



**Metodología para la valoración de impactos financieros sobre compañías de generación hidroeléctrica mediante la estimación de los precios del mercado energético colombiano a través de un sistema de redes neuronales**

Methodology for the assessment of financial impacts on hydroelectric generation companies through the estimation of Colombian energy market prices using a neural network system

Por  
Juan Camilo Mejía Melguizo<sup>1</sup>

Trabajo de grado presentado como requisito parcial para optar al título de  
Magíster en Administración Financiera – MAF

Asesor docente  
Juan Felipe Cardona Llano

Universidad EAFIT  
Escuela de Finanzas, Economía y Gobierno  
Maestría en Administración Financiera – MAF  
Medellín  
2024

---

<sup>1</sup> jcmejiam@eafit.edu.co

© 2024 por Juan Camilo Mejia Melguizo.  
Todos los Derechos Reservados.

## **Resumen**

Este trabajo de grado propone la creación de un modelo para evaluar financieramente el impacto sobre las compañías que focalizan sus actividades productivas en proyectos de centrales hidroeléctricas en Colombia con una capacidad instalada menor que 20 megavatios, empleando un sistema de redes neuronales para predecir los precios de la energía eléctrica en el mercado del país.

El modelo integra variables macroeconómicas y climáticas relevantes que afectan la volatilidad del valor del activo, que son evaluadas mediante *backtesting* para identificar la alternativa óptima y compararlas con otras herramientas predictivas bajo la metodología de redes neuronales recurrentes. Este modelo proporciona una herramienta analítica para inversionistas y reguladores, considerando la dinámica del mercado energético y los principales factores que influyen en los precios de la energía eléctrica.

Palabras claves: proyecciones energéticas, proyección y simulación financiera, mercados financieros.

## **Abstract**

This degree work proposes the creation of a model to financially evaluate the impact on organizations that concentrate their productive activities in hydroelectric power plant projects in Colombia with an installed capacity of less than 20 megawatts, using a neural network system to predict energy prices in the country's market. The model integrates relevant macroeconomic and climatic variables that affect the volatility of the asset value, and are evaluated through backtesting to identify the optimal alternative and compare them with other predictive tools under the recurrent neural network methodology. The selected model provides an analytical tool for investors and regulators, considering the dynamics of the energy market and the main factors that influence electric energy prices.

Keywords: Energy projections, financial projection and simulation, financial markets.

## Contenido

1.	Introducción.....	1
1.1	Justificación del problema.....	1
1.2	Objetivos .....	2
1.2.1	Objetivo general.....	2
1.2.2	Objetivos específicos .....	2
2.	Marco teórico .....	4
2.1	Redes neuronales.....	4
2.1.1	Redes neuronales artificiales (RNA).....	5°
2.2	Uso de las redes neuronales para la predicción de los precios en el ámbito global .....	6
2.3	Uso de las redes neuronales para la predicción de los precios en el ámbito local.....	6
2.4	Herramientas utilizadas para el pronóstico del precio de la energía .....	7
2.5	Venta de la energía en Colombia .....	8
3.	Metodología .....	9
3.1	Datos de la red neuronal.....	9
3.1.1	Precios de la energía en la Bolsa de Energía Colombiana .....	9
3.1.2	Capacidad instalada real.....	9
3.1.3	Demanda de la energía del Sistema Interconectado Nacional (SIN) .....	10
3.1.4	Índice El Niño Southern Oscillation (ENSO) .....	10
3.1.5	Generación real .....	11
3.1.6	Índice de precio al consumidor (IPC) .....	11
3.1.7	Nivel de los embalses.....	12
3.1.8	Precios del gas natural y del crudo West Texas Intermediate (WTI).....	12
3.1.9	Tasa de cambio USD/COP.....	13
3.2	Análisis de correlación.....	14
3.3	Modelo de regresión por redes neuronales.....	14
3.4	Evaluación de modelo entrenado .....	15
3.4.1	Raíz del error cuadrático medio (RECM) .....	15
3.4.2	Raíz del error cuadrático relativo (RECR).....	16
3.4.3	Coefficiente de determinación (R2) .....	16
3.5	Análisis de sensibilidad.....	16
4.	Resultados .....	18
4.1	Análisis de correlación.....	18
4.2	Modelo de regresión por redes neuronales.....	19
4.3	Análisis de sensibilidad.....	21
5.	Conclusiones y recomendaciones .....	23
5.1	Conclusiones .....	23
5.2	Recomendaciones.....	23
5.3	Conclusión general.....	24
	Referencias.....	25

## Índice de tablas

Tabla 1. Coeficientes de correlación entre las variables .....	18
Tabla 2. Precios reales de bolsa frente a precios proyectados por una regresión de red neuronal (noviembre de 2018).....	19
Tabla 3. Resultados de ajuste del modelo .....	20
Figura 14. Registros históricos de generación de la compañía Generación de Energía S. A. S. (2018-2022) .....	21
Tabla 4. Comparación de los ingresos de la compañía Generación de Energía S. A. S. (2018-2022).....	21
Tabla 5. Estado de resultados reales de la compañía Generación de Energía S. A. S. (2018-2022).....	21
Tabla 6. Comparación de la utilidad de la compañía Generación de Energía S. A. S. (2018-2022).....	22

## Índice de figuras

Figura 1. Modelo de redes neuronales artificiales (RNA).....	5
Figura 2. Precios de la energía en la Bolsa de Energía Colombiana (junio de 1999-octubre de 2021) .....	9
Figura 3. Capacidad instalada real .....	10
Figura 4. Demanda energética colombiana en kW-h (julio de 1999-octubre de 2021).....	10
Figura 5. Variación del Índice Niño Oceánico (ONI) (julio de 1999-octubre de 2021) .....	11
Figura 6. Representación de los datos de generación diaria de energía en Colombia (julio de 1999-octubre de 2021).....	11
Figura 7. Comportamiento de la inflación en Colombia (julio de 1999-octubre de 2021) .....	12
Figura 8. Variación de la reserva hídrica en las centrales de generación de energía con embalses (julio de 1999-octubre de 2021).....	12
Figura 9. Precios del gas natural en USD (julio de 1999-octubre de 2021) .....	12
Figura 10. Precios de crudo West Texas Intermediate (WTI) en USD (julio de 1999-octubre de 2021) ...	13
Figura 11. Comportamiento tasa de cambio USD/COP (julio de 1999-octubre de 2021) .....	13
Figura 12. Pipeline de modelo de entrenamiento por regresión de red neuronal realizado con la herramienta Azure Machine Learning.....	15
Figura 13. Comparación del valor proyectado contra el valor real (noviembre de 2018).....	20

## 1. Introducción

La generación de energía eléctrica en Colombia ha sido una parte muy importante del desarrollo industrial y económico del país, con presencia desde el siglo XIX cuando en Bogotá fue instalado el alumbrado público en 1886 con la constitución de la Bogotá Electric Light Co., que posteriormente derivaría en la creación de la primera central hidroeléctrica colombiana, ubicada sobre el río Bogotá, de nombre El Charquito (Ochoa Franco *et al.*, 2002). Este desarrollo, orientado inicialmente al uso público y a un acotado sector de la industria, evidenció por primera vez su eficiencia productiva, aumentó la demanda y atrajo a más interesados a realizar una transición a esta herramienta.

A medida que el país avanzaba en el desarrollo de su industria surgió la necesidad de dotar a la población del servicio doméstico en sus hogares, que inició en ciudades como Medellín, Cali, Barranquilla y Bogotá, y fue suministrado a través de iniciativas privadas locales. Posteriormente, entendiendo la diferencia de los elementos generadores, en las regiones surgió la necesidad de contar con un ente de coordinación del suministro que optimizara los procesos minimizando los costos del sistema y proyectara su expansión; esta inquietud dio pie a la creación de Interconexión Eléctrica S. A. (ISA) en 1967, que actualmente vela por la satisfacción de la demanda energética del territorio nacional. (Bello Rodríguez & Beltrán Ahumada, 2010)

La confiabilidad que había generado el sistema de generación eléctrica y su administración a cargo del Estado —que históricamente ha recaído principalmente en el aprovechamiento de las fuentes hídricas— se vio diezmada en 1992 cuando se presentó una crisis energética debido a un fuerte fenómeno de El Niño que derivaría en apagones y, por consiguiente, en medidas de racionamiento (López Díez, 2017). Dentro de las estrategias planteadas por el Gobierno surgió la reestructuración del sistema eléctrico mediante un marco regulatorio que buscara asegurar la disponibilidad del recurso con el impulso de la competencia de los generadores. El resultado originó la constitución en 1995 de Isagén, una iniciativa compuesta por capital mixto que se ha encargado de la comercialización nacional e internacional de la energía eléctrica a través del Mercado Energético Mayorista (MEM) en el que participan los principales agentes del sistema.

