



UNIVERSIDAD  
CATÓLICA  
DE CUENCA

**UNIVERSIDAD CATÓLICA DE CUENCA**

*Comunidad Educativa al Servicio del Pueblo*

**UNIDAD ACADÉMICA DE INGENIERIA,  
INDUSTRIA Y CONSTRUCCIÓN**

**CARRERA DE ELECTRICIDAD**

**PREVISION ESPACIO TEMPORAL DE LA DEMANDA  
ELECTRICA EN LA EMPRESA REGIONAL CENTRO  
SUR**

**PROYECTO DE TITULACIÓN PREVIO A LA OBTENCIÓN DEL  
TÍTULO DE INGENIERO ELECTRICO**


**AUTOR: CHRISTIAN ANDRES MACAO PIÑA**

**DIRECTOR: ING. DANIEL ORLANDO ICAZA ALVAREZ**

**CUENCA – ECUADOR**

**2023**

**DIOS, PATRIA, CULTURA Y DESARROLLO**



**UNIVERSIDAD CATÓLICA DE CUENCA**

*Comunidad Educativa al Servicio del Pueblo*

**UNIDAD ACADÉMICA DE INGENIERIA,  
INDUSTRIA Y CONSTRUCCION**

**CARRERA DE ELECTRICIDAD**

**PREVISION ESPACIO TEMPORAL DE LA DEMANDA  
ELECTRICA EN LA EMPRESA REGIONAL CENTRO SUR**

**PROYECTO DE TITULACIÓN PREVIO A LA OBTENCIÓN DEL  
TÍTULO DE INGENIERO ELECTRICO**

**AUTOR: CHRISTIAN ANDRES MACAO PIÑA**

**DIRECTOR: DANIEL ORLANDO ICAZA ALVAREZ**

**CUENCA – ECUADOR**

**2023**

**DIOS, PATRIA, CULTURA Y DESARROLLO**

## DECLARATORIA DE AUTORÍA Y RESPONSABILIDAD

Christian Andrés Macao Piña portador de la cédula de ciudadanía N° 0105782023. Declaro ser el autor de la obra: "Previsión espacio temporal de la demanda eléctrica en la empresa Regional Centro Sur", sobre la cual me hago responsable sobre las opiniones, versiones e ideas expresadas. Declaro que la misma ha sido elaborada respetando los derechos de propiedad intelectual de terceros y eximo a la Universidad Católica de Cuenca sobre cualquier reclamación que pudiera existir al respecto. Declaro finalmente que mi obra ha sido realizada cumpliendo con todos los requisitos legales, éticos y bioéticos de investigación, que la misma no incumple con la normativa nacional e internacional en el área específica de investigación, sobre la que también me responsabilizo y eximo a la Universidad Católica de Cuenca de toda reclamación al respecto.

Cuenca, 24 de noviembre de 2023

F:   
Christian Andrés Macao Piña  
0105782023

## CERTIFICACIÓN

Certifico que el presente trabajo fue desarrollado por Christian Andrés Macao Piña, bajo mi supervisión.

A handwritten signature in blue ink, consisting of stylized initials and a surname, positioned above a horizontal line.

**Ing. Daniel Orlando Icaza Álvarez**

## **DEDICATORIA**

Queridos papa y mama, no hay palabras suficientes para agradecerles todo lo que han hecho por mí. Gracias por enseñarme el valor de la educación por ser mi fuente de inspiración, motivación, confianza y por brindarme todo su apoyo para alcanzar mis metas. Esta tesis es una forma de agradecerles por su constante apoyo y por creer en mi incluso en los momentos más difíciles.

A mi querido hijo a quien amo con todo mi corazón espero que esta tesis sea una fuente de inspiración y motivación para que persiga sus sueños con pasión y determinación.

## **AGRADECIMIENTOS**

A mis padres, ustedes han sido el motor que impulsa mis sueños y esperanzas quienes estuvieron siempre a mi lado en los días y noches más difíciles durante mis horas de estudio. Siempre han sido los mejores guías de vida. Hoy cuando concluyo mis estudios, les dedico a ustedes este logro amados padres, como una etapa más conquistada. Orgulloso de tenerles como mis padres y que estén a mi lado en este momento tan importante para mí. Gracias por ser quienes son y por creer en mí.

Quiero agradecer profundamente a mi compañera de vida Renata y a mi hijo, quienes me brindaron su apoyo, me comprendieron, tuvieron tolerancia e infinita paciencia y cedieron su tiempo para que “Papá estudie”, para permitir así llevar adelante un proyecto que paso de ser personal a un proyecto familiar. A ellos, mi eterno amor y gratitud.

A los ingenieros Sergio Zambrano y Andrés Patiño, quienes me supieron guiar y compartieron sus conocimientos al momento de desarrollar esta investigación.

Agradezco sinceramente a mi director de tesis, Ing. Daniel Icaza, por su invaluable orientación y apoyo a lo largo de este proceso. Sus conocimientos y asesoramiento fueron fundamentales para la realización de este trabajo. Su dedicación y compromiso son muy apreciados. Gracias por hacer posible este logro académico.

## RESUMEN

En este trabajo de titulación se presenta el desarrollo y aplicación de un modelo de proyección de la demanda eléctrica espacial y temporalmente mediante la creación de un algoritmo en Machine Learning (ML), para dar respuesta al problema de planificación a mediano y largo plazo del sistema de distribución eléctrica de la Empresa Eléctrica Regional Centro Sur C.A. Este estudio aportara con un beneficio positivo para la empresa distribuidora del servicio eléctrico, en cuanto a la planificación y asignación de recursos en el área de distribución.

Esta investigación está enfocada en la proyección de la demanda eléctrica en áreas pequeñas desagregando la proyección global de la CENTROSUR, teniendo en cuenta un área de estudio que cuenta con 8 subestaciones (S/E), el modelo de simulación analizara los diferentes tipos de consumidores como son residencial, comercial e industrial.

El modelo aplicado en esta investigación está desarrollado con redes neuronales convolucionales (CNN), haciendo uso del lenguaje de programación Python. teniendo en cuenta variables de entrada como factores espaciales, proyección del crecimiento de consumidores, proyección de la demanda eléctrica. Creando un mapa de probabilidades de crecimiento en el área de estudio para luego mediante el modelo matemático celular automático (CA) asignar nuevos clientes espacialmente, de acuerdo con la proyección global de cada subestación.

*Palabras clave:* Redes neuronales convolucionales, demanda eléctrica, celular automático, previsión espacio-temporal.

## **ABSTRACT**

This degree work presents the development and application of a spatial and temporal electric demand projection model through the creation of an algorithm in Machine Learning (ML) to respond to the medium- and long-term planning problem of the electric distribution system of the Regional Electric Company (Centro Sur C.A. in Spanish.) This study will provide a positive benefit for the electric service distribution company in terms of planning and allocation of resources in the distribution area.

This research is focused on the projection of the electric demand in small areas disaggregating the global projection of the Regional Electric Company (CENTROSUR) considering a study area that has eight substations (Electrical Substations), the simulation model will analyze the different types of consumers such as residential, commercial, and industrial.

The model applied in this research is developed with convolutional neural networks (CNN) using Python programming language and considering input variables such as spatial factors, consumer growth projection, and electricity demand projection. A map of growth probabilities in the study area was created. Then, the mathematical model cellular automaton (CA) was used to assign new customers spatially, according to the global projection of each substation.

