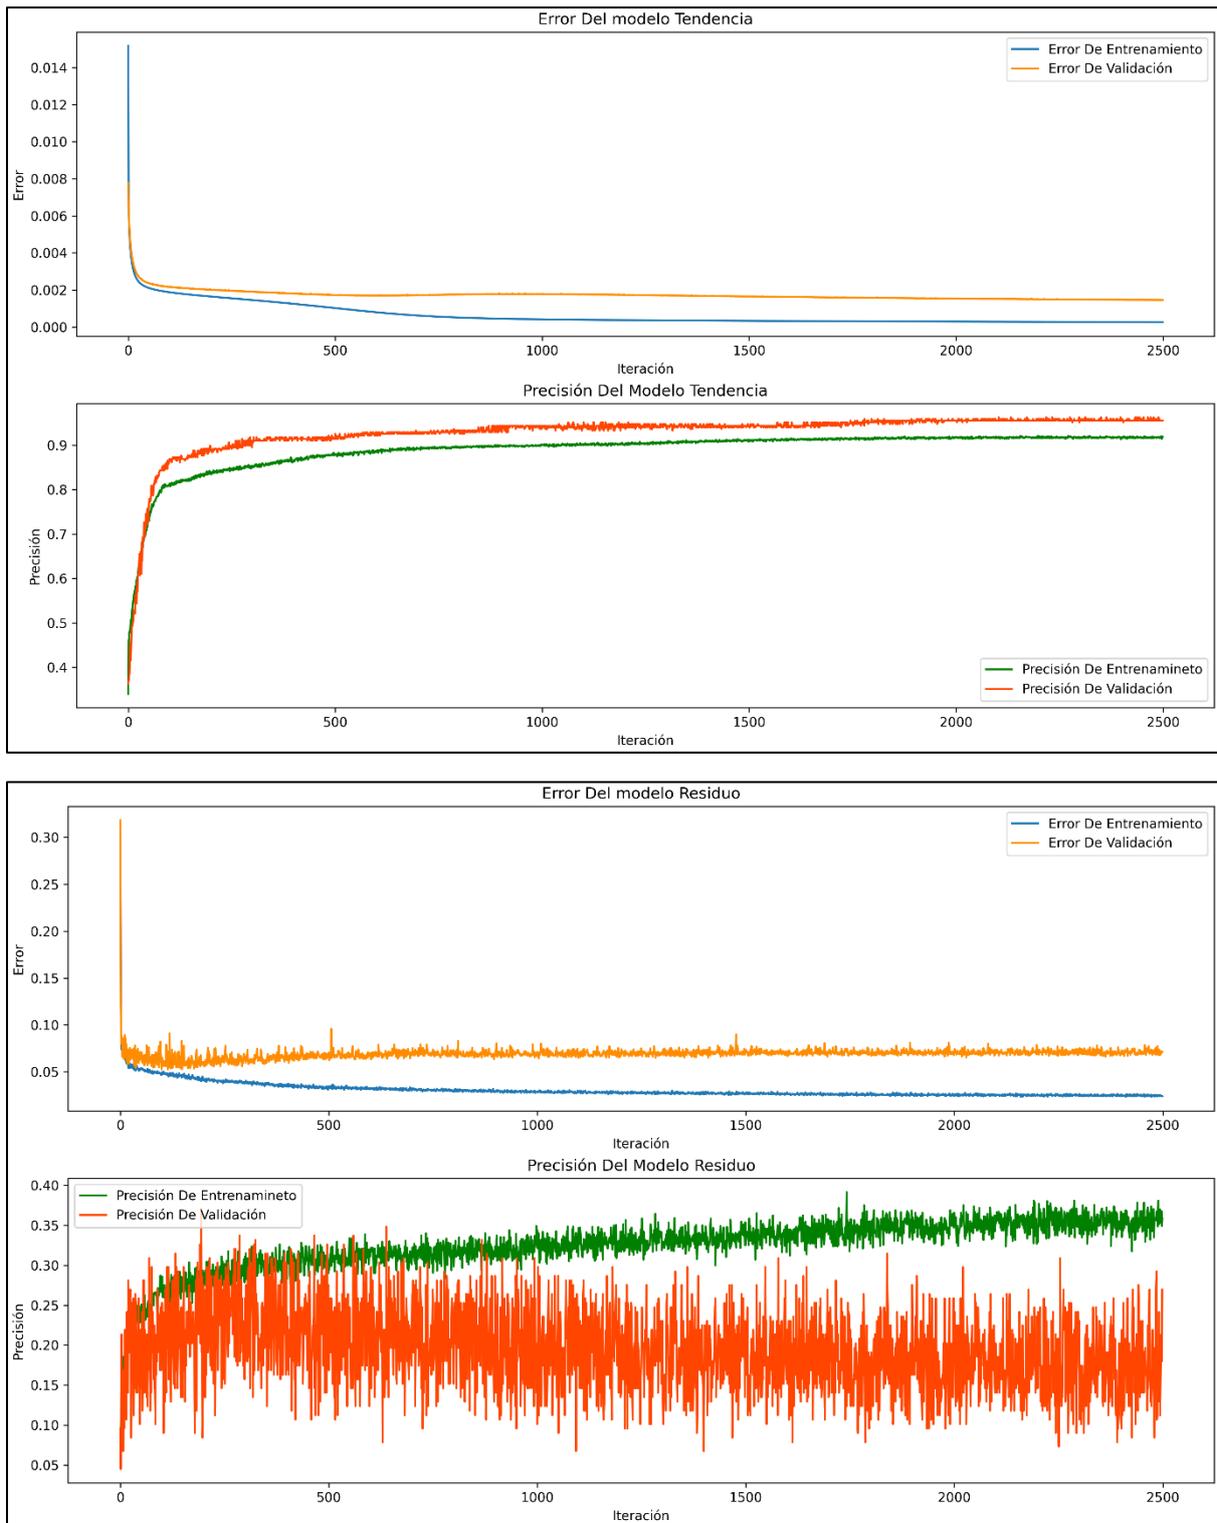
(Creado por David Rodas & Isaac Gusqui)

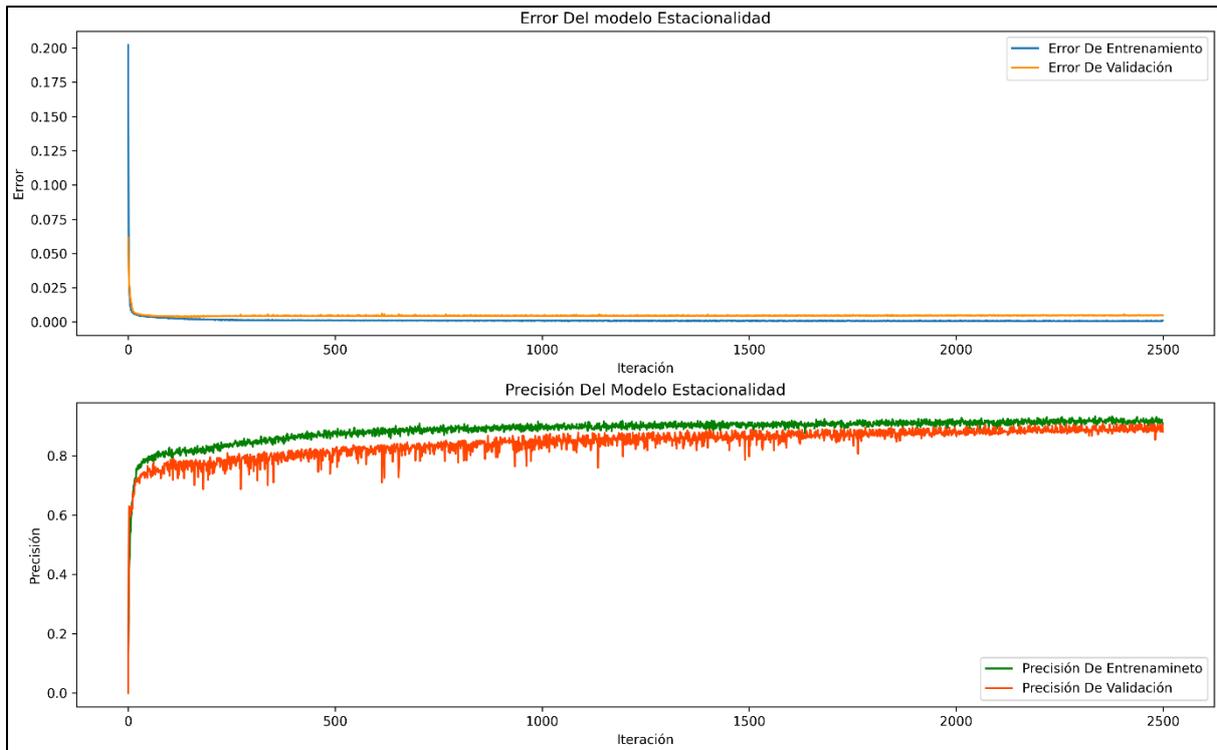
Anexo 7: Comportamiento diferencial de tendencia demanda 2017-2022



(Creado por David Rodas & Isaac Gusqui)