En la actualidad, el intercambio entre los consumidores y los generadores se da en la Bolsa de Energía de Colombia, que tranza los precios *spot* del kilovatio-hora (kW-h). Allí, en medio de un ambiente competitivo, se consideran los diferentes tipos de generación a partir de los costos operativos de cada alternativa. Este hecho suscita, entonces, la necesidad de considerar alternativas que entreguen opciones de evaluaciones de riesgo y afectaciones sobre las finanzas corporativas usando herramientas contemporáneas que mitiguen los efectos de la volatilidad del mercado.

### 1.1 Justificación del problema

Uno de los elementos más importantes en la valoración de una empresa es la proyección de sus ingresos, que suele ser estimada con metodologías internas y registros históricos en conformidad

con su capacidad de producción y los precios del mercado. En un escenario común, donde la venta a un consumidor, bien sea de un producto o un servicio, está expuesta, la empresa se expone a riesgos de mercado que pueden ser mitigados con estrategias condicionadas al manejo adecuado que le dé a la operación; sin embargo, en casos extraordinarios, donde los ingresos están expuestos a factores exógenos como el clima o elementos macroeconómicos, es necesario implementar mecanismos alternativos que le permitan blindarse de la mejor manera.

La industria de la generación y suministro de energía es una de las más representativas del producto interno bruto (PIB) colombiano, que en 2021 tuvo una participación del 3,48 % (Statista Research Department, s. f.). Este sistema, que crece constantemente, proyecta anualmente un aumento de alrededor del 3 % hasta 2030 (XM, s. f.-c), un hecho que evidencia una inmensa oportunidad para el desarrollo del sector.

Si se entra en el detalle, en la generación de energía por fuentes hídricas existen dos condicionantes fundamentales que resumen los ingresos operacionales de una empresa productora: 1) el caudal, que es el producto de los diferentes elementos geológicos y climáticos de una cuenca —precipitación, escorrentía, geometría del área aferente— (Sandoval Erazo & Aguilera Ortiz, 2014), determina la cantidad de energía que puede generar una central según su capacidad instalada; y 2) el precio de la energía en bolsa, que, al ser tranzado abiertamente en la bolsa mayorista, se ve afectado por situaciones que generan fluctuaciones de mercado y condicionantes externos como factores climáticos que elevan la volatilidad del activo, y terminan traducándose en incertidumbre para el inversionista participante del sector minero-energético.

En consecuencia, buscando responder la incógnita de cómo proyectar los resultados financieros de las compañías hidroeléctricas en Colombia disminuyendo la incertidumbre por el valor del kilovatio-hora (kW-h) en el mercado energético, este trabajo propone una alternativa de estimación de los precios basada en herramientas de predicción que consideren los elementos que históricamente han influido sobre el precio del kW-h de energía en el país, a través de un acercamiento al *machine learning* enfocado en el desarrollo de redes neuronales con series recurrentes de tiempo, para posteriormente evaluar las consecuencias sobre los estados de resultados de una empresa previamente seleccionada y verificar las proyecciones en retrospectiva bajo una mirada crítica.

## 1.2 Objetivos

### 1.2.1 Objetivo general

Desarrollar una metodología para la evaluación de los impactos financieros en las compañías desarrolladoras de proyectos hidroeléctricos en Colombia utilizando un enfoque de predicción de los precios energéticos basado en sistemas de redes neuronales.

### 1.2.2 Objetivos específicos

- Crear una base de datos que recopile los precios de cierre diarios de la Bolsa de Energía de Colombia entre 2000 y 2022.

- Recopilar las variables que tengan injerencia sobre el precio nacional de la energía y evaluar su inclusión mediante un análisis de correlación.
- Desarrollar un modelo de regresión por medio de redes neuronales que permita el pronóstico del precio nacional de la energía para un período determinado.
- Aplicar el modelo seleccionado a los estados de resultados de una empresa colombiana dedicada al sector hidroeléctrico y evaluar los impactos financieros que presenta su aplicación mediante un análisis de sensibilidad.

## 2. Marco teórico

Desde las primeras ocurrencias históricas en materia de la transacción de acciones —presentes desde la época de la Roma clásica—, hasta la primera emisión registrada de bonos y acciones en el siglo XVII por la Compañía Holandesa de las Indias Orientales (Stringham, 2015), los inversionistas han buscado estrategias para obtener rentabilidades del mercado desde diferentes enfoques de análisis.

Al considerar algunos elementos teóricos contemporáneos es posible identificar dos marcadas corrientes relacionadas con la búsqueda de rentabilidades en el mercado. La primera establece que la valoración de un activo en bolsa es justificada por información fiable y deducible que da como resultado una repetición de la tendencia de su comportamiento en el futuro y genera una ventaja sobre las valoraciones actuales (Murphy, 1999). La segunda plantea una hipótesis de mercados eficientes donde los precios de los activos en la valoración de mercado son evidentes, por lo que es imposible el uso de estrategias que venzan el rendimiento del mercado mismo. (Fama, 1969).

Aceptando que existe evidencia de inversionistas o fondos que han vencido al mercado año a año, es importante recoger las metodologías de análisis que han ayudado al estudio de los activos. Dentro de las modelaciones más conocidas está el *análisis fundamental*, concebido bajo el examen de los parámetros de operación de las empresas en comparación con sus pares de la industria o, inclusive, con ellas mismas en el pasado. También están los *análisis técnicos*, que se apoyan en el entendimiento de patrones de los precios históricos, que identifican las tendencias de comportamiento, y le permiten al inversionista una estimación de valoraciones futuras con la posibilidad de obtener rentabilidades. (Coronilla Valdivieso, 2021)

Además de estas modelaciones, se han implementado alternativas que recogen elementos característicos de estos análisis y que se integran por medio de la recolección y la organización de datos; estas alternativas, sumadas a la capacidad de procesamiento moderna, han resultado en un importante avance en materia herramientas predictivas, por ejemplo, las redes neuronales.

### 2.1 Redes neuronales

Los primeros registros del uso de las redes neuronales datan de 1940, cuando los matemáticos McCulloch y Pitts plantearon un sencillo modelo basado en circuitos eléctricos que subrayaba la relevancia de las conexiones entre las neuronas en el proceso de aprendizaje humano. Aunque los primeros intentos de simular estas redes en computadoras, en la década de 1950, no tuvieron éxito, en la década de 1980 resurgió el interés en este campo, especialmente con el desarrollo de las redes de retro-propagación. Este renacer fue impulsado por conferencias internacionales y por el auge de la quinta generación de computadoras, que abarcaban el campo de la inteligencia artificial. (Stanford University, s. f.)

Una *red neuronal* se define como un sistema capaz de establecer relaciones lineales o no lineales entre las entradas y salidas. Estas redes se inspiran en el funcionamiento del sistema nervioso, lo que les otorga ventajas como la capacidad de aprendizaje adaptativo auto-organizativo, la habilidad para funcionar en paralelo en tiempo real y la facultad de ofrecer tolerancia a los fallos gracias a la codificación redundante de la información.


Desde la perspectiva de la resolución de problemas, las redes neuronales difieren de los computadores convencionales en el hecho de que emplean algoritmos secuenciales. Mientras que estos últimos siguen un proceso lineal, las primeras operan de manera similar al cerebro humano procesando información en paralelo. Además, tienen la capacidad de aprender y generalizar incluso situaciones no contempladas durante su entrenamiento. (Villada et al., 2012)

### 2.1.1 Redes neuronales artificiales (RNA)

Buscando replicar el funcionamiento humano para la resolución de problemas, las *redes neuronales artificiales* —en adelante RNA— plantean un modelo que incluye una parametrización de tres capas, cada una compuesta de un número determinado de neuronas clasificadas como capa de entrada, capa oculta y capa de salida. La primera recoge datos e información exógena que serán insumos para el procesamiento y pasarán a ser interpretados y desarrollados en la capa oculta —la segunda capa—; esta última pueden tener diferentes niveles de jerarquización, lo que permite un procesamiento progresivo que arroje un análisis más certero. La tercera capa recoge una salida de datos que, en el caso del pronóstico de precios, permite la interpretación del comportamiento del mercado.