*Keywords:* Convolutional neural networks, electric demand, cellular automaton, spatio-temporal forecasting.

## ÍNDICE DE CONTENIDO

DECLARATORIA .....	i
CERTIFICACIÓN.....	ii
DEDICATORIA .....	iii
AGRADECIMIENTOS.....	iv
RESUMEN .....	v
ABSTRACT .....	vi
INDICE DE CONTENIDOS .....	vii
LISTA DE FIGURAS.....	viii
LISTA DE TABLAS .....	ix
LISTA DE ECUACIONES.....	ix
LISTA DE ANEXOS.....	ix
INTRODUCCION .....	1
CAPÍTULO 1. DATOS GENERALES .....	5
CAPÍTULO 2. MARCO TEORICO .....	7
CAPÍTULO 3. METODOLOGIA.....	20
CAPÍTULO 4. CASO DE ESTUDIO.....	35
CONCLUSIONES.....	50
RECOMENDACIONES.....	51
REFERENCIAS BIBLIOGRÁFICAS.....	52
ANEXOS .....	56

## LISTA DE FIGURAS

Figura 1 Estructura de un modelo de proyección espacial.....	10
Figura 2 Métodos para la proyección de la demanda eléctrica. ....	11
Figura 3 Modelo general de una neurona artificial .....	13
Figura 4 Esquema de una ANN .....	13
Figura 5 Ejemplo de las arquitecturas CNN más conocidas .....	15
Figura 6 Arquitectura VGG-16.....	16
Figura 7 Capa de convolución.....	17
Figura 8 Capa de agrupación .....	17
Figura 9 Flujograma de la metodología para la investigación.....	26
Figura 10 Primera etapa del proceso .....	27
Figura 11 Diagrama de flujo del geo procesamiento de los factores .....	30
Figura 12 Diagrama de flujo de la CNN .....	31
Figura 13 Segunda etapa del proceso .....	32
Figura 14 Efecto Vecindad. a) Vecindario tipo Moore. b) Vecindario tipo Von Neumann .....	33
Figura 15 Tercera y última etapa .....	34
Figura 16 Área de estudio.....	35
Figura 17 Área de concesión de las subestaciones .....	36
Figura 18 Factores geo procesados .....	37
Figura 19 Arquitectura propuesta.....	39
Figura 20 Curva de error en el entrenamiento de la clase Residencial .....	40
Figura 21 Mapa de probabilidades de desarrollo establecidas por la CNN .....	41
Figura 22 Distribución de los consumidores tipo residencial en el año base.....	42
Figura 23 Proyección de la demanda eléctrica para los siguientes años por cada subestación de CENTROSUR.....	43
Figura 24 Repartición porcentual de potencia KWh para el año base.....	44
Figura 25 Comparación del crecimiento total en los diferentes lapsos de tiempo .....	46
Figura 26 Repartición porcentual de los tipos de consumidor para el año base .....	47
Figura 27 Distribución espacial de clientes en los diferentes años de la clase "Residencial" .....	48
Figura 28 Resultados de la distribución espacial de la demanda eléctrica en los diferentes lapsos de tiempo para la clase "Residencial" .....	49
Figura 29 Distribución espacial de clientes para la clase comercial .....	56
Figura 30 Distribución espacial de la demanda eléctrica de la clase comercial.....	57
Figura 31 Distribución espacial de clientes para la clase industrial .....	58
Figura 32 Distribución espacial de la demanda eléctrica para la clase industrial .....	59

## LISTA DE TABLAS

Tabla 1 Funciones de activación más utilizadas .....	18
Tabla 2 Factores espaciales .....	28
Tabla 3 Número de clientes según su tipo de consumidor en cada S/E del año base..	36
Tabla 4 Resultados del entrenamiento del CNN según clase de consumidor .....	39
Tabla 5 Métricas de precisión en vecindario tipo Von Neumann .....	41
Tabla 6 Métricas de precisión en vecindario tipo Moore .....	41
Tabla 7 Potencia KWh de cada S/E por cada tipo de consumidor .....	43
Tabla 8 Incremento de usuarios en cada S/E según tipo de consumidor .....	45

## LISTA DE ECUACIONES

<b>Ecuación 1:</b> Ecuación de la función de salida de la una red neuronal artificial .....	20
<b>Ecuación 2:</b> Ecuación de la capa convolucional de una CNN .....	20
<b>Ecuación 3:</b> Ecuación de la función max-pooling de la capa de agrupación .....	21
<b>Ecuación 4:</b> Ecuación de la función average pooling de la capa de agrupación .....	21
<b>Ecuación 5:</b> Ecuación general de celular autómeta .....	21
<b>Ecuación 6:</b> Ecuación para el desarrollo potencial de una celda .....	22
<b>Ecuación 7:</b> Ecuación de probabilidad de desarrollo espacial .....	22
<b>Ecuación 8:</b> Ecuación del efecto vecindario para la vecindad de Neumann .....	23
<b>Ecuación 9:</b> Ecuación del efecto vecindario para la vecindad de Moore .....	23
<b>Ecuación 10:</b> Ecuación para calcular el valor estocástico .....	23
<b>Ecuación 11:</b> Ecuación para calcular las perdidas MSE .....	24
<b>Ecuación 12:</b> Ecuación de matriz de confusión .....	24
<b>Ecuación 13:</b> Ecuación para calcular F1-Score .....	25
<b>Ecuación 14:</b> Ecuación para calcular la precisión de un modelo de ML .....	25

## LISTA DE ANEXOS

<b>ANEXO 1</b> .....	56
<b>ANEXO 2</b> .....	57
<b>ANEXO 3</b> .....	58
<b>ANEXO 4</b> .....	59

## 1. INTRODUCCIÓN

La inteligencia artificial (IA) tiene muchos usos en la vida cotidiana actualmente, desde simplificar las tareas a los humanos hasta realizar predicciones importantes en diferentes campos y ámbitos investigativos, es por esa razón que en este tema se considera realizar un pronóstico de la demanda eléctrica con la implementación de redes neuronales convolucionales (CNN) y redes neuronales artificiales (ANN).

Tanto Las ANN como las CNN han tenido un crecimiento y una considerable atención los últimos años, las dos principales tareas en las que se desempeñan son en la clasificación y problemas de regresión, para el caso de los sistemas eléctricos ambas tareas son de gran utilidad para las empresas de distribución y generación, por ejemplo para la tarea de regresión que es de lo que trata este estudio nos ayuda a realizar un pronóstico de la demanda eléctrica, a nivel espacio y tiempo, lo que para la empresa distribuidora del servicio EMPRESA ELECTRICA CENTRO SUR C.A, se representa en beneficio de optimización de tiempo y recursos, ya que una vez que el modelo este entrenado y validado, se pueden realizar pronósticos para responder la pregunta de ¿Dónde y cuánto va crecer la zona de concesión? Y con esos datos la empresa puede planear donde irían las subestaciones y donde se puede invertir los recursos para la zona de expansión.

En el capítulo 1 se puede apreciar los alcances y objetivos planteados para este estudio.

Seguidamente en el capítulo 2 podemos apreciar el marco teórico necesario para el caso.

Dando paso a la formulación matemática, proceso y metodología de investigación que se encuentra en el capítulo 3.