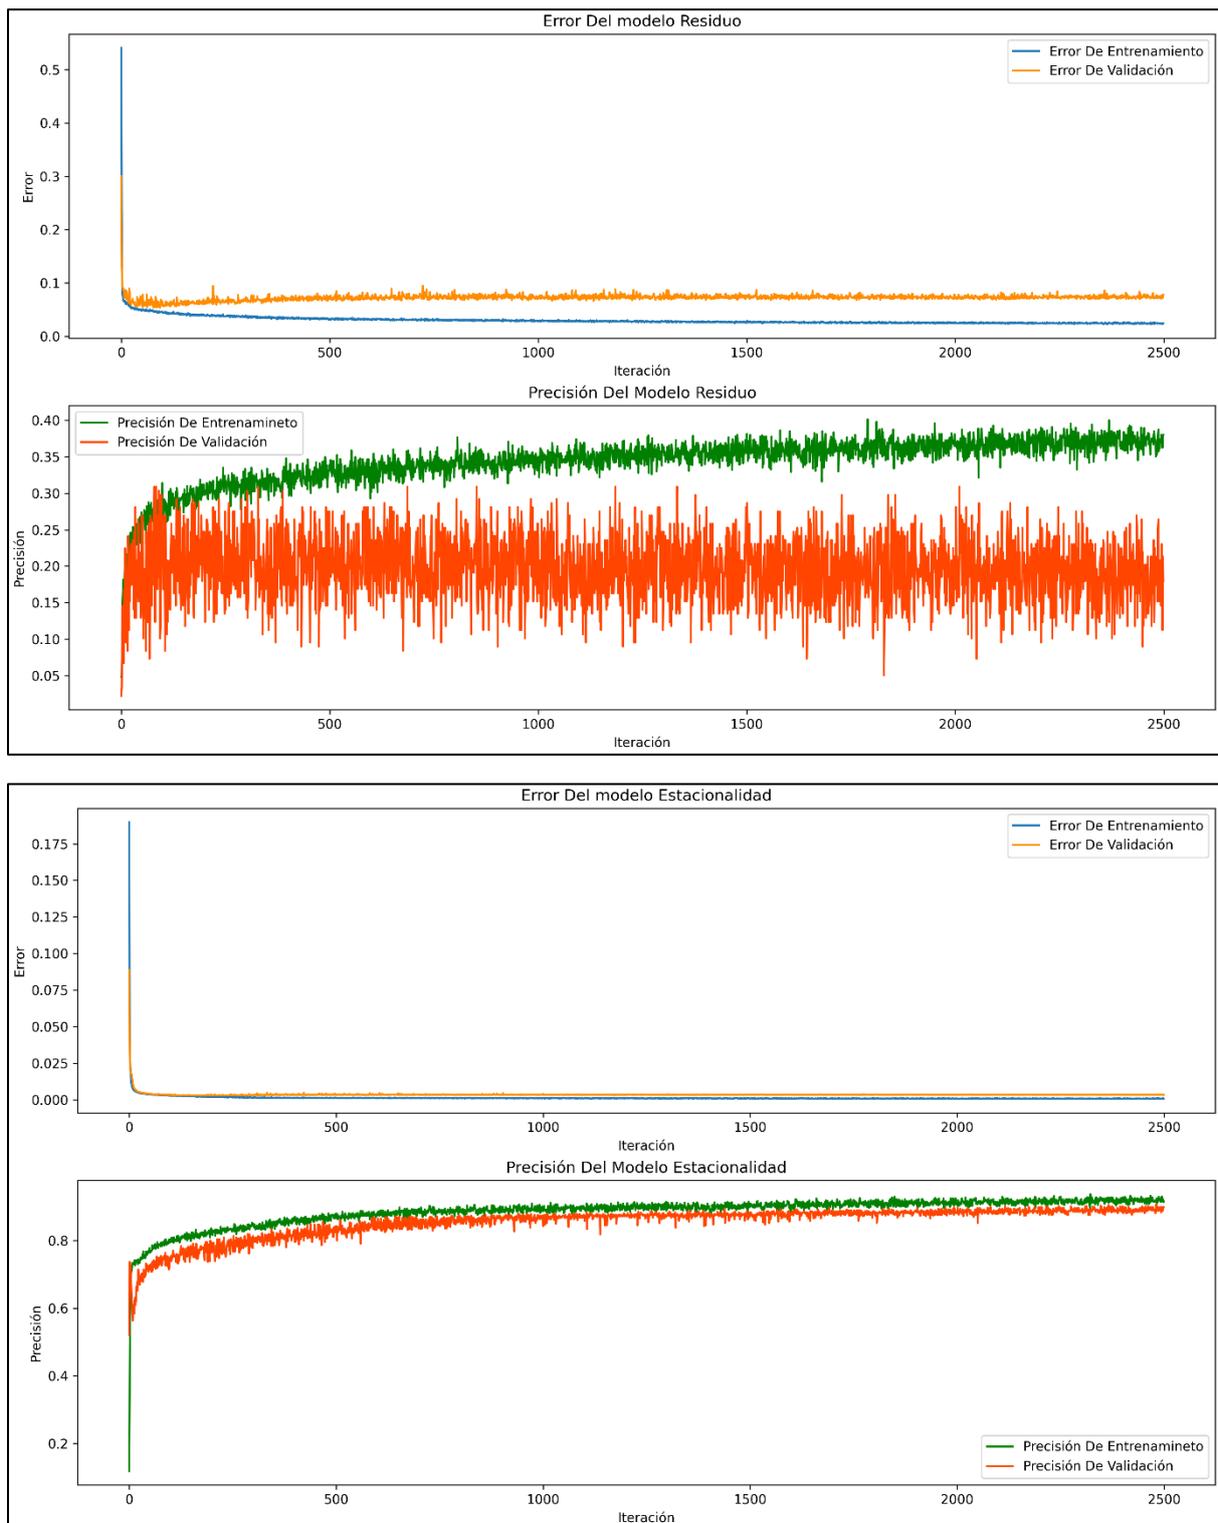
Anexo 8: Resultados de rendimiento de los 3 modelos RNA N_steps =3

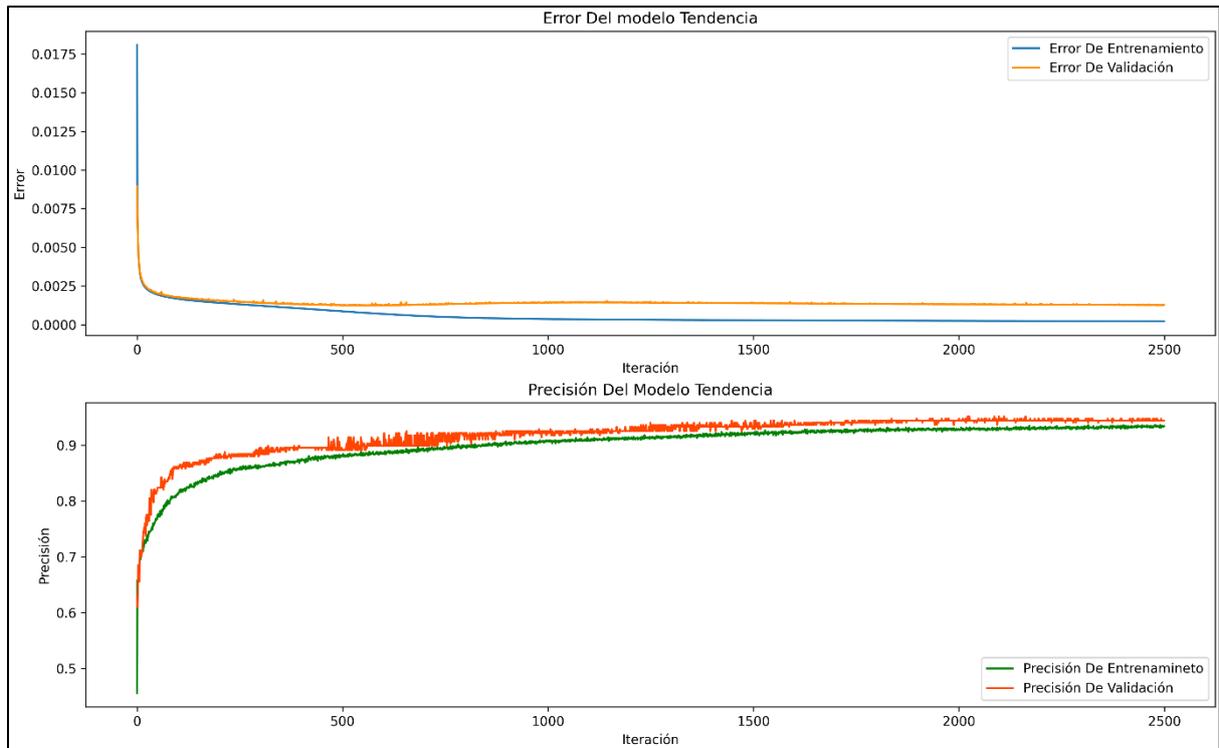




(Creado por David Rodas & Isaac Gusqui)