La esquematización del modelo de RNA se muestra en la **¡Error! No se encuentra el origen de la referencia..**

Figura 1. Modelo de redes neuronales artificiales (RNA)



Fuente: Amazon Web Services, AWS (2024).

Para el funcionamiento correcto de las neuronas es necesario un proceso de entrenamiento que las oriente hacia la solución de una tarea. Este método es conocido como *algoritmo de aprendizaje*, un mecanismo que se va adaptando gracias a las iteraciones constantes.

En 1943, McCulloch y Pitts realizaron una propuesta teórica para las RNA que partía de  $n$  entradas ( $x_i$ ), una calificación de peso ( $w_i$ ) y un umbral o *bias*, y arrojaba un resultado ( $z$ ) que posteriormente se evaluaba dentro de una función de activación [Ecuación 1].

ECUACIÓN 1. Modelo de neuronas artificiales de McCulloch & Pitts (1943)

$$z = b + \sum_{i=1}^n w_i x_i$$

A esta ecuación se le aplica una función de activación lineal, que en este modelo es de tipo escalonada [Ecuación 2].

ECUACIÓN 2. Función de activación lineal en el modelo de McCulloch & Pitts (1943)

$$a = f(z) \begin{cases} 1 & z \geq 0 \\ 0 & z \leq 0 \end{cases}$$

El resultado de este modelo produce una salida binaria que puede utilizarse como clasificador y es un insumo para el desarrollo del entrenamiento del dispositivo que permitirá un entrenamiento progresivo del modelo y dará como resultado el desarrollo de una RNA. (Universidad Politécnica de Madrid, s. f.)

## 2.2 Uso de las redes neuronales para la predicción de los precios en el ámbito global

Las redes neuronales se han usado en diferentes áreas de estudio con el propósito de buscar un modelo fiable para la predicción de los precios; por ejemplo, en 2020, Mir *et al.* desarrollaron un modelo de proyección para los precios de los materiales de construcción por medio de la metodología de RNA, abordando las fluctuaciones de los precios de las incertidumbres asociadas. Mediante la estimación de límites superior e inferior óptimos, los autores pudieron demostrar que este enfoque superaba las técnicas tradicionales y resaltaron la importancia del uso de las redes neuronales como estrategia de gestión de riesgo. (Mir *et al.*, 2020)

Por otro lado, en 2023, Lu y Xu llevaron a cabo la construcción de un modelo eficiente de red neuronal recurrente para series temporales para la predicción de los precios de las acciones en bolsa, considerando elementos influyentes como los sucesos mundiales significativos o el volumen de mercado como condicionantes para la valoración de los activos. Los autores encontraron que las series temporales presentaban un resultado más preciso en comparación con otros tipos de redes neuronales como las recurrentes o las de corta memoria, principalmente por su ineficiencia a la hora de identificar puntos de inflexión sobre los precios y las tendencias; adicionalmente, resaltaron la precisión del método escogido, con resultados cercanos al 90 % de precisión y una considerable reducción en la aparición de valores atípicos. (Lu & Xu, 2024)

## 2.3 Uso de las redes neuronales para la predicción de los precios en el ámbito local

Desde una mirada financiera, los avances en materia del uso de las redes neuronales en Colombia han evolucionado desde diferentes perspectivas útiles. En 2002, Misas *et al.* adelantaron una investigación para encontrar una aproximación de la inflación en Colombia en el período 1969-1999 por medio de las redes neuronales —que fueron evaluadas por *backtesting*—, realizando una comparación de los resultados con diferentes modelos de predicción. Los hallazgos les permitieron concluir que la alternativa era competitiva frente a modelos como el Arima —*autoregressive integrated moving average*— o a los precios relativos, y le abrió las puertas a esta metodología en el campo de los estudios financieros y macroeconómicos. (Misas *et al.*, 2002)

Para el mercado bursátil también existe bibliografía que busca pronosticar los precios por medio de las redes neuronales. En 2012, Villada *et al.* hicieron una evaluación de dos acciones colombianas que negocian tanto en la bolsa colombiana como en la neoyorquina: Ecopetrol y Preferencial Bancolombia. Para el análisis partieron de la consecución de los precios de cierre, evaluándolos a través de una serie de tiempo con un horizonte de seis años, a manera de insumo para la construcción del modelo. Los autores concluyeron que, a pesar de ser acciones de industrias diferentes —energética y financiera—, el ajuste del modelo fue correcto, y consideraron el uso de esta herramienta como una alternativa fiable para la identificación y la mitigación de riesgos. (Villada *et al.*, 2012)

## 2.4 Herramientas utilizadas para el pronóstico del precio de la energía

En la literatura existen aproximaciones para el pronóstico del precio de la energía en bolsa a través de enfoques estadísticos. En 2023, Villareal y Flores adelantaron una investigación para evaluar los precios de la energía eléctrica en Colombia por medio de *machine learning*. En su artículo, los autores exploraron diferentes alternativas fiables dentro de múltiples escenarios de evaluación, entre los que destacan las regresiones —lineal y simple—, los modelos de vector autorregresivo —VAR, *vector autoregression*— y los modelos Arima y Arimax —similar al modelo Arima, pero con regresores exógenos—. El estudio concluyó que los modelos se encontraban dentro de un rango fiable, con una probabilidad de ocurrencia del 68 %; sin embargo, los autores destacaron la importancia de un acercamiento a través de redes neuronales que permitiera un mejor ajuste en la capacidad de generar un desempeño más confiable en un horizonte de largo plazo. (Villareal & Flores, 2023)

Desde un enfoque macroeconómico, en 2012, Barrientos *et al.* investigaron un modelo de pronóstico que proyectaba el precio de la energía en función del PIB, el nivel nacional de los embalses y la demanda. En el período de estudio evaluado (2010-2017) fue posible determinar que los precios previstos se alineaban con los hallazgos más recientes de la Unidad de Planeación Minero-energética, UPME. Según los autores, en un escenario de crecimiento económico medio y con proyectos de generación aprobados en las subastas de cargo por confiabilidad, era plausible que los precios de la electricidad fluctuaran entre los 50 y los 80 USD por MW-h, un hallazgo que probó ser consistente con los resultados obtenidos. (Barrientos *et al.*, 2012)

## 2.5 Venta de la energía en Colombia

Todo el comercio eléctrico en el país se realiza a través de la Bolsa de Energía de Colombia, donde suceden diferentes tipos de operaciones clasificadas según los horizontes de tiempo de negociación. En el primer horizonte, que se denomina *mercado de corto plazo*, los productores de energía ofrecen sus precios diariamente con una precisión horaria, reflejando la cantidad de energía disponible para el sistema; mientras tanto, los comercializadores, en nombre de la demanda, se ajustan a los precios establecidos por el precio de corto plazo de la energía —conocido como *precio de bolsa*—, que es uniforme para todo el sistema durante cada hora del día. Este precio se determina mediante un modelo de despacho de optimización horaria que no tiene restricciones de transmisión —el *modelo de despacho ideal*—, aunque sí tiene en cuenta las características técnicas de los recursos de generación.

En el segundo horizonte —el *mercado de largo plazo*—, los participantes tanto comerciales como generadores inscriben sus acuerdos de compra y venta de energía en el Administrador del Sistema de Intercambios Comerciales (ASIC), que determina las transacciones hora a hora en el mercado de corto plazo, también conocido como la *bolsa de energía*. Estas transacciones representan la diferencia entre las obligaciones de compra —o satisfacción de la demanda, en el caso de los comerciales— y las de venta —o suministro de energía, en el caso de los generadores— valoradas al precio de mercado; sin embargo, la facturación y el cobro de estas transacciones de contratos a largo plazo son responsabilidad exclusiva de las partes involucradas, y su registro en el ASIC no implica la gestión de los fondos intercambiados. (XM, s. f.-b)

### 3. Metodología

#### 3.1 Datos de la red neuronal


Para el desarrollo de la red neuronal propuesta en este trabajo es necesario hacer una selección de datos relevantes. Estos deberán ser elegidos a través de un análisis basado en supuestos elementos que influyen en la valoración del activo por considerar, que en este caso es el precio de la energía. Dentro de dichos supuestos también se consideraron variables agrupadas en indicadores de producción y consumo eléctrico, elementos climáticos e indicadores macroeconómicos relevantes.

En este ejercicio fueron evaluados datos comprendidos entre el 1 de enero de 2000 y el 31 de diciembre de 2022, con una periodicidad diaria, para un total de 8401 datos por elementos considerados.