Finalmente, en el capítulo 4 esta detallado el caso de estudio y lo resultados obtenidos.

## 1. Nomenclatura.

ANN	Red Neuronal Artificial
Ap	Average pooling
CA	Celular Automata
CENTROSUR	Empresa Eléctrica Regional Centro Sur C. A
CNN	Red Neuronal Convolutacional
GDAL	Geospatial Data Abstraction Library
IA	Inteligencia Artificial
Lr	Learning Rate
MAE	Error absoluto medio
Mp	Max pooling
MSE	Error cuadrático medio
Pb	Nivel de selectividad
S/E	Subestación
VGG	Visual Geometric Group

## 2. Estado del arte.

La demanda eléctrica a nivel nacional y mundial está creciendo exponencialmente en los últimos tiempos a un ritmo constante.(Cabello et al., 2012). Y la disponibilidad de energía eléctrica es considerada como uno de los indicadores de desarrollo, además está vinculado al bienestar de la sociedad, puesto que ahora es un servicio básico para la sociedad. (Santiesteban Velázquez et al., 2014). Por lo que tener la oportunidad de pronosticar el consumo eléctrico a futuro es una prioridad para el buen funcionamiento del sistema eléctrico (Zavala et al., 2009).

El pronóstico de la demanda eléctrica es un paso fundamental dentro del proceso de planificación, la misma que trata de seguir con una expansión ordenada y eficaz de los equipos y recursos tanto de Trasmisión como de Distribución (Willis, 2004), esto con el objetivo de optimizar tiempo y recursos. Con ese objetivo presente se vienen desarrollando y aplicando varios métodos, ya sean matemáticos o computacionales desde los años cincuenta, buscando disminuir las métricas de error en las proyecciones realizadas (Willis & Northcote-Green, 1983). Varias veces se han comparado o fusionado varios métodos entre sí, llegando a una conclusión que para tener mejores resultados es necesario conocer cuáles son los recursos y requerimientos necesarios para la aplicación por parte de la empresa distribuidora del servicio eléctrico.(Mayorga Márquez, 2018).

(Ediger & Tatlidil, 2002) Explica que la predicción se la puede realizar para diferentes lapsos de tiempo según las necesidades de las empresas distribuidoras o según la problemática a analizar. Algunas técnicas de predicción utilizan varios parámetros para cumplir con su objetivo, como por ejemplo los cambios que se dan en el año al número de usuarios del servicio, el consumo promedio por usuario, el uso de la tierra, etc. (Arias Román, 2000).

(Dávila Arias, 2019) Manifiesta que el desconocimiento en la previsión de la demanda eléctrica espacialmente provoca inversiones en direcciones contrarias donde son realmente necesarias, por ejemplo, al no saber las empresas solo se basan en la factibilidad de construcción y muchas de las veces la carga está en otros sectores, para evitar estos inconvenientes se analiza la proyección a nivel de micro-áreas, consiguiendo determinar el real comportamiento de la demanda en forma espacial. Entonces la simulación o predicción del cambio de uso de la tierra permite a los planificadores proporcionar mejores resultados en cuanto a la inversión y servicios, mismos que son necesarios para sostener el desarrollo.(Hathout, 2002)

La ubicación de los consumidores se ve afectada o influenciada de varios factores y necesidades, o del ambiente que rodea a cada usuario, toda esta información se puede plantear o convertirla en patrones, mismos que pueden ser analizados y predichos con métodos de simulación.(Willis, 2002), por otra parte (Carreno et al., 2011) Manifiesta que existen algunos métodos que abordan la investigación espaciotemporal, pero la mayoría de ellos cuentan con un problema que se convierte en el mayor de los inconvenientes y es la necesidad de contar con una gran cantidad de datos para realizar

la predicción. Por lo que se plantearon crear un método que no requiera tanta información.

La integración del CA en los métodos de proyección puede brindar información valiosa sobre fenómenos de desarrollo urbano, adicionalmente los CA tienen un mejor rendimiento en la simulación de crecimiento poblacional, que las simulaciones tradicionales puesto que son mucho más sencillas que las ecuaciones matemáticas complejas y producen resultados más intuitivos y significativos. (Deadman et al., 1993).

(Li & Yeh, 2002) Expresa que las simulaciones del cambio en el uso de la tierra son fundamentales para varias aplicaciones como por ejemplo la gestión y planificación, pero también es de vital importancia para la investigación académica, ya que puede mostrar y establecer un patrón de cambio hacia el futuro.

La integración de redes neuronales artificiales con CA da un mejor enfoque para la simulación del cambio del uso de la tierra ya que las redes neuronales son eficaces para trabajar con datos incorrectos y deficientes, pero además capturan características complejas no lineales en el proceso del modelado.

(Vieira et al., 2020) explica que la influencia de los vecinos de cualquier zona influye directamente en la carga o consumo eléctrico de dicha locación puesto que la convolución en el dominio espacial tiene un funcionamiento como una conexión ponderada entre vecinos, adicionalmente su fácil estructura e implementación brindan buenos resultados, y no descarta que los resultados mejoren combinando métodos como por ejemplo Aprendizaje automático con el efecto que tiene la vecindad en incremento de la demanda eléctrica.

# CAPITULO 1

## DATOS GENERALES

### Objetivos

#### *Objetivo general*

Determinar la proyección espacial de la demanda eléctrica para un horizonte de mediano y largo plazo para la empresa Regional Centro Sur. C.A. Mediante un método de simulación del uso del suelo, para generar un proyecto de planificación de expansión, sólido y eficaz.

#### *Objetivos específicos*

- Realizar un procesamiento espacial de la información base sobre herramientas de un sistema de información geográfico.
- Identificar patrones de consumo espacio- temporales mediante la construcción de un modelo de mapa de preferencias por clase de consumidor.
- Desagregar la previsión de la demanda desde grandes áreas a micro áreas, mediante la construcción de un método de uso de suelo, considerando las preferencias de los consumidores y los efectos del vecindario y entorno.
- Proponer métricas para la cuantificación del patrón de error espacial.

### Alcance

La Empresa Eléctrica Regional Centro Sur C.A, ubicada con su matriz en la ciudad de Cuenca, es la encargada de brindar el servicio de distribución y comercialización de energía eléctrica, teniendo como área de servicio la mayoría de la superficie que cubre las provincias del Azuay, Cañar y Morona Santiago.

Para esta investigación se determinó conjuntamente con los docentes investigadores de la Centro Sur, que el área de estudio va a estar limitada en el 75% del área de concesión de la empresa de distribución, la cual se encuentra especificada en el capítulo 4.

En los años anteriores CENTROSUR conjuntamente con otros estudiantes desarrollaron una investigación similar, uno de los propósitos de realizar esta investigación es mejorar las métricas anteriores.

## **Justificación**

El pronóstico de la demanda eléctrica no solo se considera una herramienta sino se ha convertido en una necesidad fundamental para las empresas distribuidoras de energía eléctrica, esto con el fin de tomar mejores decisiones ya sean operativas o estratégicas, estas decisiones deben contar con la mayor fiabilidad y precisión ya que esto puede generar pérdidas económicas y de recursos. (Ariza Ramírez, Adriana Marcela, 2013)

La importancia del pronóstico de la demanda de energía eléctrica cada vez es mayor a medida que la tecnología va aumentando su alcance y cada vez dejando que se dependa menos del azar, disminuyendo considerablemente del fallo y la incertidumbre de errores al momento de tomar decisiones, esta es una de las razones principales para calcular y conocer cuánto va a ser el incremento de la demanda de energía eléctrica a mediano y largo plazo, pero no obstante ya no es suficiente conocer ese dato crucial sino ahora se trata de conocer los lugares donde se van a dar estos incrementos, tratando de que sea lo más cercano a la realidad.