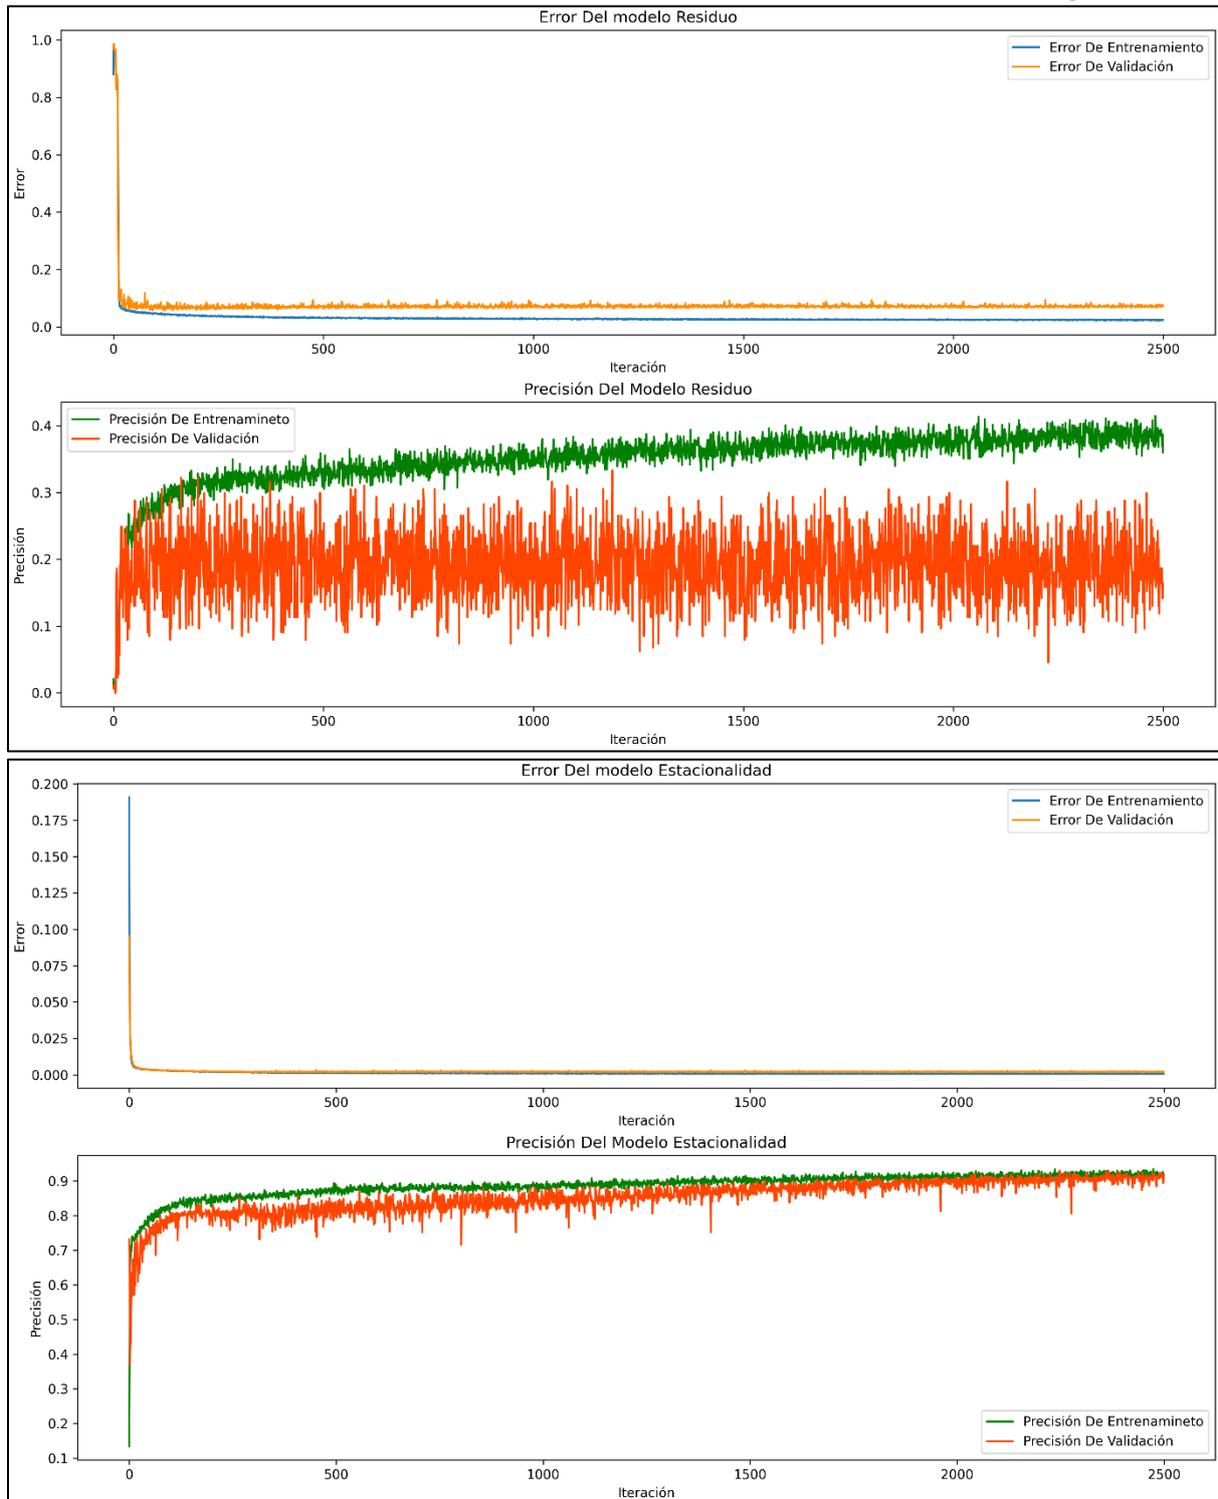
Anexo 9: Resultados de rendimiento de los 3 modelos RNA N_steps =6

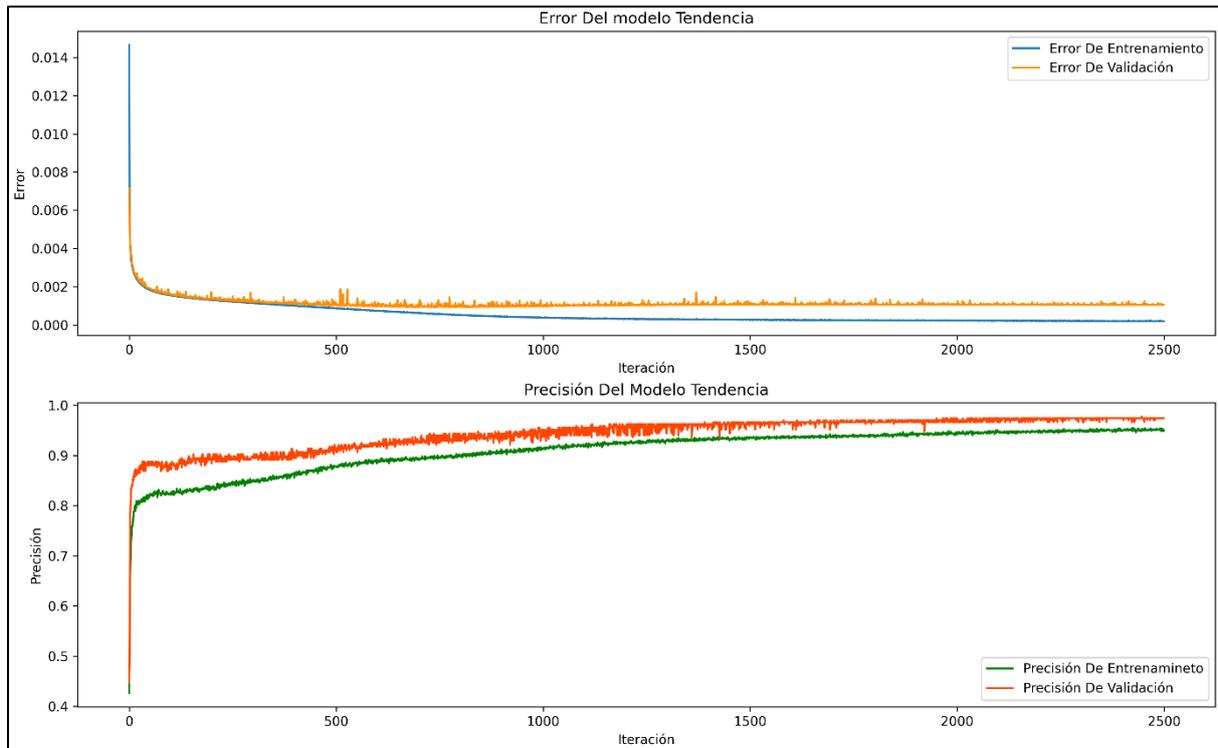




(Creado por David Rodas & Isaac Gusqui)