##### 3.1.1 Precios de la energía en la Bolsa de Energía Colombiana

El primer elemento considerado fue el registro de los precios históricos del kilovatio-hora (kW-h) dentro del mercado. En el modelo de red neuronal propuesto se usó este dato como comparador, a fin de evaluar errores de pronóstico entre la proyección y los valores registrados durante el período de estudio [Figura 2].

Figura 2. Precios de la energía en la Bolsa de Energía Colombiana (junio de 1999-octubre de 2021)

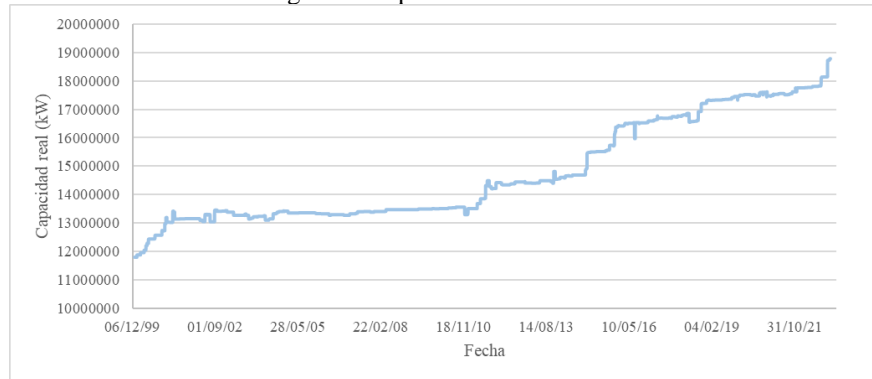


Fuente: elaboración del autor.

##### 3.1.2 Capacidad instalada real

La *capacidad instalada real* señala la capacidad total de potencia que pueden generar las plantas del país en un momento dado. Este indicador, que se mide en kilovatios (kW), refleja la disponibilidad real que las plantas despachan al Sistema Interconectado Nacional (SIN) (XM, s. f.-a). En este indicador se contemplan todas las generaciones registradas ante el despacho central y reguladas por la compañía XM [Figura 3].

Figura 3. Capacidad instalada real




Fuente: elaboración del autor a partir de XM (s. f.-a).

### 3.1.3 Demanda de la energía del Sistema Interconectado Nacional (SIN)

La *demanda de energía del Sistema Interconectado Nacional (SIN)* resume la necesidad de consumo del país en un momento dado, que varía a lo largo del día y suele presentar sus picos en el horario diurno. Este indicador, evaluado diariamente, es un elemento crucial para la planeación minero-energética del país [Figura 4].

Figura 4. Demanda energética colombiana en kW-h (julio de 1999-octubre de 2021)




Fuente: elaboración del autor.

### 3.1.4 Índice El Niño Southern Oscillation (ENSO)

El índice *El Niño Southern Oscillation (ENSO)* describe el comportamiento del fenómeno meteorológico de El Niño. Este valor, que permite la evaluación de las fases cálidas y frías en el Pacífico Ecuatorial Central, se calcula mediante la variación del promedio de las temperaturas presentadas en las diferentes zonas de estudio sobre el océano Pacífico. (Perú, Instituto del Mar de Perú, Imarpe, s. f.)

En este caso, se toma en consideración el Índice Niño Oceánico (INO), que muestra que una variación positiva mayor que 0,5 es un período de El Niño, mientras que si es inferior a  $-0,5$  se presenta la condición climática de La Niña [Figura 5].

Figura 5. Variación del Índice Niño Oceánico (ONI) (julio de 1999-octubre de 2021)

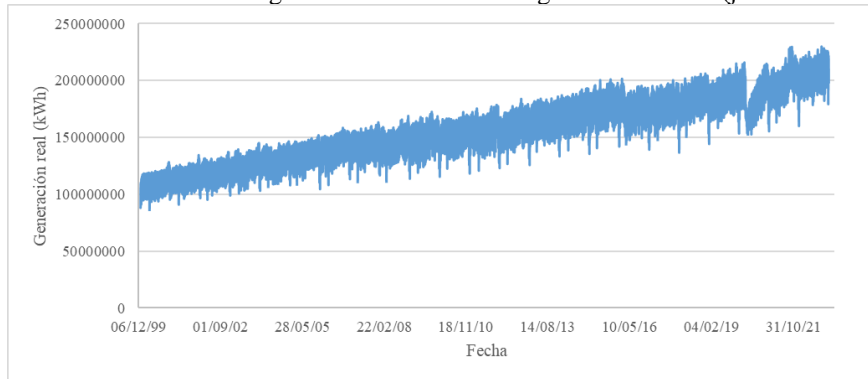


Fuente: elaboración del autor a partir de Estados Unidos, National Oceanic and Atmospheric Administration, NOAA (s. f.).

### 3.1.5 Generación real

Los datos de la *generación real* recogen diariamente la producción energética de las distintas centrales del país que aportan al Sistema Interconectado Nacional (SIN) y buscan suplir la proyección de demanda emitida por la central de despacho de XM [Figura 6].

Figura 6. Representación de los datos de generación diaria de energía en Colombia (julio de 1999-octubre de 2021)




Fuente: elaboración del autor.

### 3.1.6 Índice de precio al consumidor (IPC)

El *índice de precio al consumidor (IPC)*, que resume la variación del costo promedio de una canasta de bienes y servicios para los hogares colombianos, es calculado por el Departamento Administrativo Nacional de Estadística (DANE) con una base de tiempo determinado, y permite la evaluación del componente de la inflación nacional. (Colombia, Banco de la República, s. f.)

Este valor se considera fundamental para la evaluación del modelo propuesto en este trabajo, pues en el sistema de redes neuronales permite una indexación implícita de los precios que condicionan los valores del kW-h a los demás factores [Figura 7].

Figura 7. Comportamiento de la inflación en Colombia (julio de 1999-octubre de 2021)




Fuente: elaboración del autor a partir de Colombia, Departamento Administrativo Nacional de Estadística, DANE (s. f.).

### 3.1.7 Nivel de los embalses

XM, a través de su plataforma Sinergox, recopila diariamente el *nivel de los embalses* de las centrales de generación hidroeléctrica en millones de metros cúbicos de agua almacenados que, a diferencia de las plantas que no tienen presas o que funcionan a filo de agua, puede controlar la cantidad diaria de energía por generar. Este índice se considera importante puesto que permite la identificación de períodos donde el flujo de agua supera la necesidad de producción y puede tener injerencia sobre el precio del kW-h en bolsa [Figura 8].

Figura 8. Variación de la reserva hídrica en las centrales de generación de energía con embalses (julio de 1999-octubre de 2021)

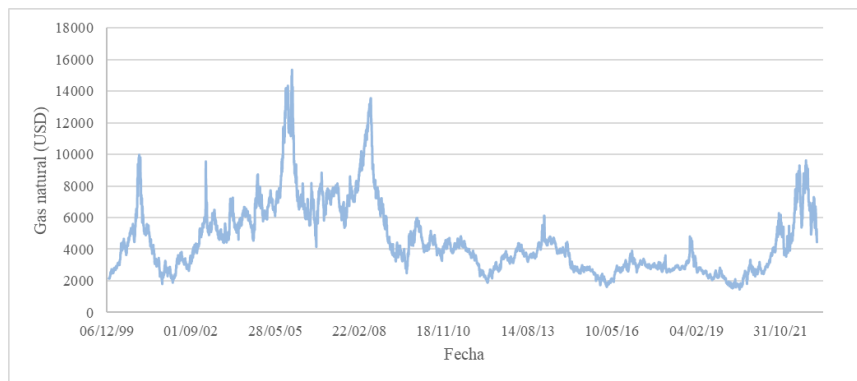


Fuente: elaboración del autor a partir de XM (s. f.-a).

### 3.1.8 Precios del gas natural y del crudo West Texas Intermediate (WTI)


Detrás de la hidroeléctrica, la segunda fuente de generación eléctrica en el país es la termogeneración (Rodríguez, 2023), que depende de combustibles fósiles como el gas y los derivados del petróleo. Se consideraron los precios de estos *commodities*, puesto que, en momentos de bajo caudal en las cuencas de generación, la matriz energética del país puede volcarse a una dependencia de generación térmica que condicione los precios a la evaluación internacional de los insumos [Figura 9 y Figura 10].

Figura 9. Precios del gas natural en USD (julio de 1999-octubre de 2021)



Fuente: elaboración del autor a partir de Investing.com (s. f.-a).