Con la información obtenida por este estudio la empresa distribuidora Empresa Eléctrica Regional Centro Sur C.A puede tomar acciones que le beneficien en el ámbito financiero y de gestión de recursos tanto a mediano y largo plazo.

## CAPITULO 2

### 2. MARCO TEÓRICO

La proyección de la demanda eléctrica, tanto espacial o temporalmente nos permite observar el comportamiento de la demanda y su crecimiento, esto es de gran ayuda para las empresas distribuidoras del servicio eléctrico, puesto que si conocen cuanto y donde se va a dar el crecimiento se puede optimizar la inversión de recursos económicos y de tiempo.

Para satisfacer una proyección existen varios métodos que con el paso del tiempo se han ido combinando con la tecnología, esto con el fin de realizar una mejor estimación e ir reduciendo los márgenes de error.

Cada método de proyección cuenta con sus fortalezas y debilidades, pero todos buscan un mismo objetivo que es brindar confiabilidad al momento de realizar la proyección, para brindar esa seguridad cada método trata de reducir el error y disminuir el grado de incertidumbre que se genera en todas las proyecciones.

#### **Demanda y sus unidades de medida**

La demanda es la cantidad de potencia eléctrica promedio que se entrega a los consumidores en un lapso de tiempo, este lapso de tiempo es conocido como intervalo de demanda. La demanda puede expresarse en diversas formas de medida como por ejemplo KW, KVA, KVAR, etc. (Ariza Ramírez, 2013)

#### **Demanda o carga máxima**

Es el valor mayor de la potencia consumida en un sistema o circuito, en un lapso de tiempo ya establecido. Este valor es de crucial importancia ya que aquí se puede observar la máxima caída de tensión en el circuito, lo que representa mayores pérdidas de potencia y energía. (Ramirez Castaño, 2004)

#### **Carga instalada**

Es el resultado de la suma de potencias nominales de los servicios conectados a un circuito o sistema y esto se expresa en kVA, MVA, kW, MW. (Ramirez Castaño, 2004)

### **Causas del crecimiento de la demanda.**

El crecimiento o decrecimiento de la demanda de energía eléctrica en un sistema de distribución se da únicamente por dos razones o la combinación de las mismas. (Willis & Northcote-Green, 1983)

1. Aumento del número de clientes. Cuando nuevos usuarios adquieren el servicio eléctrico en una zona en específico.
2. Nuevos usos de la energía eléctrica. Cuando los clientes ya existentes de una zona en específico adquieren o remplazan electrodomésticos o herramientas que requieran más energía eléctrica. (Willis, 2002)

### **Curva de demanda**

La curva es la representación gráfica de la variación de la demanda eléctrica a través de un periodo de tiempo, las variaciones se dan por diferentes factores como el clima, factores sociales y económicos. (Simbaña Guamanzara, 2015). La curva de demanda eléctrica se la construye para cada tipo de consumidor.

### **Factores que intervienen en el pronóstico de la demanda**

Se consideran aquellos factores que de manera directa afectan a la demanda eléctrica, esto puede ser de forma ascendente o descendente, estos factores están relacionados principalmente a variables exteriores, los más importantes que se pueden destacar son:

#### **➤ Factores geográficos:**

Según la zona o región de vivienda de los usuarios existen costumbres o necesidades diferentes que influyen en el consumo de energía eléctrica, por ejemplo, una de las variables que más afectan son la temperatura puesto que en las regiones costa, oriental e insular, la temperatura ambiente es mayor por lo que es necesario contar con ventiladores o aires acondicionados, para cierta época del año (Berrezueta Suárez & Encalada Serrano, 2014)

#### **➤ Cantidad de clientes**

El consumo de energía eléctrica está directamente relacionado con la cantidad de usuarios que dependen de la empresa distribuidora, por lo tanto, se puede decir que el

desarrollo poblacional influye de manera directa en el aumento de nuevos usuarios para la empresa y por ende la expansión de las redes.

➤ **Hábitos de consumo**

Este factor nos indica las costumbres y la forma en que los usuarios hacen uso de la energía eléctrica en su día a día, anteriormente la iluminación era la variable que mayormente representaba como consumo, sin embargo, al día de hoy con la introducción de nuevas tecnologías y nuevos electrodomésticos, ese rubro ha disminuido notoriamente. (Berrezueta Suárez & Encalada Serrano, 2014)

➤ **Clases de uso del suelo**

Hace referencia a las diferentes categorías de los usuarios de la empresa distribuidora, la cual clasifica según su consumo por ejemplo tenemos (residencial, comercial, industrial, etc.), tomando en cuenta la zonificación establecida en los planes de desarrollo territorial por parte de cada ciudad o cantón. (*Predicción Espacial de La Demanda Eléctrica en La Ciudad de Maracaibo. | PDF | Predicción | Planificación*, s. f.)

**Proyección espacial de la demanda eléctrica**

El modelo de la proyección espacial de la demanda eléctrica es un modelo de simulación que trabaja simultáneamente con las proyecciones espacial y temporal. En las proyecciones espaciales, se combina el interés de un cliente para encontrar un espacio disponible que cumpla con las expectativas del uso del suelo, estableciendo un mapa de preferencias por otra parte el análisis temporal ejecuta un análisis en base a las curvas de la demanda eléctrica y consumo por cada grupo consumidor. Combinando los dos análisis se logra la proyección en espacio y tiempo. (Monteiro, 2003)

En la Fig. [1] se puede apreciar la estructura del modelo de proyección espacial, teniendo en cuenta el área global donde se analiza la cobertura general de un área a estudiar, dando paso seguido a las áreas grandes, donde se analiza las iteraciones en áreas subdivididas, y por ultimo las áreas pequeñas, esto se logra dividiendo el área global en áreas más pequeñas para poder realizar las predicciones




Figura 1 Estructura de un modelo de proyección espacial

Nota: Fuente, elaboración del autor

### Área global

El estudio del área global contempla el estudio de las series de tiempo en un lapso de tiempo de energía y de consumidores, en esta área esta categorizado por tipos de consumidores. (Zambrano et al., 2018)

### Áreas pequeñas

Esta es la técnica más común para el análisis espacial, la técnica consiste en dividir toda el área global en áreas más pequeñas, es importante destacar que el área del pronóstico tiene que estar asociada a la ubicación geográfica.

El modelo requiere de algunos requisitos para realizar la previsión de la demanda eléctrica y según (Morales et al., 2017), son los siguientes:

- **Previsión de magnitud.** Es la potencia máxima de cada área.
- **Resolución y análisis espacial.** Hace referencia a la ubicación de los consumidores.
- **Evaluación temporal.** Se debe definir el tiempo y las estaciones
- **Estandarización de tiempo.** Se debe normalizar la previsión de la demanda eléctrica por clima.