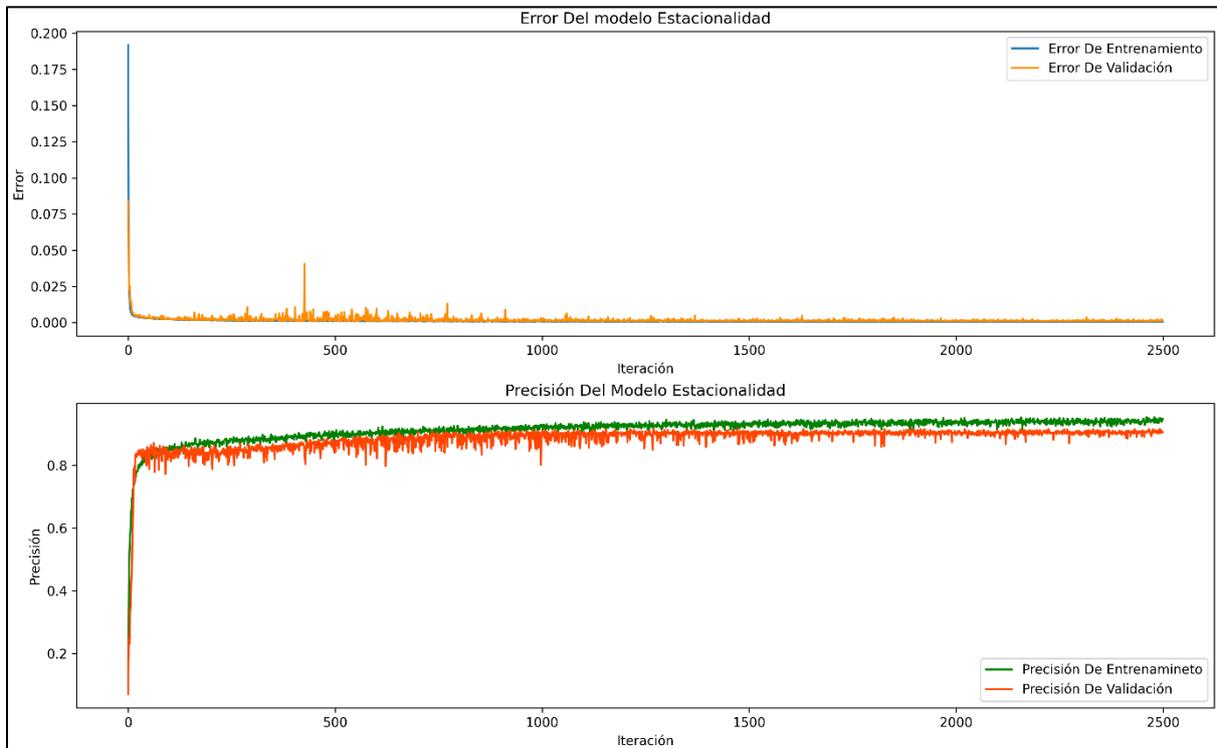
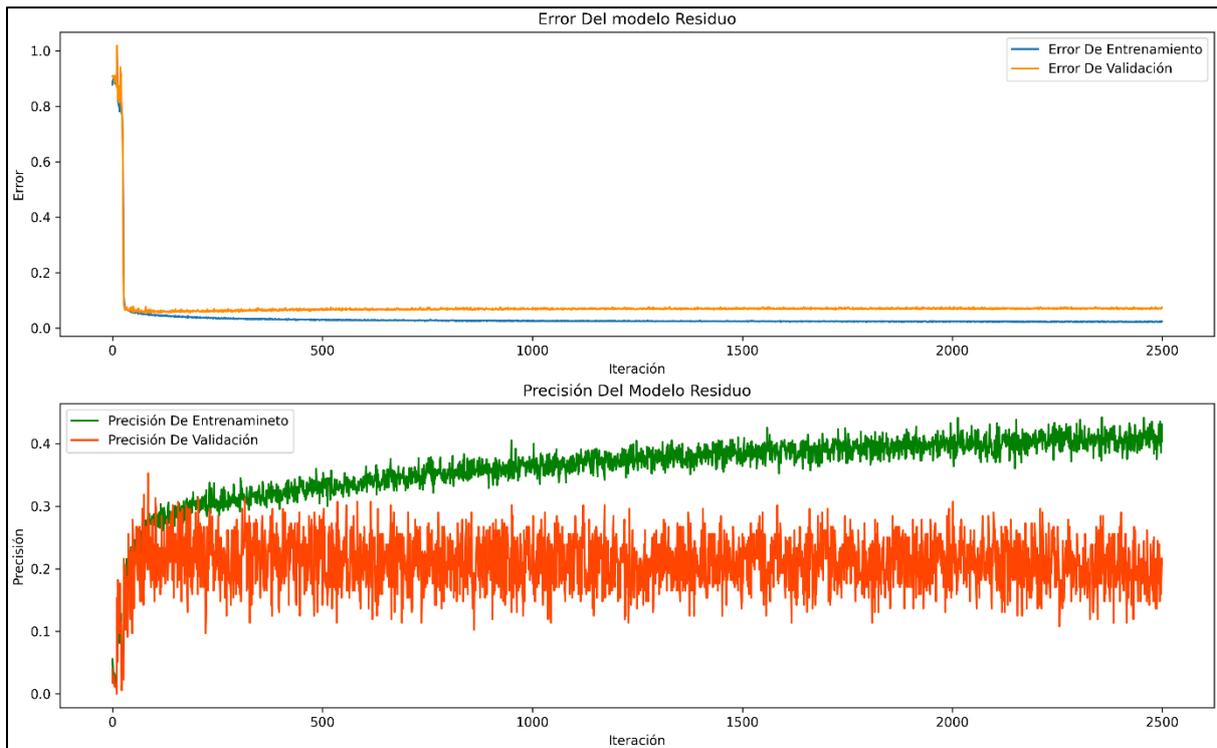
Anexo 10: Resultados de rendimiento de los 3 modelos RNA N_steps = 13

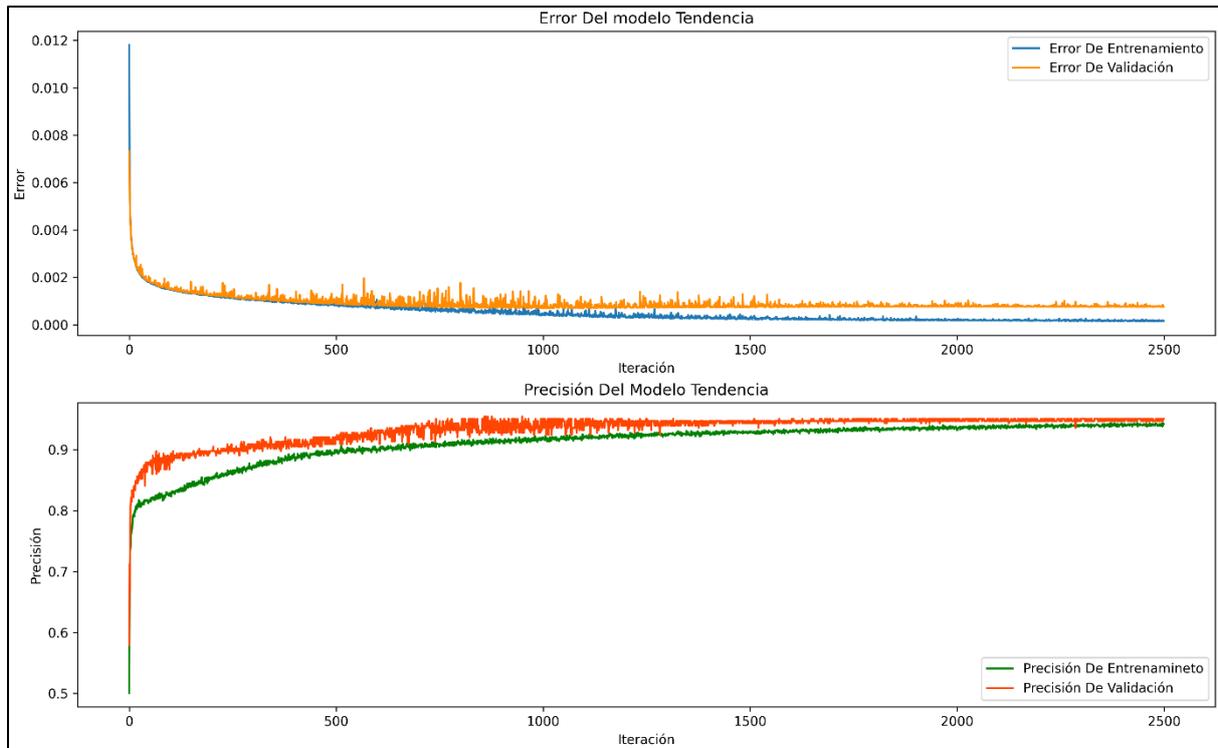




(Creado por David Rodas & Isaac Gusqui)