Figura 10. Precios de crudo West Texas Intermediate (WTI) en USD (julio de 1999-octubre de 2021)



Fuente: elaboración del autor a partir de Investing.com (s. f.-b).

### 3.1.9 Tasa de cambio USD/COP

La *tasa representativa de mercado (TRM)* es uno de los índices macroeconómicos más representativos del país, en tanto expresa un síntoma importante del desempeño económico nacional. Entendiendo que los precios de los *commodities* de combustibles se negocian en dólares norteamericanos, es fundamental poner en consideración este indicador a fin de representar el costo de la materia prima en moneda local [Figura 11].

Figura 11. Comportamiento tasa de cambio USD/COP (julio de 1999-octubre de 2021)



Fuente: elaboración del autor a partir de Investing.com (s. f.-c).

### 3.2 Análisis de correlación

Una vez definidas las variables para el modelo propuesto, resulta crucial realizar un análisis que permita evaluar, por medio de un estudio de sus patrones y tendencias, los efectos que podrían tener las variables entre sí. Para ello se propone la construcción de un análisis de correlación basado en estadística para evaluar la relación de dos variables entre sí. (Walpole, 1999)

Se evaluaron todas las variables que presentaban esta característica y se calificaron según su coeficiente de correlación —v. la Tabla 1 en el Capítulo 4 de este trabajo, “Resultados”—. El valor de este coeficiente, según su valor y signo permite clasificarlo así:

- 1: indica una correlación positiva perfecta, es decir, que cuando una variable aumenta, la otra también aumenta proporcionalmente.
- 0: indica que no hay ninguna correlación, es decir que no hay relación lineal entre las dos variables.
- -1: indica una correlación negativa perfecta, es decir, que cuando una variable aumenta, la otra disminuye proporcionalmente.

### 3.3 Modelo de regresión por redes neuronales

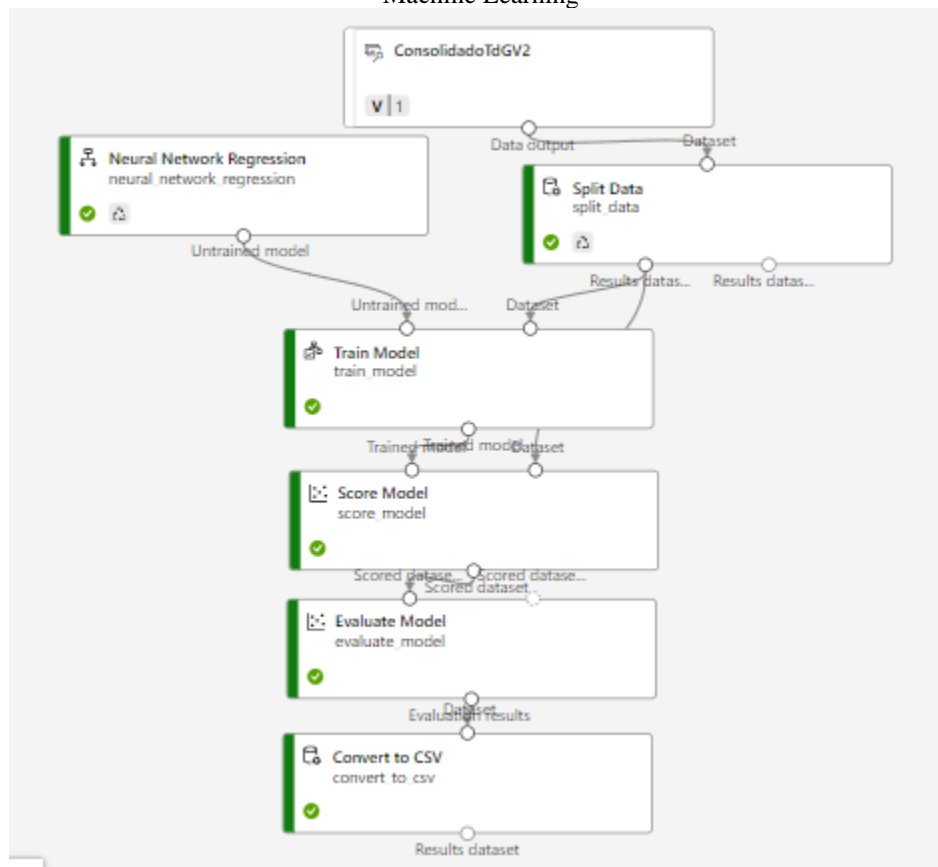
Una *regresión por redes neuronales* es una técnica de aprendizaje automático en la que se utilizan RNA para predecir valores continuos. A diferencia de la clasificación, donde se predicen categorías discretas, la regresión se enfoca en estimar una variable de salida que puede tomar cualquier valor dentro de un rango continuo.

Para iniciar la construcción de este modelo fue necesario la consolidación de la información por evaluar en una base de datos —*dataset*—, que es el insumo principal. Una vez se realizó la identificación mediante el análisis de correlación, se decidió incluir solamente las variables que se clasificaran con un coeficiente mayor que 0,3 o menor que -0,3, eliminando la posibilidad de que, una vez evaluado, el modelo no se ajustara adecuadamente.

La regresión buscada puede obtenerse por medio de un entrenamiento del modelo, que capacita a un algoritmo para realizar tareas específicas utilizando conjuntos de datos de entrenamiento. Este proceso se centra en la investigación y la aplicación de técnicas de aprendizaje automático, e implica una optimización de los parámetros internos del modelo a fin de minimizar una función de pérdida o de maximizar una función de recompensa, dependiendo del paradigma de aprendizaje utilizado.

El modelo de aprendizaje se basó en los parámetros establecidos en la herramienta Azure Machine Learning [Figura 12] con el parámetro *neural\_network\_regression*, que contiene en su código los parámetros base para la aplicación de una red neuronal que capacite una variable determinada por medio una compilación no lineal que otorgue un resultado para un período  $x_i$ , considerando variaciones bajo la premisa de clasificación por series temporales.

Figura 12. Pipeline de modelo de entrenamiento por regresión de red neuronal realizado con la herramienta Azure Machine Learning



Fuente: elaboración del autor.

El modelo entrenado producto de la regresión tiene la capacidad de pronosticar los valores del precio de la energía en bolsa para un período determinado; sin embargo, la fiabilidad de estos resultados debe ser evaluada a través de metodologías de cuantificación de error.

### 3.4 Evaluación de modelo entrenado

Para calificar el ajuste del modelo existen diferentes acercamientos para la evaluación del error que permiten, según sus resultados, la clasificación del resultado del modelo entrenado.

#### 3.4.1 Raíz del error cuadrático medio (RECM)

La *raíz del error cuadrático medio* (RECM), la medida de las diferencias entre los valores predichos por un modelo y los valores observados, se representa como la raíz cuadrada del promedio de los errores al cuadrado y proporciona la medida de cuán precisas son las predicciones. La RECM suma las magnitudes de los errores en una sola métrica, lo que es útil al comparar el poder predictivo de los modelos con los datos mismos; asimismo, es siempre no negativa, y con un valor de 0 estaría perfectamente ajustada —Ecuación 3—. (Hyndman & Koehler, 2021)

ECUACIÓN 3. Ecuación de la RECM

$$RECM = \sqrt{\frac{\sum_{t=1}^T (y'_t - y_t)^2}{T}}$$

Fuente: Hyndman & Koehler (2021).

### 3.4.2 Raíz del error cuadrático relativo (RECR)

A diferencia de la RECM, el *error cuadrático relativo* (RECR) permite la evaluación de errores a través de la normalización de los datos —entendiendo que estos últimos usan valores medios—, y resulta especialmente útil para la calificación de modelos que consideran variables en distintas unidades —Ecuación 4—. (Hiregoudar, 2020)

ECUACIÓN 4. Ecuación de la RECR

$$RECR = \frac{\sum_{j=1}^n (P_j - T_j)^2}{\sum_{j=1}^n (T_j - T)^2}$$

Fuente: Hiregoudar (2020).

### 3.4.3 Coeficiente de determinación ( $R^2$ )

El *coeficiente de determinación*, o regresión ( $R^2$ ), es una medida estadística que representa la variación de una variable dependiente en comparación con las variables independientes en un modelo de regresión. Este coeficiente suele ser un valor decimal que oscila entre  $-1$  y  $1$ , siendo  $1$  una correlación perfecta inversa y,  $-1$ , una correlación perfecta positiva, pasando por el  $0$ , que indica no correlación absoluta —Ecuación 5—. (Hiregoudar, 2020)

ECUACIÓN 5. Ecuación del  $R^2$

$$R^2 = 1 - \frac{\sum_i (y_i - y'_i)^2}{\sum_i (y_i - \bar{y})^2}$$

Fuente: Hiregoudar (2020).