- **Análisis de precisión.** Es importante contar con un análisis que evalué las proyecciones
- **Clasificación de los consumidores.** Es necesario clasificar los consumidores por el tipo de uso de la energía.

### Clasificación de los métodos de proyección

Actualmente existen varios métodos que se pueden utilizar para la proyección de la demanda eléctrica, como podemos observar en la Fig. [2]




Figura 2 Métodos para la proyección de la demanda eléctrica.

Nota: Fuente, elaboración del autor

Esta investigación se centra en la proyección mediante el uso de la inteligencia artificial para lo cual se toma en cuenta las redes neuronales artificiales (ANN) y las redes neuronales convolucionales (CNN).

### Inteligencia Artificial (IA)

La IA es considerada como un conjunto de algoritmos matemáticos que tienen el fin de simular la inteligencia humana, actualmente la IA cuenta con varios subcampos, al día de hoy ha tenido un gran avance tecnológico, y día a día seguirá sorprendiéndonos

ya que es capaz de ofrecernos sugerencias y predicciones relacionadas a cualquier ámbito.

(Russell & Norvig, 2011) Consideran que la IA está enfocada en 4 enfoques principales, los cuales son:

1. Sistemas que piensan como humanos: Tratan de hacer que las computadoras u maquinas piensen, otorgar mentes a los diversos tipos de máquinas.(Haugeland, 1989)
2. Sistemas que pienses racionalmente. - (Winston, 1992) Manifiestan que es necesario estudiar los cálculos que hacen posible percibir, razonar y actuar como seres humanos.
3. Sistemas que actúen como humanos. - (Rich & Knight, 1991) Explican que la IA logre realizar tareas cotidianas que actualmente el ser humano las realiza mejor.
4. Sistemas que actúen racionalmente. – (Nilsson, 1998) Expresa que esta área está relacionada con las conductas inteligentes en artefactos o máquinas.

Dentro de esos 4 enfoques esta cimentado la objetividad de la IA, y cada uno de ellos cuenta con numerosos subcampos en los que se puede adentrar para comprender el proceso que tiene una IA, o lo que hay atrás de cada comportamiento en sí.

Actualmente hay una gran variedad de IA que facilitan la vida cotidiana para miles de personas, esto en diferentes campos ya sea en la manufacturación, investigación, redacción, edición, etc.

### **Red Neuronal Artificial (ANN)**

Una red neuronal artificial es un algoritmo inspirado en el sistema nervioso de los seres humanos, la cualidad que resalta de las ANN es la capacidad de aprender patrones a través de un entrenamiento y validación de datos.

El elemento principal de una ANN es la “neurona” o también llamada “nodo”, cuya representación del esquema matemático se puede observar en la Fig. [3]

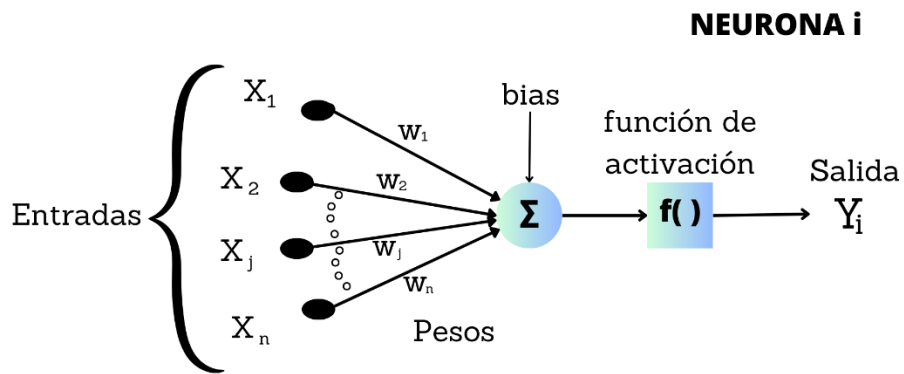


Figura 3 Modelo general de una neurona artificial

Nota: Fuente, elaboración del autor

Cada neurona está organizada con otras formando grupos que se les conoce como capas, interconectando cada neurona con la siguiente con un peso asociado, pudiendo o no interactuar con las neuronas de la misma capa. En la Fig. [4] se observa cómo está conectado un esquema general de las ANN

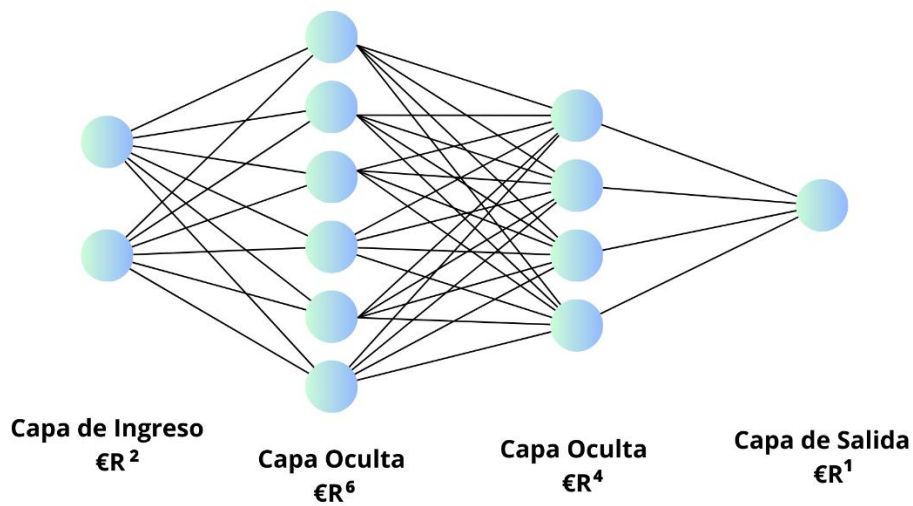


Figura 4 Esquema de una ANN

Nota: Fuente, elaboración del autor

## **Red Neuronal Convolutacional (CNN)**

Las redes neuronales convolucionales es un tipo de ANN pero la diferencia se basa en que las CNN cuentan con varias capas anteriores especializadas, por lo tanto son capaces de reconocer patrones o formas básicas y posteriormente en las capas más profundas son capaces de reconocer formas más complejas como un rostro humano o diferentes siluetas.(Artola Moreno, 2019)

Todas las imágenes están compuestas de información numérica, por lo que se puede definir como una matriz numérica, cada pixel tiene un rango de 0 a 255 dependiendo del número es el color que obtiene cada imagen, para todo proyecto de CNN se normalizan los valores estableciendo en un rango de 0 a 1.

Las CNNs son consideradas como las técnicas dominantes del Deep learning,(LeCun et al., 2015) no obstante, el rendimiento que tiene la CNNs se ve influenciado por la arquitectura que tenga la misma. Hoy en día existen varias arquitecturas desarrolladas por expertos en ML y grandes compañías como Google, Microsoft Research y grandes investigadores a nivel mundial, por lo tanto, estas arquitecturas requieren un gran poder computacional para lograr el rendimiento deseado, pero eso no implica que las arquitecturas se puedan modificar para cada problema específico y dependiendo de la máquina que se disponga.

En la Fig. [5] podemos observar algunas de las arquitecturas más conocidas que han participado en la competición anual de ImageNet Large Scale Visual Recognition Challenge (ILSVRC), esta competencia desarrollada por el equipo de ImageNet era la encargada de premiar a los mejores equipos de investigación con sus algoritmos de reconocimiento visual.