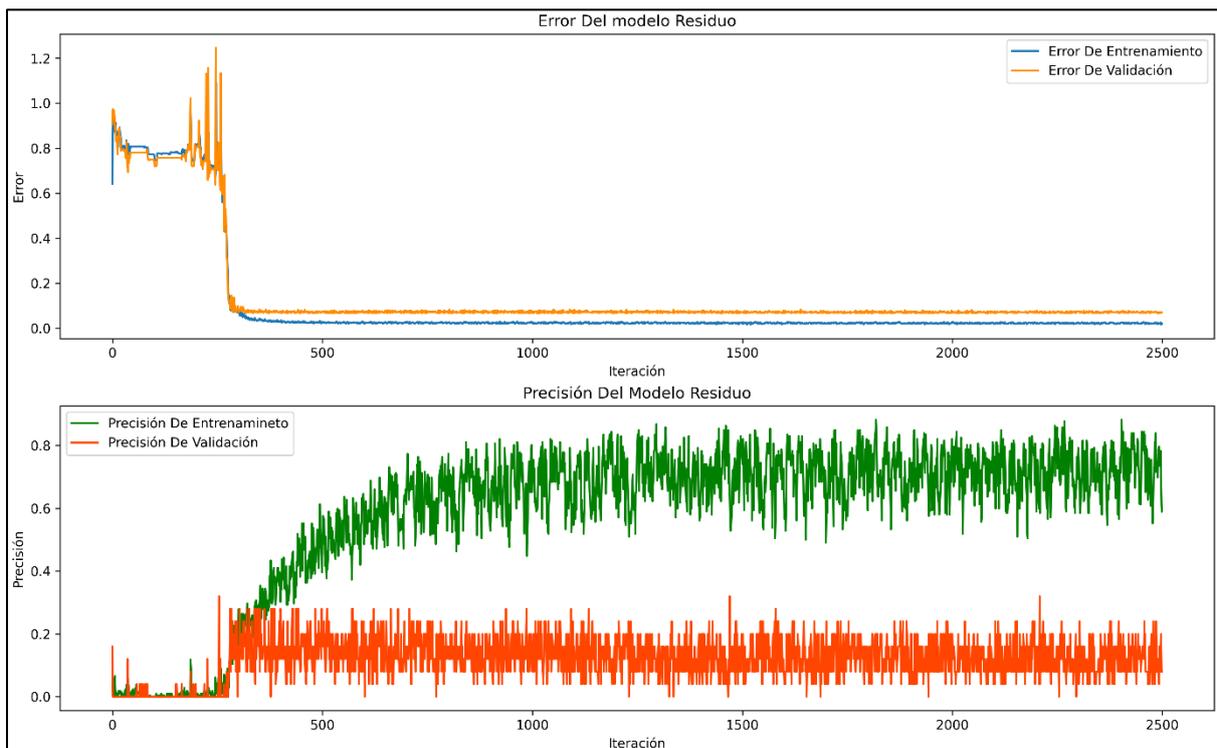
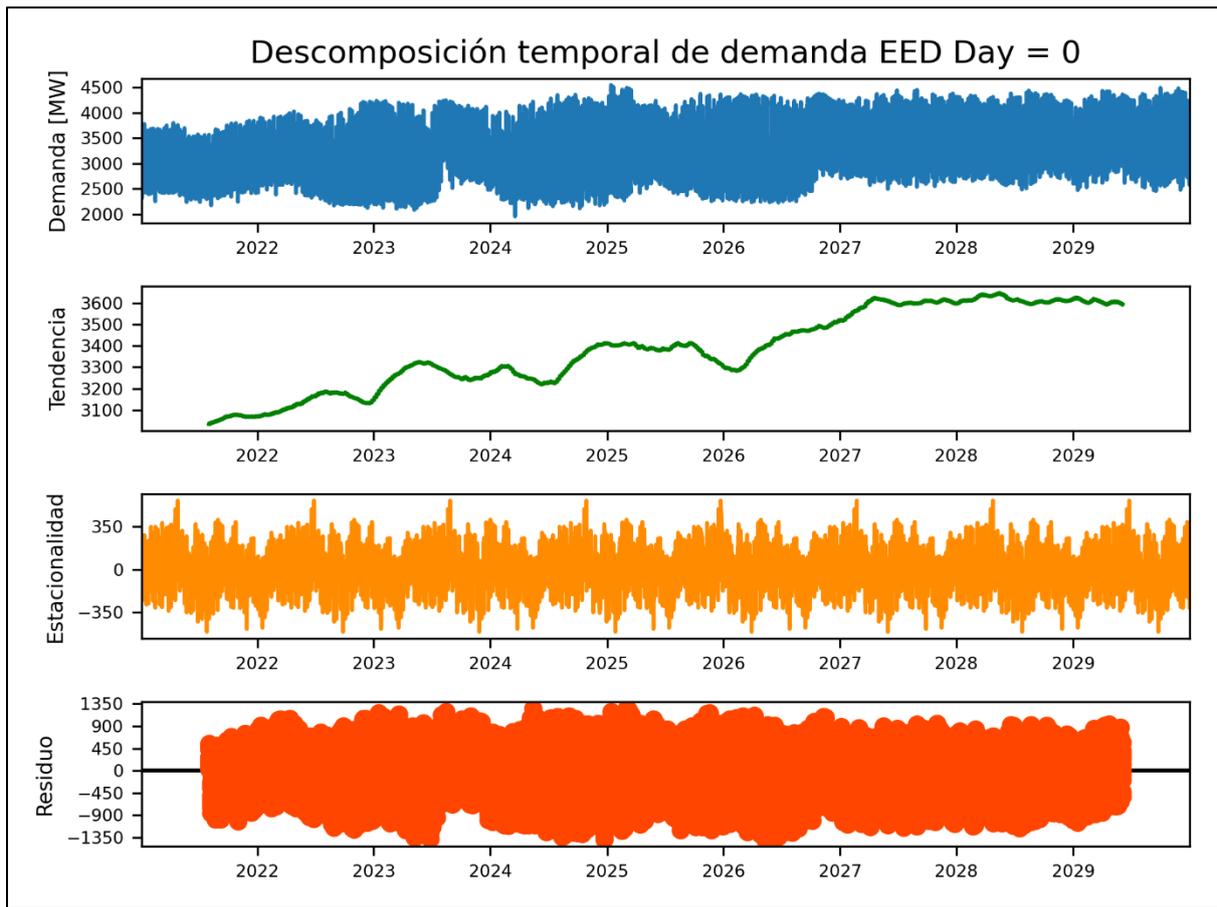
Anexo 11: Resultados de rendimiento de los 3 modelos RNA N_steps =28

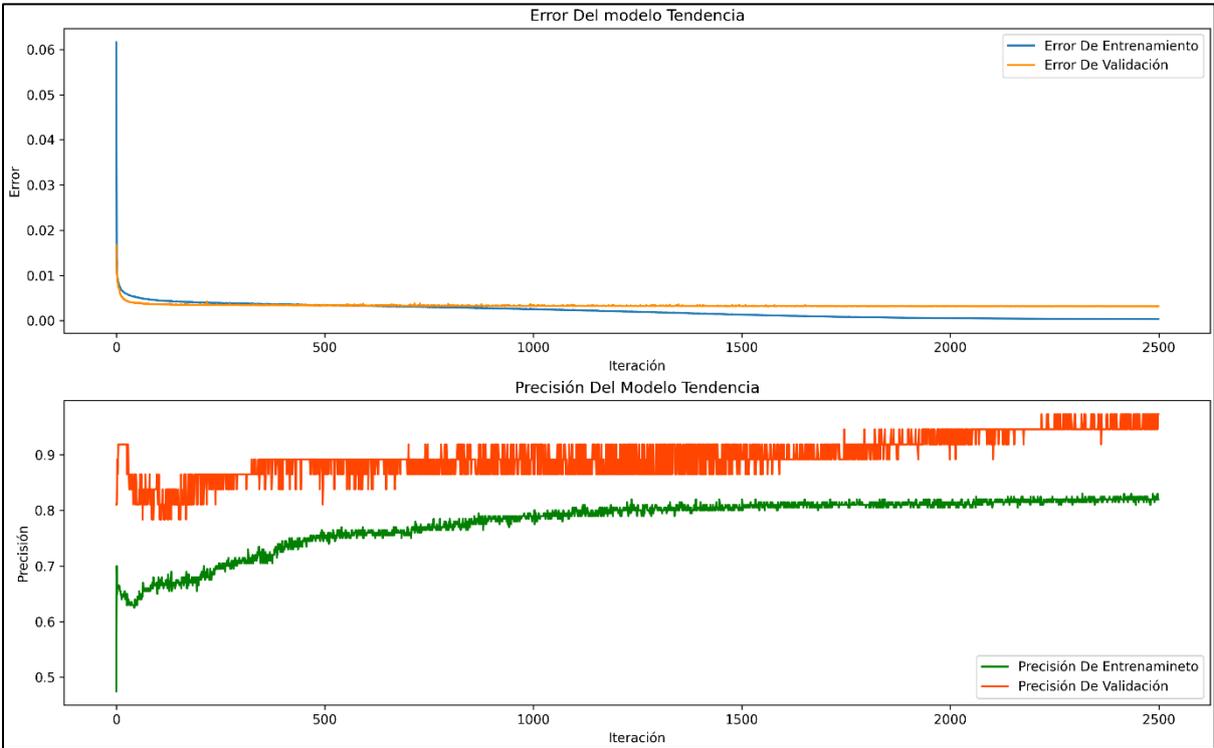
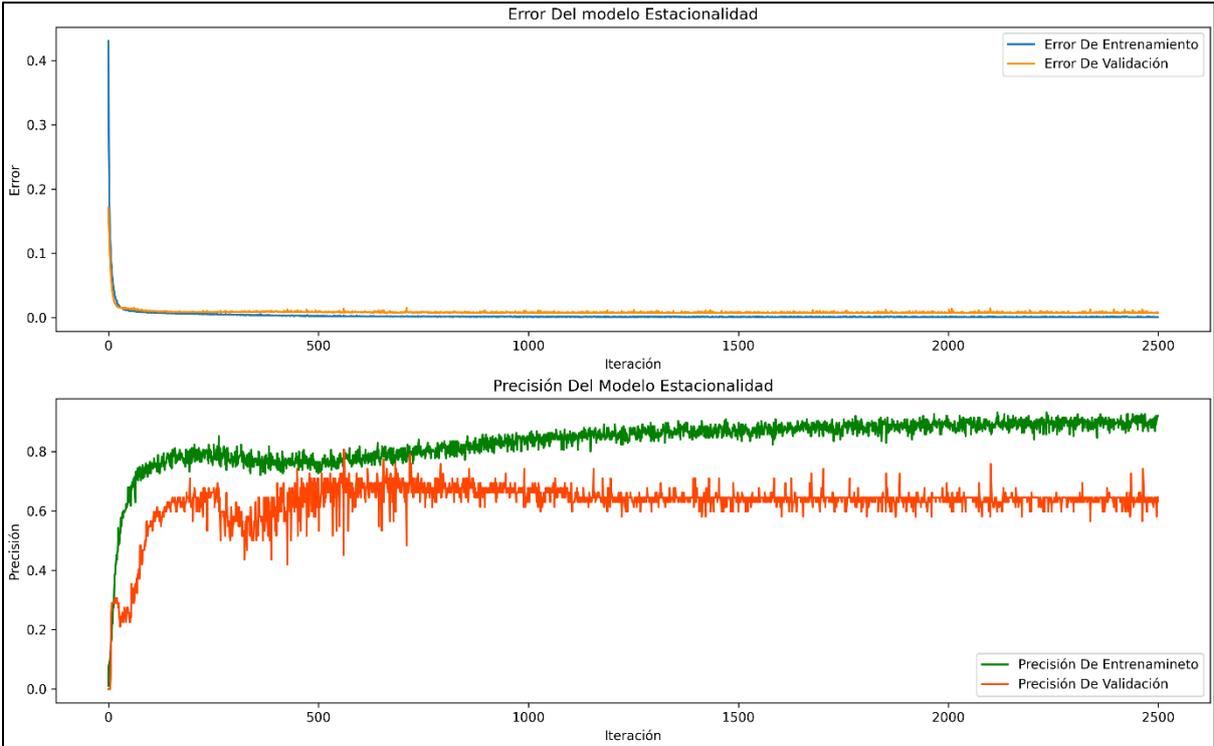