## 3.5 Análisis de sensibilidad

El modelo obtenido por la regresión mediante redes neuronales es un gran paso en busca del objetivo de este trabajo; sin embargo, es fundamental encontrar herramientas que permitan evaluar la variación que puede tener el uso de este pronóstico sobre las finanzas de una empresa en la que sus ingresos operacionales dependen únicamente de la venta de energía.

Para ello se propone el uso de un *análisis de sensibilidad* que permita la comparación de los resultados reales de una empresa frente a una proyección basada en modelos de *machine learning*.

En el ejercicio de valoración realizado a una empresa debe realizarse una proyección de diferentes elementos que busquen anticipar el futuro, y donde el objetivo sea la mitigación de riesgos y se elimine la volatilidad en la mayor cantidad de ítems. En el análisis de sensibilidad se busca realizar una comparación de las variables que modifiquen la información financiera con

alguna métrica de comparación, por ejemplo, la tasa interna de retorno (TIR), el valor presente neto (VPN) o un análisis por flujo de caja descontado. (Pérez *et al.*, 2012)

La propuesta para realizar este análisis fue la de comparar la proyección del estado financiero de la compañía Generación de Energía S. A. S. en el período 2018-2022, llevando a cabo una proyección de los ingresos basada en la generación real de la compañía y ajustados a los precios de bolsa proyectados, y compararlos con los resultados reales para determinar qué tan ajustable es el uso de esta herramienta de pronóstico.

## 4. Resultados

### 4.1 Análisis de correlación

Una vez seleccionadas las variables, se aplicó el análisis de correlación buscando las variables más significativas [Tabla 1].

Tabla 1. Coeficientes de correlación entre las variables

	Precio Bolsa	Capacidad (kW)	Demanda Energía SIN (kW-h)	ENSO index	Generación kW-h	IPC	Nivel de embalse (m <sup>3</sup> )	Precio crudo WTI (USD)	Precio gas natural (USD)	USD/COP
Precio en bolsa	1.00									
Capacidad (kW)	0.43	1.00								
Demanda energía SIN kW-h	0.44	0.88	1.00							
ENSO index	0.34	-0.06	-0.08	1.00						
Generación kW-h	0.41	0.86	0.92	-0.10	1.00					
IPC	0.40	0.82	0.86	-0.12	0.87	1.00				
Nivel de embalse (m <sup>3</sup> )	0.06	0.74	0.64	-0.23	0.63	0.54	1.00			
Precio crudo WTI (USD)	0.02	0.10	0.34	-0.35	0.37	0.47	0.08	1.00		
Precio gas natural (USD)	-0.29	-0.40	-0.33	-0.21	-0.30	-0.17	-0.21	0.27	1.00	
USD/COP	0.30	0.80	0.59	-0.02	0.56	0.51	0.65	-0.27	-0.19	1.00

Fuente: elaboración del autor

Los resultados obtenidos señalan un comportamiento muy diferente entre las distintas variables y muestran qué elementos deberían considerarse para la elaboración de la regresión por red neuronal y cuáles deberían descartarse para encontrarle un mejor ajuste al modelo.

Las tendencias de los precios de los *commodities* indican que no existe un sentido de comportamiento común frente al comportamiento del kW-h en la bolsa colombiana, a pesar de que son insumos para la producción termoeléctrica; así, el supuesto de que una eventual alza en su valor tiene consecuencia sobre la valoración de la energía nacional se desmiente al no mostrar una clara relación.

Otro de los hallazgos que se resaltan es la irrelevancia que muestra el nivel de los embalses en comparación con el precio de la energía en bolsa. Es factible que la volatilidad que presenta este índice no sea congruente con el comportamiento bursátil de la energía, lo que resulta en la exclusión dentro del modelo final.

Por último, se descarta la consideración de la tasa cambiaria entre el dólar norteamericano y el peso colombiano, pues su coeficiente de correlación no es significativo, sumado al hecho de que si se dejan por fuera del análisis los insumos como el petróleo y el gas, que están representados en dólares, su inclusión estaría injustificada.

## 4.2 Modelo de regresión por redes neuronales

Una vez elegidos los datos considerados, el modelo propuesto fue ejecutado según la metodología planteada, buscando la proyección de los valores diarios de la energía. El resultado se divide en dos entregables: el *scored model*, que ofrece la proyección de valores para cada una de las fechas elegidas, y el *evaluated model*, que evidencia las calificaciones de error y los indicadores de ajuste de la regresión.

La Tabla 2 presenta una extracción de la muestra del *scored model* obtenida para noviembre de 2018, como una comparación inicial de las diferencias de los precios. En esta muestra se evidencia una variación considerable dentro del precio real de la energía en comparación con el obtenido en la modelación.

Tabla 2. Precios reales de bolsa frente a precios proyectados por una regresión de red neuronal (noviembre de 2018)

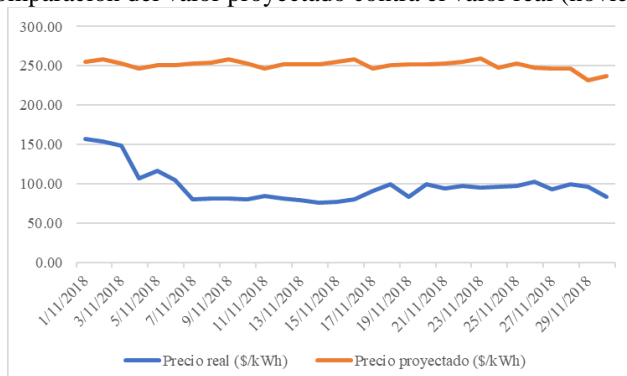
Fecha	Precio real (COP/kW-h)	Precio proyectado (COP/kW-h)	Variación (%)
1/11/2018	157,23	255,01	38,34
2/11/2018	153,89	258,50	40,47
3/11/2018	148,78	253,44	41,30
4/11/2018	107,66	246,47	56,32
5/11/2018	116,59	250,95	53,54
6/11/2018	105,18	251,04	58,10
7/11/2018	80,73	252,66	68,05
8/11/2018	82,11	254,53	67,74
9/11/2018	81,33	258,25	68,51
10/11/2018	80,09	252,77	68,32
11/11/2018	84,68	246,92	65,70
12/11/2018	81,49	252,06	67,67
13/11/2018	79,85	251,47	68,25
14/11/2018	75,83	251,41	69,84
15/11/2018	76,98	254,82	69,79
16/11/2018	80,69	258,40	68,77
17/11/2018	90,70	246,80	63,25
18/11/2018	100,09	251,39	60,19
19/11/2018	83,48	252,42	66,93
20/11/2018	99,76	251,85	60,39
21/11/2018	94,37	252,70	62,66
22/11/2018	97,74	255,51	61,75
23/11/2018	95,03	259,00	63,31
24/11/2018	96,96	247,17	60,77
25/11/2018	97,54	253,30	61,49
26/11/2018	102,89	247,34	58,40
27/11/2018	92,78	246,96	62,43
28/11/2018	100,03	247,14	59,52
29/11/2018	96,04	231,75	58,56
30/11/2018	83,34	237,07	64,85

Nota. Cifras expresadas en pesos colombianos

Fuente: elaboración del autor.

Los resultados se pueden comparar en la Figura 13, en la que se observa que, a pesar de conservar una tendencia comparable, el precio proyectado tiene una sobrevaloración del activo para la muestra, con una desviación promedio del 60 %.

Figura 13. Comparación del valor proyectado contra el valor real (noviembre de 2018)



Fuente: elaboración del autor.

La Tabla 3, que muestra los resultados del *evaluated model*, evidencia unos valores alejados de lo esperado en la modelación por redes neuronales. Los resultados de la regresión presentan un nivel de ajuste bajo que indican que la proyección puede generar un nivel de incertidumbre importante.

Tabla 3. Resultados de ajuste del modelo

Raíz del error cuadrático relativo (RECR)	Raíz del error cuadrático relativo (RECR)	Coefficiente de determinación ( $R^2$ )
139,17	0,71	0,28


Fuente: elaboración del autor.