AlexNet	VGG Net	GoogleNet	ResNet
8 Capas	19 - 21 Capas	22 Capas	152 Capas
15.3% Error	7.3% Error	6.67% Error	3.57% Error
1er Lugar en competencia ILSVRC	2do Lugar en competencia ILSVRC	1er Lugar en competencia ILSVRC	1er Lugar en competencia ILSVRC
2012	2014	2014	2015

Figura 5 Ejemplo de las arquitecturas CNN más conocidas

Nota: Fuente, elaboración del autor

### Arquitectura VGG 16

(Simonyan & Zisserman, 2014) fueron los encargados de desarrollar la red neuronal convolucional, que tiene su nombre por las siglas en ingles Oxford Visual Geometry Group (VGG). Esta arquitectura es una de las más utilizadas para la clasificación de imágenes, esta red cuenta con 16 capas que están distribuidas de la siguiente manera, 13 filtros y 3 capas densas completamente conectadas, en la Fig. [6] se puede observar la arquitectura de la red.

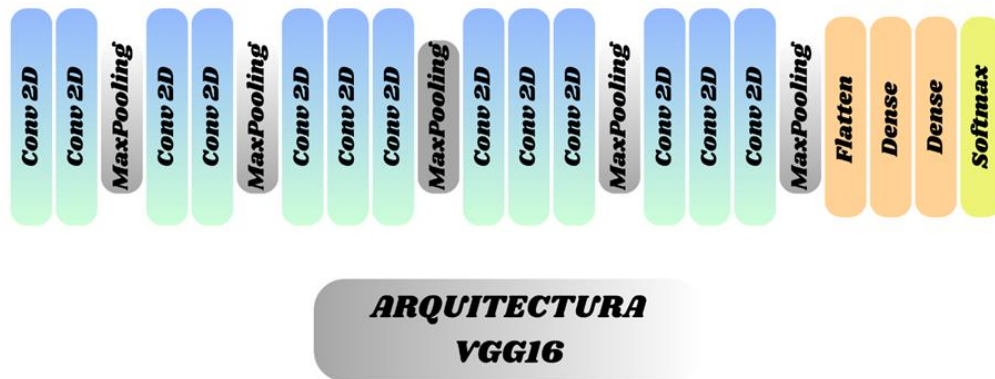


Figura 6 Arquitectura VGG-16

Nota: Fuente, elaboración del autor

Dependiendo de los objetivos de cada proyecto o investigación se toma en cuenta una arquitectura o se diseña una, tomando en cuenta el caso de estudio se plantea utilizar como referencia la arquitectura VGG16, y adaptarla a nuestra necesidad.

### Capa convolucional

Las capas convolucionales son las encargadas de realizar las operaciones de convolución de una imagen o matriz de datos, mediante filtros que son los encargados de crear mapas de nuevas características, esto es posible ya que el filtro empieza desde la parte superior izquierda y va recorriendo todo el ancho de la imagen, una vez que el filtro llega al borde lateral el filtro continúa bajando y va repitiendo el proceso durante todo lo ancho y largo de la imagen.

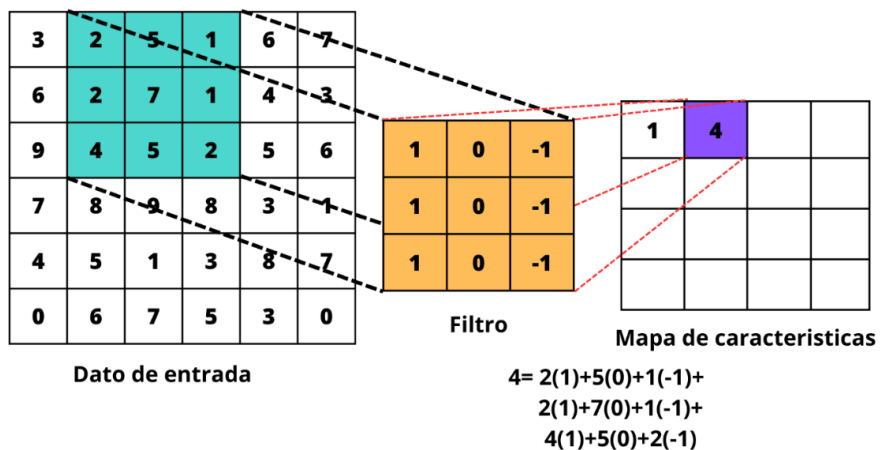


Figura 7 Capa de convolución

Nota: Fuente, elaboración del autor

La operación matemática que se realiza en la capa convolucional está definida en la sección 3.1. Generalmente las CNNs utilizan una función de activación no lineal, la misma que se encuentra después de cada capa convolucional.

### Capa de agrupación

Seguidamente de las capas de convolución generalmente se puede encontrar con las capas de agrupación, las cuales son encargadas de reducir el tamaño de las imágenes, conservando la información principal, que se obtuvo anteriormente mediante los filtros, comúnmente en estas capas se utilizan dos funciones como son (Max-Pooling y Average Pooling).




Figura 8 Capa de agrupación

Nota: Fuente, elaboración del autor

Como se aprecia en la Fig. [8] en el caso de ser max pooling (Mp) la matriz resultante de la salida de los filtros se divide en segmentos específicos y se selecciona el valor más alto de dicha sección. Por otra parte, para el caso de average pooling (Ap), funciona de manera similar al anterior pero como salida, este devuelve el valor promedio de la sección especificada.

### **Función de activación**

(Artola Moreno, 2019) Explica que existen varias funciones de activación que define la salida de la neurona, en la mayoría de los modelos generalmente es creciente y continua, obteniendo la forma  $y = f(x)$ . En la tabla 1 se puede apreciar algunas de las funciones más utilizadas donde  $x$  representa el potencial postsináptico, por otra parte,  $y$  es el estado de activación.

*Tabla 1 Funciones de activación más utilizadas*

	Función	Rango
Identidad	$y = x$	$[-\infty, +\infty]$
Escalón	$y = \text{sign}(x)$	$\{-1, +1\}$
	$y = H(x)$	$\{0, +1\}$
Lineal o tramos	$y = \begin{cases} -1, & \text{si } x < -1 \\ x, & \text{si } -1 \leq x \leq +1 \\ +1, & \text{si } x > +1 \end{cases}$	$[-1, +1]$
Sigmoidea	$y = \frac{1}{1 + e^x}$	$[0, +1]$
		$[-1, +1]$
Gaussiana	$y = Ae^{Bx^2}$	$[0, +1]$
ReLu	$f(x) = \max(0, x)$ $= \begin{cases} 0 & \text{para } x < 0 \\ x & \text{para } x \geq 0 \end{cases}$	$[0, +\infty]$

*Nota: Fuente, elaboración del autor*

### **Celular automático (CA).**

Los autómatas celulares (CA) tienen sus inicios por los años de 1940 de la mano de Jhon Von Neumann, y se puede decir que es un modelo matemático y computacional, mayormente es utilizado en modelar procesos o sistemas dinámicos en el tiempo.

(Monteiro, 2003) indica que el modelo está formado por cuatro componentes principales que son celdas, estados, vecindarios y reglas de transición.