(Creado por David Rodas & Isaac Gusqui)

Anexo 12: Resultados de rendimiento de los 3 modelos RNA solo lunes

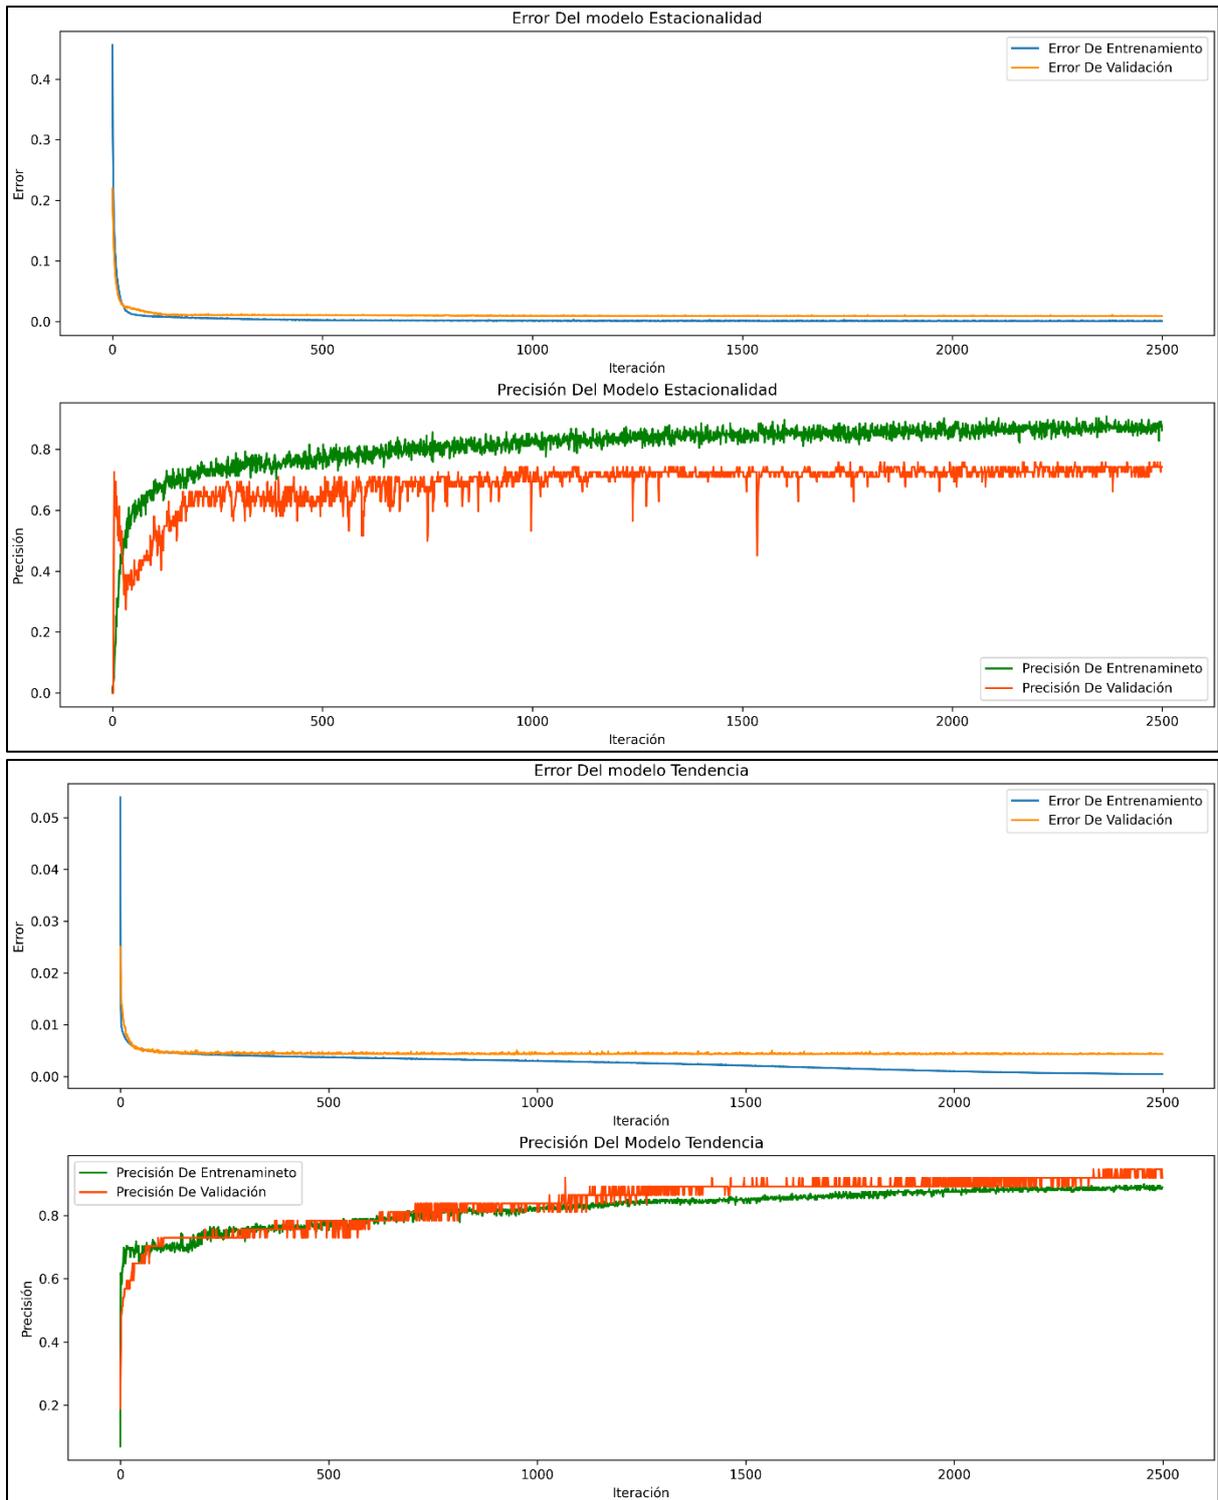




(Creado por David Rodas & Isaac Gusqui)