Si se ponen en consideración los resultados del modelo frente a algunas de las propuestas de pronóstico evaluadas en la literatura, se pueden encontrar modelos de pronóstico con unos indicadores de ajuste más apropiados. En 2023, Villareal y Flores encontraron que la aplicación de modelos de *machine learning* como Sarimax —*Seasonal autoregressive integrated moving average with exogenous regressors*— presentaban un error relativo del 26,4 % que tenía una aplicación acertada en una proyección de mediano plazo. Si el análisis se orienta al horizonte de largo plazo, la opción planteada que más ajuste tuvo fue la de regresión múltiple, puesto que mostraba un  $R^2$  de 0,452. Este tipo de regresión permite una considerable mitigación de riesgos y se muestra como una interesante herramienta para el análisis financiero de compañías dedicadas a la generación eléctrica. (Villareal & Flores, 2023)

### 4.3 Análisis de sensibilidad

Los resultados de la proyección de precios se aplicaron en el análisis de sensibilidad sobre la compañía Generación de Energía S. A. S. para el período 2018-2022, a partir de sus registros históricos de generación.

Figura 14. Registros históricos de generación de la compañía Generación de Energía S. A. S. (2018-2022)



Nota. Cifras expresadas en kWh.

Fuente: elaboración del autor.

Con esta información, y aplicando los resultados de la regresión, fue posible obtener la proyección de los ingresos operacionales de la compañía, para ser comparados con los resultados reales [Tabla 4].

Tabla 4. Comparación de los ingresos de la compañía Generación de Energía S. A. S. (2018-2022)

	2018	2019	2020	2021	2022
<b>Ingresos reales</b>	\$ 1.955	\$ 2.594	\$ 2.729	\$ 3.610	\$ 4.144
<b>Ingresos proyectados</b>	\$ 2.106	\$ 3.990	\$ 2.273	\$ 2.220	\$ 2.439
<b>Diferencia</b>	-\$ 151	-\$ 1.395	\$ 457	\$ 1.390	\$ 1.705
<b>Variación</b>	7,7%	53,8%	16,7%	38,5%	41,2%

Nota. Cifras expresadas en millones COP.

Fuente: elaboración del autor.

Los resultados comparados en la Tabla 4 evidencia las considerables diferencias entre la realidad presentada en materia de ingresos con respecto a lo obtenido usando los datos producidos dentro del modelo de regresión por redes neuronales.

En pro de tener una visión más completa del panorama de los resultados del periodo de estudio, es necesario evaluar el estado de resultados entre 2018 y 2022. [Tabla 5].

Tabla 5. Estado de resultados reales de la compañía Generación de Energía S. A. S. (2018-2022)

Concepto	2018	2019	2020	2021	2022
Ingresos	1955	2594	2729	3610	4144
Devoluciones	-	-	-	-	-

Ingresos operacionales netos	1955	2594	2729	3610	4144
Costos de producción	728	768	1131	933	2096
Depreciación	445	452	454	448	466
Total costos	1173	1220	1585	1381	2561
Utilidad en ventas	782	1374	1144	2229	1583
Gastos admón. y ventas	294	200	265	373	340
Utilidad operativa	488	1174	879	1856	1243
Otros ingresos	109	31	32	75	147
Otros egresos y gastos financieros	1049	1026	790	812	1111
Utilidad antes de impuestos	- 452	179	122	1119	279
Impuesto corriente renta	-	77	50	348	75
Impuesto diferido	-	- 70	9	- 111	0
Utilidad del ejercicio	- 452	171	63	882	203

*Nota.* Cifras expresadas en COP millones.

Fuente: elaboración del autor.

Al ser el modelo de regresión por redes neuronales un pronóstico orientado al precio del kW-h en la Bolsa de Energía de Colombia, en el análisis de sensibilidad, las demás variables del estado de resultados se consideraron estáticas y ajustadas a los datos reales proporcionados por la compañía. Cabe resaltar que la producción para el análisis también fue considerada idéntica a lo registrado durante el tiempo de operación, buscando orientar el análisis sobre el desempeño financiero. [Tabla 6].

Tabla 6. Comparación de la utilidad de la compañía Generación de Energía S. A. S. (2018-2022)

	2018	2019	2020	2021	2022
<b>Utilidad real</b>	-\$ 452	\$ 171	\$ 63	\$ 882	\$ 203
<b>Utilidad proyectada</b>	-\$ 301	\$ 1.567	-\$ 394	-\$ 508	-\$ 1.502
<b>Diferencia</b>	-\$ 151	-\$ 1.395	\$ 457	\$ 1.390	\$ 1.705
<b>Variación</b>	-33,3%	814,4%	727,3%	157,7%	840,0%

*Nota.* Cifras expresadas en millones COP.

Fuente: elaboración del autor.

Por otro lado, si el análisis se considera bajo una evaluación por valor presente neto (VPN), en el modelo real se obtiene un monto de COP 440 683 070,26 en comparación con el modelo proyectado, con un resultado de COP -429 820 472,18, usando una tasa de descuento idéntica para ambos. Con respecto a la tasa interna de retorno (TIR), los resultados también distan considerablemente: 49 % para los flujos de caja del estado de resultados real frente a 36 % del proyectado.

## 5. Conclusiones y recomendaciones

### 5.1 Conclusiones

La investigación demostró que la precisión y el ajuste de un modelo de redes neuronales son cruciales para obtener resultados fiables. Un modelo que presente resultados que evidencien un mal ajuste puede llevar a interpretaciones erróneas sobre el impacto de las variables claves en el rendimiento financiero de empresas dedicadas a la generación de energía eléctrica en Colombia.

Varias razones pueden haber contribuido al mal ajuste del modelo. En primera instancia se resalta la inclusión de resultados atípicos para el análisis, como lo fue el período de contingencia causado por la pandemia de 2020 a 2022, que afectó los comportamientos de generación y consumo de energía; además, se destacan los períodos de sequía y de fuertes precipitaciones relacionados con el fenómeno de El Niño, que presentó una de las intensidades históricas más grandes en 2015. (Estados Unidos, National Oceanic and Atmospheric Administration, NOAA, s. f.)

La estacionalidad de los datos se considera relevante, entendiendo que un análisis diario de precio puede generar imprecisiones al considerar todos los factores a pequeña escala que pueden influir sobre la valoración del activo.

En conclusión, el modelo de pronóstico de precios basado en regresión por redes neuronales no presenta una alternativa fiable de predicción de los precios de la energía en el marco de estudio colombiano, en tanto los indicadores de ajuste obtenidos lo sitúan lejos de poder ser considerado para modelos de predicción y evaluación de riesgos.

### 5.2 Recomendaciones

Considerando que existen metodologías con índices de ajuste mayores como Sarima y la regresión múltiple, se sugiere su uso para las proyecciones financieras como alternativas a los métodos tradicionales. Además, se recomienda la exploración de otros modelos alternativos de *machine learning* que puedan generar resultados aún más adecuados como modelos de soporte vectorial o de regresión *ridge*

Se recomienda la valoración de redes neuronales en períodos de tiempo más cortos que permitan la normalización de los datos en una escala mensual, y comparar los resultados de ajuste para futuras aplicaciones.

### 5.3 Conclusión general

Aunque el modelo de redes neuronales empleado en este trabajo no proporcionó un ajuste adecuado, el proceso permitió identificar áreas claves para mejorar en futuras investigaciones. Se destacan la importancia de mejorar la calidad y la representatividad de los datos, así como la necesidad de una optimización de los períodos de evaluación.

Es esencial continuar desarrollando y refinando modelos predictivos para proporcionar herramientas analíticas robustas que ayuden a las compañías generadoras de energía a enfrentar desafíos operativos y estratégicos. Modelos más precisos y fiables mejorarán significativamente la toma de decisiones optimizando la gestión de recursos, mejorando la previsión de la demanda y ayudando a mitigar riesgos. Aunque los resultados no fueron los esperados, los aprendizajes obtenidos son invaluable para guiar futuras investigaciones y avanzar hacia la creación de herramientas predictivas más eficaces en el sector energético.