El CA está compuesto por un conjunto de celdas o células que van cambiando en el tiempo  $t$ , estas se encuentran en función del estado anterior  $t-1$  y están relacionadas directamente con el estado del vecindario y a reglas locales, en un momento específico del tiempo  $t$ .

Existen algunos elementos básicos de un CA descritos a continuación según (David Alejandro Reyes Gómez, 2011):

- Espacio. - Hace referencia a cualquier dimensión ya sea un arreglo de 1D o un espacio de  $n$ - Dimensiones.
- Conjunto de estados. – Cada elemento toma un valor de este conjunto que es finito, este puede estar representado por colores o valores.
- Configuración inicial. – Es la asignación que tiene cada elemento al iniciar el proceso
- Vecindario. – Define el entorno que rodea a cada elemento,
- Funciones de transiciones. – Es una regla de evolución que determina el el comportamiento del modelo CA

Uno de los términos que más influye en los resultados al momento de asignar los valores a las celdas escogidas es el vecindario.

## CAPITULO 3

### 3. METODOLOGIA

La investigación para este trabajo de titulación se centra en una simulación espacio temporal, para el cual se plantea el siguiente modelo de ejecución, especificado en la sección 3.2. Aplicando esta metodología nos permite asignar los clientes nuevos o previstos en un mapa de densidad para cada tipo de consumidor (residencial, comercial, industrial, otros).

#### 3.1. Formulación matemática

##### Red Neuronal Artificial

La expresión matemática que calcula la función de salida está dada por la siguiente ecuación.

**Ecuación 1:** Ecuación de la función de salida de la una red neuronal artificial

$$y_i = f\left(\sum_{j=1}^n w_{ij}x_j - \theta_i\right) \quad (1)$$

Donde:

- $F()$  es la función de activación
- $w_{ij}$  determinan las señales de ingreso de  $n$  neuronas
- $x_j$  equivale al peso asociado de cada uno de las conexiones entre dos neuronas
- $\theta_j$  es igual al umbral de activación de la neurona
- $y_i$  representa la salida de la red neuronal

##### Capa convolucional

La operación relacionada en esta capa podemos apreciar en la Ecuación 2

**Ecuación 2:** Ecuación de la capa convolucional de una CNN

$$C = g [ W * X + b ] \quad (2)$$

Donde:

$W$  = peso o tamaño del kernel

$X$  = matriz de ingreso

$b$  = bias

$*$  = Operación de convolución

g = función de activación

### Capa de agrupación

La formulación matemática atrás de esta operación dependiendo de la opción que escojamos podemos ver a continuación en las ecuaciones Ecuación 3 y Ecuación 4, primeramente, veremos la más utilizada que es Max-pooling:

**Ecuación 3:** Ecuación de la función max-pooling de la capa de agrupación

$$P_{max} = \max(C_{i,j}) \quad (3)$$

Donde:

$C_{i,j}$  = ventana de dos dimensiones donde C es igual a la salida4

Average – pooling para este tipo de agrupación el resultado se obtiene mediante la siguiente operación detallada en la Ecuación 4:

**Ecuación 4:** Ecuación de la función average pooling de la capa de agrupación

$$P_{average} = \frac{1}{P_0} \sum (C_{i,j}) \quad (4)$$

Donde:

$P_0$  = tamaño de la ventana de agrupación.

### Celular automática:

**Ecuación 5:** Ecuación general de celular automática

$$CA_k^t = \{e_k^t\} \quad (5)$$

Donde:

$e_k^t$  es el posible resultado que puede tomar la cuadrícula k en un determinado tiempo t, este resultado puede ser 0 o 1, indicando si existió o no un desarrollo dependiendo que valor asigne, 0 = no hay desarrollo, 1 = existe desarrollo.

$P_k^{t+1}$  representa el desarrollo potencial de la celda k, la misma que está considerada en función de su valor propio más el valor añadido por el efecto del vecindario y un valor asignado al azar, descrito en la Ecuación 6. El nivel de selectividad  $P_b$  es asignado por el desarrollador y se encarga de definir los cambios que pueden darse al iterarse el modelo.

**Ecuación 6:** Ecuación para el desarrollo potencial de una celda

$$P_k^{t+1} = \alpha * A_{kt} + \beta * \sum_{j \in Z_l} A_{kt} + \lambda * \varepsilon_{kt}$$

$$P_k > P_b \tag{6}$$

La ecuación contiene 3 componentes que son:

- a) Parámetro de realimentación positiva  $\alpha$ , este relaciona la preferencia previa t-1 con el desarrollo, el rango de valores está en [0.3 - 1]
- b) Parámetro de vecindad  $\beta$ , está relacionado con el efecto de las celdas aledañas a la celda k, este parámetro está dentro del rango de valores [0 – 0.5]
- c) Parámetro de innovación  $\lambda$ , es considerado como un ruido aleatorio que define la desviación aleatoria a partir del comportamiento normal, los valores pueden ser [0 – 0.2]

### Probabilidad de crecimiento

El CA tiene varias adaptaciones, dependiendo al caso de estudio y a los objetivos planteados, para el caso de investigación se plantea que la probabilidad del crecimiento espacialmente se calcula con la siguiente Ecuación. 7.

**Ecuación 7:** Ecuación de probabilidad de desarrollo espacial

$$P_k^{t+1} = P_{S_k^{c,t}} * P_{\Omega_k^{c,t}} * P_{X_k} * P_{\epsilon_k} \tag{7}$$

Donde:

$P_k^{t+1}$  = Probabilidad de crecimiento

$P_{S_k^{c,t}}$  = Mapa de probabilidades (salida de la CNN).

$P_{\Omega_k^{c,t}}$  = Efecto vecindario

$P_{X_k}$  = Restricciones

$P_{\epsilon_k}$  = Valor estocástico.

## Efecto Vecindario

### Vecindad de Neumann:

**Ecuación 8** Ecuación del efecto vecindario para la vecindad de Neumann

$$\Omega_{t,i} = (1 - \lambda) * \Omega_{t-1} + \lambda * \left( \sum (Pg_{t-1} * W_{i,j}) \right) \quad (8)$$

Donde:

$\Omega_{t,i}$  = Efecto vecindad en la celda i en un tiempo t

$\lambda$  = Es el factor de suavizado que controla la influencia del efecto vecindad en el momento anterior.

$\Omega_{t-1}$  = Es el efecto vecindad en la celda i en el tiempo anterior.

$Pg_{t-1}$  = Es la idoneidad de desarrollo general de la celda j para el uso de suelo k en el momento anterior.

$W_{i,j}$  = Peso de conexión entre celda i y celda j

### Vecindad de Moore:

**Ecuación 9:** Ecuación del efecto vecindario para la vecindad de Moore

$$\Omega_{i,m} = \frac{\sum m * m(S_{i,t=k})}{m * m - 1} \quad (9)$$

Donde:

$\Omega_{i,m}$  = Efecto vecindad en la celda i en un vecindario m

$m * m$  = Tamaño de la vecindad

### Valor Estocástico.

**Ecuación 10:** Ecuación para calcular el valor estocástico

$$P\epsilon_k = 1 + (-\ln\gamma)^\alpha \quad (10)$$

Donde:

$P\epsilon_k$  = Valor estocástico.