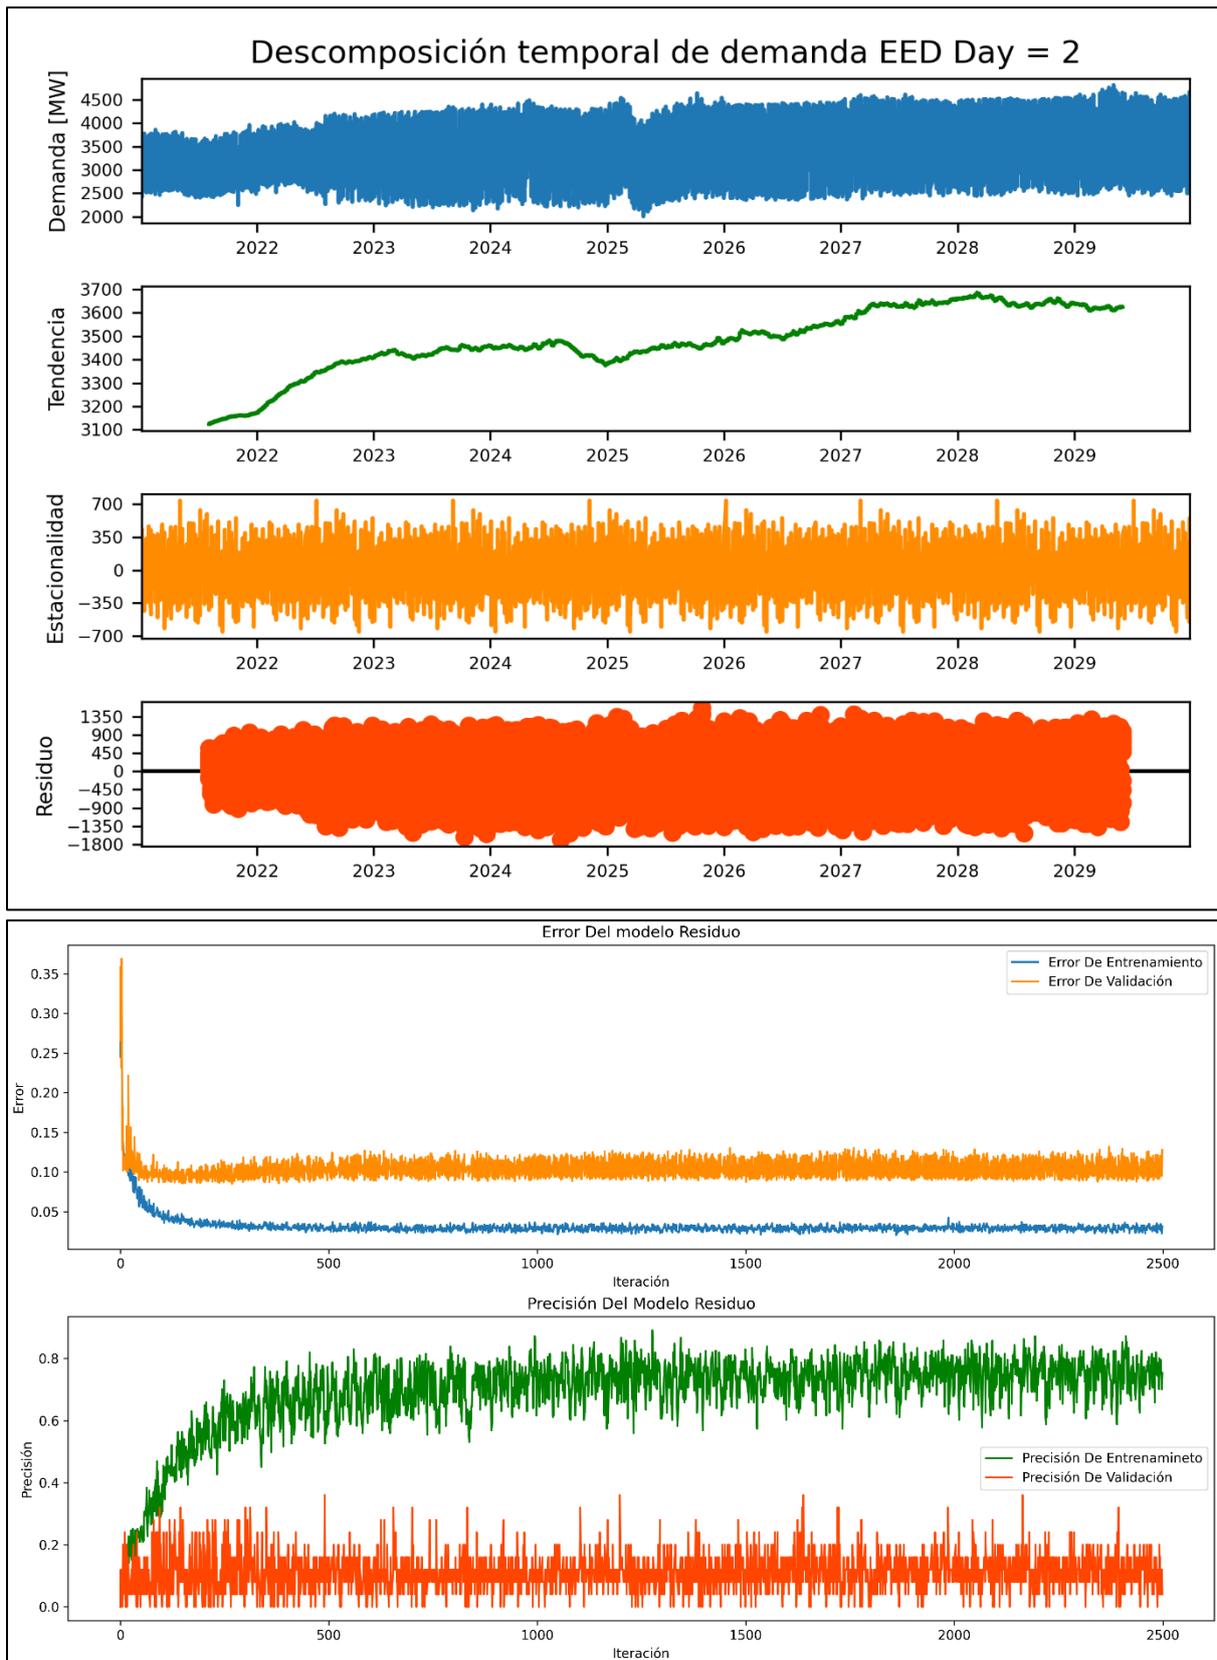
Anexo 13: Resultados de rendimiento de los 3 modelos RNA solo martes

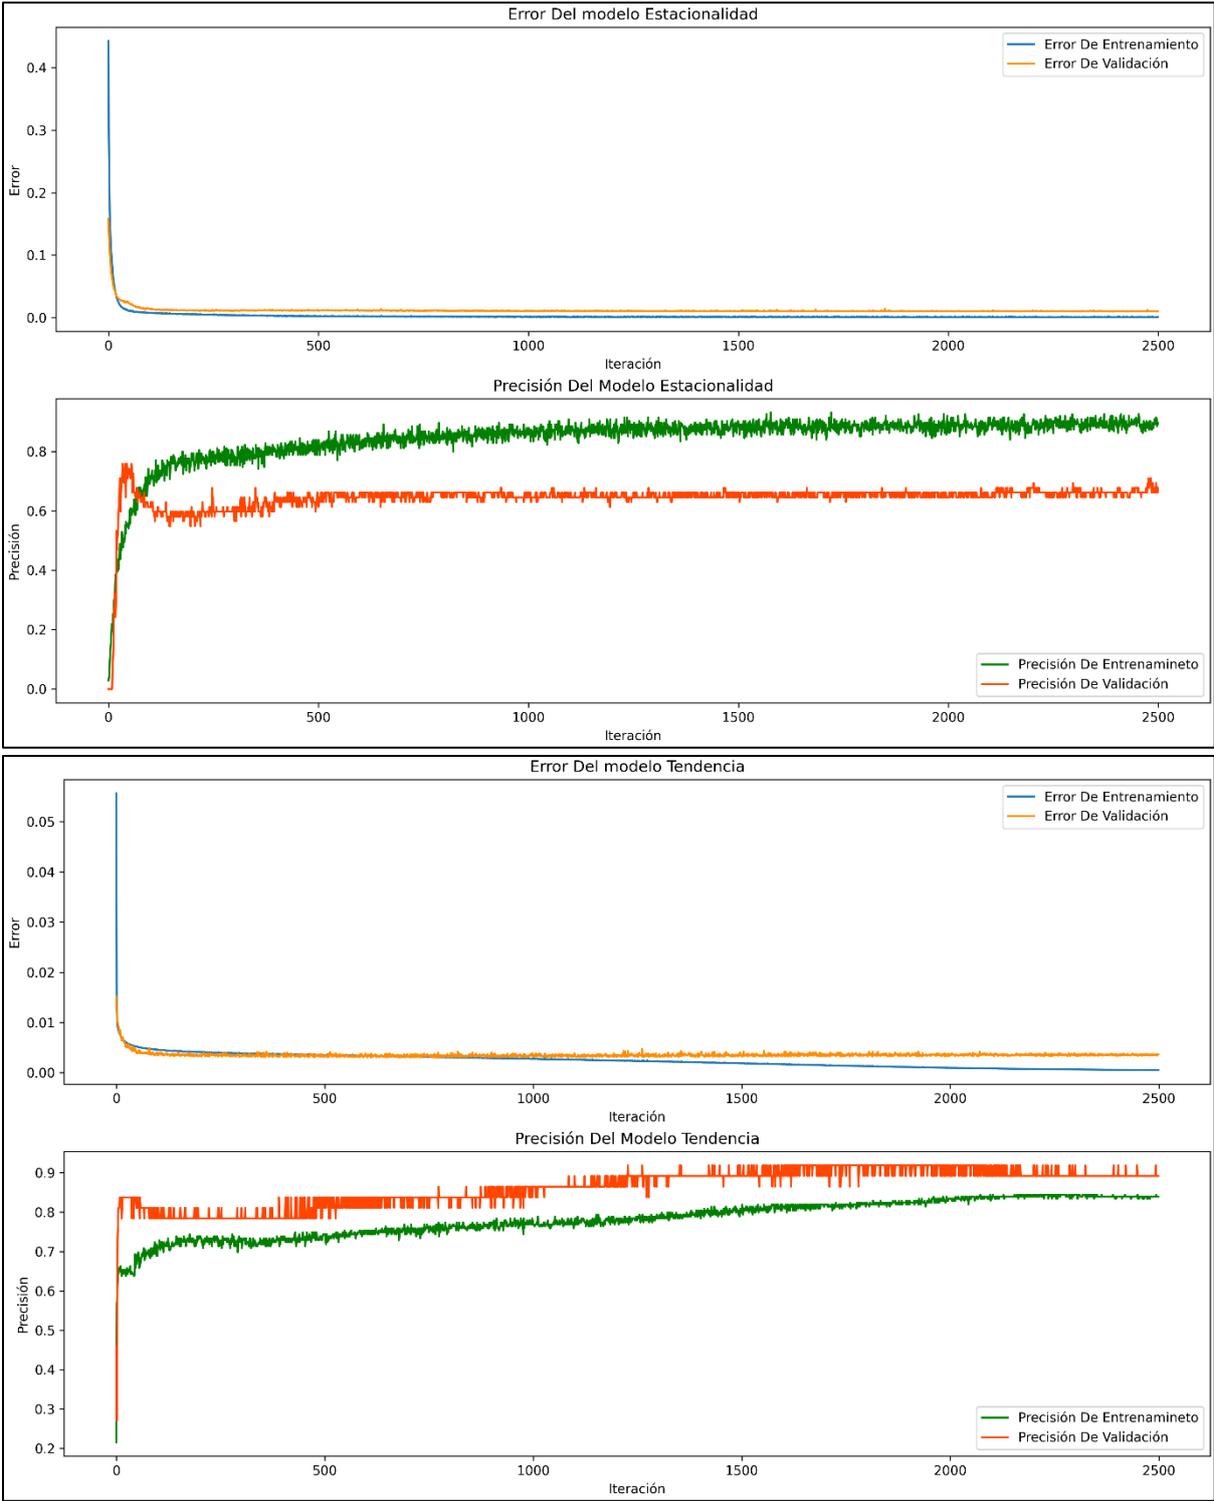




(Creado por David Rodas & Isaac Gusqui)