## Referencias

- Amazon Web Services, AWS. (s. f.). *¿Qué es una red neuronal?* <https://aws.amazon.com/es/what-is/neural-network/>
- Barrientos, J., Rodas, E., Velilla, E., Lopera, M., & Villada, F. (2012). Modelo para el pronóstico del precio de la energía. *Lecturas de Economía*, 77, 91-127. [https://bibliotecadigital.udea.edu.co/bitstream/10495/3633/1/BarrientosJorge\\_2012\\_ModeloPronosticoPrecio.pdf](https://bibliotecadigital.udea.edu.co/bitstream/10495/3633/1/BarrientosJorge_2012_ModeloPronosticoPrecio.pdf)
- Bello Rodríguez, S. P., & Beltrán Ahumada, R. B. (2010). Caracterización y pronóstico del precio *spot* de la energía. *Revista Maestría en Derecho Económico*, 6(6), 293-316. <https://revistas.javeriana.edu.co/index.php/revmaescom/article/view/7174>
- Colombia, Banco de la República. (s. f.). *Índice de precios al consumidor (IPC)*. <https://www.banrep.gov.co/es/estadisticas/indice-precios-consumidor-ipc>
- Colombia, Departamento Administrativo Nacional de Estadística, DANE. (s. f.). *IPC. Índices de precios al consumidor*. <https://www.dane.gov.co/index.php/estadisticas-por-tema/precios-y-costos/indice-de-precios-al-consumidor-ipc>
- Coronilla Valdivieso, R. M. (2021). *Inversión en el mercado de valores: análisis fundamental, análisis técnico y estrategias de inversión* [tesis de maestría, Universidad de Sevilla, Departamento de Contabilidad y Finanzas, Sevilla]. <https://idus.us.es/handle/11441/127387>
- Estados Unidos, National Oceanic and Atmospheric Administration, NOAA. (s. f.). *Multivariate ENSO Index Version 2 (MEI.v2)*. <https://psl.noaa.gov/enso/mei/>
- Fama, E. F. (1969). Efficient capital markets: a review of theory and empirical work. *The Journal of Finance*, 25(2), 383-417. <https://doi.org/10.2307/2325486>
- Hiregoudar, S. (2020). *Ways to evaluate regression models*. Towards Data Science. <https://towardsdatascience.com/ways-to-evaluate-regression-models-77a3ff45ba70>
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3.<sup>a</sup> ed.). Melbourne: O Texts.
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679-688. <https://doi.org/10.1016/j.ijforecast.2006.03.001>
- International Business Machines, IBM. (s. f.). *¿Qué son las redes neuronales recurrentes?* <https://www.ibm.com/es-es/topics/recurrent-neural-networks>
- Investing.com (s. f.-a). *Futuros gas natural - Jul 2024 (NGM4)*. <https://es.investing.com/commodities/natural-gas>
- Investing.com (s. f.-b). *Futuros petróleo crudo WTI - Jul 2024 (CLN4)*. <https://es.investing.com/commodities/crude-oil>
- Investing.com (s. f.-c). *USD/COP - Dólar Peso colombiano*. <https://es.investing.com/currencies/usd-cop>
- López Díez, J. C. (2017). 1992: el año en que se nos fueron las luces. *Revista Gestión y Región*, 23, s. pp. <https://revistas.ucp.edu.co/index.php/gestionyregion/article/view/112>

- Lu, M., & Xu, X. (2023). TRNN: an efficient time-series recurrent neural network for stock. *Information Sciences*, 657, s. pp. <https://doi.org/10.1016/j.ins.2023.119951>
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5, 115-133. <https://doi.org/10.1007/BF02478259>
- Mera, J. (2023). *Modelos de predicción: todos los detalles de este proceso matemático*. INESEM Business School. <https://www.inesem.es/revistadigital/informatica-y-tics/modelos-de-prediccion/>
- Mir, M., Dipu Kabir, H. M., & Nasirzadeh, F. (2020). Neural network-based interval forecasting of construction material prices. *Journal of Building Engineering*, 39, s. pp. <https://doi.org/10.1016/j.jobe.2021.102288>
- Misas, M., López, E., & Querubín, P. (2002). *La inflación en Colombia: una aproximación desde las redes neuronales*. Banco de la República, Borradores de Economía 139. <https://www.banrep.gov.co/es/inflacion-colombia-aproximacion-las-redes-neuronales>
- Murphy, J. J. (1999). *Análisis técnico de los mercados financieros*. Ciudad de Nueva York, NY: New York Institute of Finance. <https://archive.org/details/AnlisisTcnicoDeLosMercadosFinancierosJohnJ.Murphy>
- Ochoa Franco, F. J., Smith Quinteto, R., & Villegas Botero, L. J. (2002). “Orígenes”, Capítulo 1 en *El sector eléctrico colombiano. Orígenes, evolución y retos. Un siglo de desarrollo 1882-1999*. Medellín: Interconexión Eléctrica S. A., ISA. <https://memoriaempresarial.eafit.edu.co/wp-content/uploads/2014/08/03.Historia-de-la-electricidad-en-las-regiones-de-Colombia.pdf>
- Pérez, S. S., Cruz, D., & Quiroz, L. G. (2012). *Análisis de sensibilidad de indicadores financieros en la evaluación de inversiones en mipymes*. VI Encuentro de Investigación en Ciencias Económico Administrativas, Universidad Autónoma del estado de Hidalgo, México. <https://repository.uaeh.edu.mx/bitstream/handle/123456789/7263?show=full>
- Perú, Instituto del Mar de Perú, Imarpe. (s. f.). *Índice Niño Oceánico (ONI)*. [https://www.imarpe.gob.pe/imarpe/index2.php?id\\_seccion=I017809050000000000000000](https://www.imarpe.gob.pe/imarpe/index2.php?id_seccion=I017809050000000000000000)
- Rodríguez, J. (2023, julio 17). ¡Que se haga la luz! Así se genera la energía eléctrica en Colombia. *Portafolio*. <https://www.portafolio.co/economia/infraestructura/sector-electrico-en-colombia-asi-funciona-la-generacion-de-energia-en-el-pais-584285>
- Sandoval Erazo, W. R., & Aguilera Ortiz, E. P. (2014). Determinación de caudales en cuencas con poca información hidrológica. *Revista Ciencia UNEMI*, 7(12), 100-110. <https://dialnet.unirioja.es/servlet/articulo?codigo=5210356>
- Stanford University. (s. f.). *Neural networks history: The 1980's to the present*. <https://cs.stanford.edu/people/eroberts/courses/soco/projects/neural-networks/History/history2.html>
- Statista Research Department. (s. f.). *Distribución del producto interno bruto (PIB) por actividad económica en Colombia en 2021*. <https://es.statista.com/estadisticas/1337044/distribucion-de-las-actividades-economicas-en-el-pib-de-colombia/>
- Stringham, E. (2015). *Private governance: Creating order in economic and social life*. Oxford, Inglaterra: Oxford University Press.

- Tsay, R. S. (2002). *Analysis of financial time series*. Hoboken, NJ: John Wiley & Sons.
- Universidad Politécnica de Madrid. (s. f.). *05.1 Redes Neuronales. Introducción*.  
[https://dcain.etsin.upm.es/~carlos/bookAA/05.1\\_RedetesNeuronalesIntroduccion.html](https://dcain.etsin.upm.es/~carlos/bookAA/05.1_RedetesNeuronalesIntroduccion.html)
- Villada, F., Muñoz, N., & García, E. (2012). Aplicación de las redes neuronales al pronóstico de precios en el mercado de valores. *Información Tecnológica*, 23(4), s. pp.  
[https://www.scielo.cl/scielo.php?script=sci\\_arttext&pid=S0718-07642012000400003](https://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0718-07642012000400003)
- Villareal, Y., & Flores, L. (2023). *Predicción del precio de la energía eléctrica en Colombia mediante un enfoque de machine learning* [tesis de maestría, Universidad EAFIT, Medellín].  
<https://repository.eafit.edu.co/server/api/core/bitstreams/c6124f19-b8be-421c-aaa7-979154f3d904/content>
- Walpole, R. (1999). *Probabilidad y estadística para ingenieros* (6.<sup>a</sup> ed.). Ciudad de México: Prentice-Hall.
- XM. (s. f.-a). *Disponibilidad real*.  
<https://sinergox.xm.com.co/oferta/Paginas/Informes/DisponibilidadReal.aspx>
- XM. (s. f.-b). *Preguntas frecuentes*. [https://www.xm.com.co/herramientas/preguntas-frecuentes#:~:text=La %20Bolsa %20de %20Energ %C3 %ADa %20\(mercado,del %20precio %20de %20corto %20plazo](https://www.xm.com.co/herramientas/preguntas-frecuentes#:~:text=La%20Bolsa%20de%20Energ%C3%ADa%20(mercado,del%20precio%20de%20corto%20plazo)
- XM. (s. f.-c). *Pronóstico de demanda*. <https://www.xm.com.co/consumo/pronostico-de-demanda>