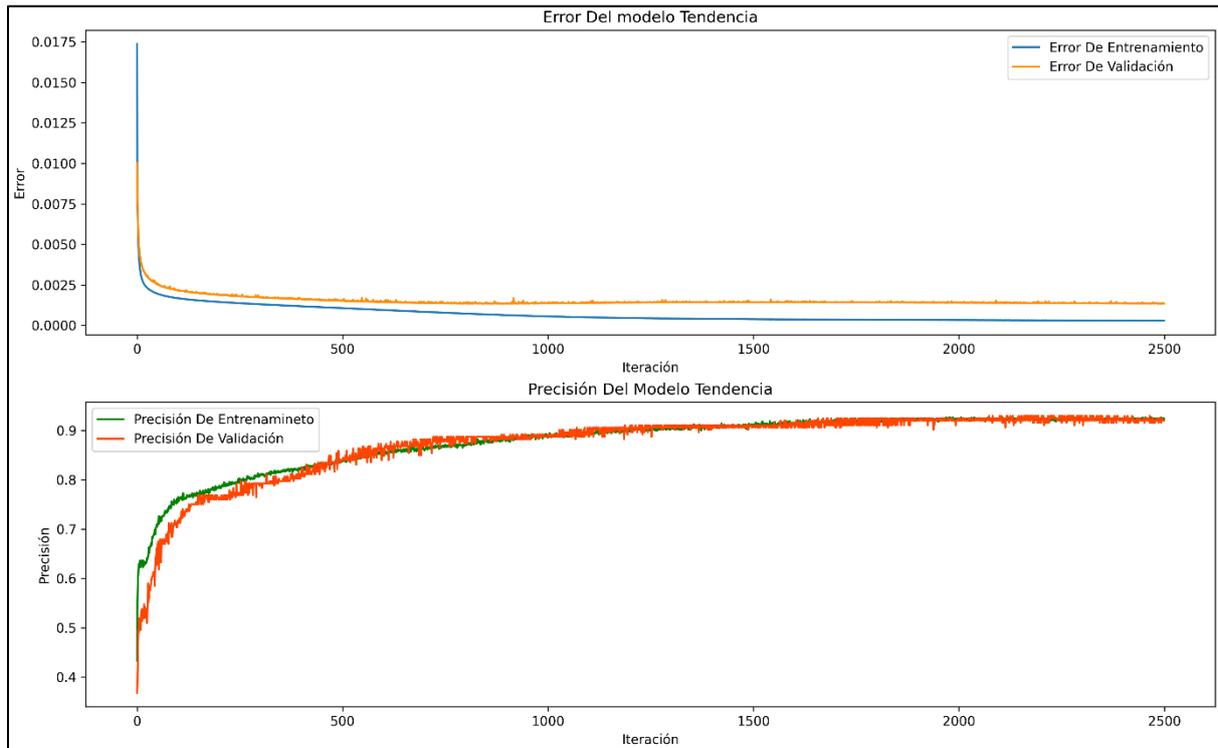
Anexo 14: Resultados de rendimiento de los 3 modelos RNA solo miércoles

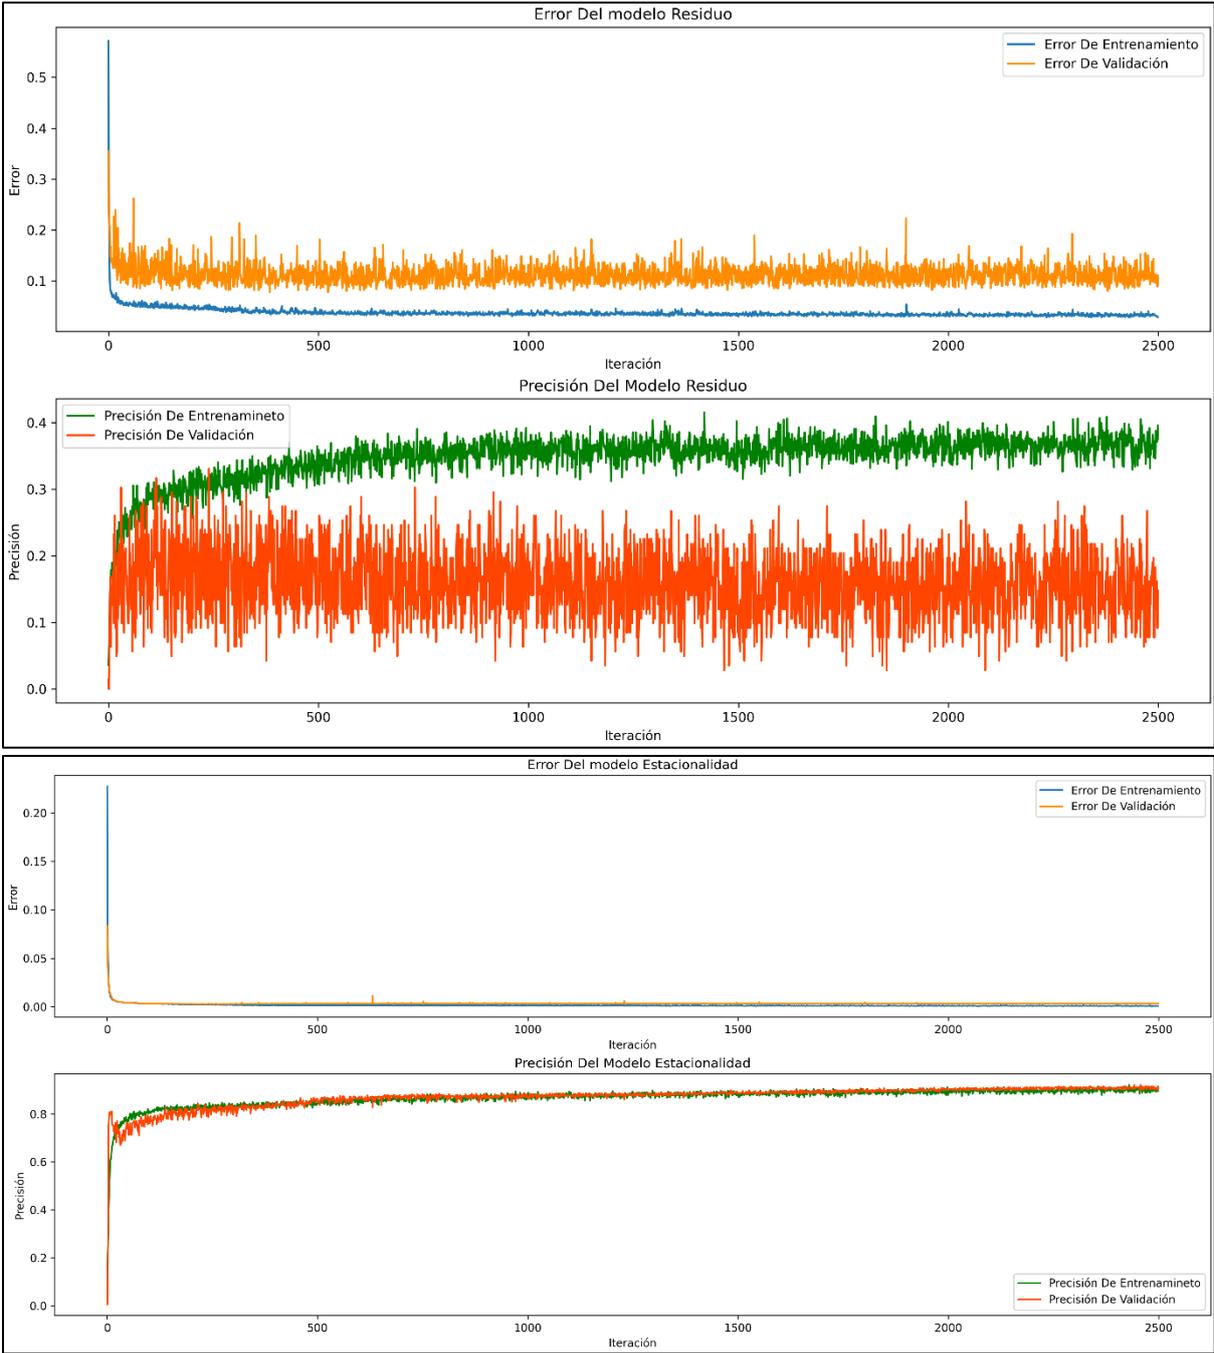




(Creado por David Rodas & Isaac Gusqui)

Anexo 15: Resultados de rendimiento sin considerar datos del 2020





(Creado por David Rodas & Isaac Gusqui)