$\gamma$  = numero aleatorio en un rango de 0 a 1

$\alpha$  = parámetro que controla el disturbio estocástico con un valor constante entre 1-10

### **Funciones de costo o error:**

Nos permite cuantificar el error entre la predicción hecha por el modelo y salida esperada que está prevista durante el entrenamiento y aprendizaje, las funciones de perdida varían de acuerdo a las necesidades de cada problema en específico a continuación se detalla la formulación matemática aplicada para este tema de regresión.

Las perdidas más utilizadas en problemas de regresión es el MSE el cual calcula el promedio de la diferencia elevado al cuadrado entre los valores reales y los valores predichos por la red.

**Ecuación 11:** Ecuación para calcular las perdidas MSE

$$E = \frac{\sum_{l=1}^n (\hat{Y}_l - Y_l)^2}{2n} \quad (11)$$

Donde:

E = la perdida MSE que calcula la diferencia de los cuadrados

Yl = Vector de elementos l

Yi = Vector de elementos con el valor objetivo

N = número de elementos

### **Matriz de Confusión**

Una matriz de confusión en el campo de la IA es una herramienta muy útil para evaluar los modelos construidos, está establecido por:

**Ecuación 12:** Ecuación de matriz de confusión

$$M = \begin{bmatrix} TP & FP \\ FN & TN \end{bmatrix} \quad (12)$$

Donde:

M = Matriz de confusión

TP = Verdaderos positivos es el número de muestras predichas correctamente como positivos.

FP = Falsos positivos, es el número de muestras predichas erróneamente como positivos.

TN = Verdaderos negativos es el número de muestras predichas correctamente como negativos.

FN = Falsos negativos es el número de muestras predichas erróneamente como negativas.

### **F1 Score**

Utilizando la matriz de confusión se establecen algunas métricas importantes en el ML, la métrica F1 este definido como una función de precisión y recuperación, matemáticamente está establecido como:

**Ecuación 13:** Ecuación para calcular F1-Score

$$F1\ Score = \frac{TP}{TP + \frac{1}{2}(FP + FN)} \quad (13)$$

### **Precisión**

La precisión en el ML es el porcentaje de predicciones correctas que logra un modelo entrenado. Matemáticamente se calcula de la siguiente manera

**Ecuación 14:** Ecuación para calcular la precisión de un modelo de ML

$$Presicion = \frac{TP}{TP + FP} \quad (14)$$

## **3.2. Flujograma**

En la Fig. [9] Se puede observar todo el proceso a seguir para la asignación de clientes en cada subestación, ya que esta información es necesaria para la proyección espacial de la demanda eléctrica, misma que esta especificada en la etapa 3 de la siguiente sección

Este proceso de asignación de clientes se lo realiza en 3 etapas detalladas en la sección 3.3, cada una de estas etapas consta de varios análisis o subprocesos, mismos que se encuentran detallados en dicha sección.




Figura 9 Flujograma de la metodología para la investigación

Nota: Fuente, elaboración del autor

. Una vez realizado este proceso, se da paso a la proyección de la demanda eléctrica según la cantidad de clientes y según el grupo consumidor de cada subestación, obteniendo así una proyección en espacio y tiempo.

### 3.3. Método de Solución

#### Etapa 1

Como se puede apreciar en la Fig. [10] la primera etapa consiste en preparar la base de datos con los factores teniendo en cuenta que se tiene información desde el año 2013 hasta el año 2022.

Una vez que los datos están almacenados y preparados se procede a geo procesarlos, y seguidamente se construye una CNN que sea capaz de predecir un mapa de probabilidades, dando fin a la etapa 1.



Figura 10 Primera etapa del proceso

Nota: Fuente, elaboración del autor

El mapa del año base está definido como el último año de registro que se tenga, en este caso es el 2022, se toma en cuenta este año ya que para calibrar la CNN y realizar predicciones es necesario contar con información real y que sirva para validar datos, como no se sabe que va a pasar a futuro y no contamos con esos datos lo que se realiza es una regresión en el tiempo para analizar los datos de los años anteriores y tener todos la información necesaria para que la CNN aprenda y podamos realizar predicciones a futuro.

### Creación del mapa del año base

Dentro de la creación del mapa de año base, incluye también la creación de los mapas históricos ya que son datos imprescindibles para el desarrollo de esta investigación, la creación de mapas históricos de los consumidores anuales de energía eléctrica, se lo realiza con la ayuda del software ArcMap. Estos mapas se subclasifican por tipo de consumidor.

### Factores Espaciales

Los factores espaciales son esenciales para la proyección, estos pueden variar en diferentes casos de proyección, para este caso de estudio los factores a utilizar se detallan en la tabla [2].

Como primer paso se conforma una base de datos de todos los factores espaciales a través del tiempo, paso seguido se realiza un procesamiento de los factores para lo cual se toma en cuenta las 3 categorías (proximidad, locales, entorno).

*Tabla 2 Factores espaciales*

<b>Factores Espaciales</b>			
<b>Índice</b>	<b>Factores</b>	<b>Descripción</b>	<b>Grupo</b>
1	Avenidas	Distancia entre clientes y calles urbanas o avenidas	Proximidad
2	Centros Comerciales	Distancia entre clientes e infraestructuras comerciales más cercanas	Proximidad
3	Espacios Culturales	Distancia entre cliente y museos, casas comunales, etc.	Proximidad
4	Centros Educativos	Distancia entre cliente y centros educativos	Proximidad
5	Lugares Recreativos	Distancia entre clientes y espacios verdes	Proximidad
6	Servicios de Salud	Distancia entre clientes con respecto a hospitales, centros de salud	Proximidad
7	Servicios de Seguridad	Distancia entre clientes y los UPC	Proximidad
8	Industrias	Distancia entre clientes y las industrias	Proximidad
9	Pendiente de Suelo	Corresponde a la pendiente presente en el terreno	Locales
10	Consumidores	Define la cantidad de clientes por unidad de área	Entorno
11	Centro de Ciudad	Distancia desde el centro de la ciudad hacia los alrededores	Proximidad

*Nota: Fuente, elaboración del autor*

### **Factores de proximidad**

Este tipo de factores indican la distancia que existe entre los clientes y los diferentes puntos de interés, por ejemplo, vías de acceso, parques públicos, escuelas, hospitales, etc.

## **Factores locales**

Estos factores brindan información tipo topográfica

## **Factores de entorno**

Estos factores indican el entorno de la vecindad de la cuadrícula a analizar, con lo cual se puede determinar una densidad en cierta área de estudio

Cada tipo de cliente tiene diferente probabilidad de desarrollo según los factores que influyan en su entorno, por ejemplo, para un cliente comercial, tiene mayor probabilidad de desarrollo en un entorno de varios clientes residenciales, por otra parte, un cliente residencial tiene mayor probabilidad cerca de centros educativos, parques, vías de acceso, etc.

## **Proceso para el análisis de factores**

En el desarrollo de este proceso se utiliza la librería GDAL, misma que es especialista en análisis de datos geoespaciales, el diagrama de flujo de la Fig. [11] indica el procesamiento que se siguió para el análisis de los factores.




Figura 11 Diagrama de flujo del geo procesamiento de los factores

Nota: Fuente, elaboración del autor

## Metodología para redes neuronales

Para el desarrollo de la red se usó el software Python con la librería, Pytorch, la mismas que son utilizadas para creación de algoritmos de ML y DL, en la Fig. [12] se puede observar el diagrama de flujo del funcionamiento de la red.

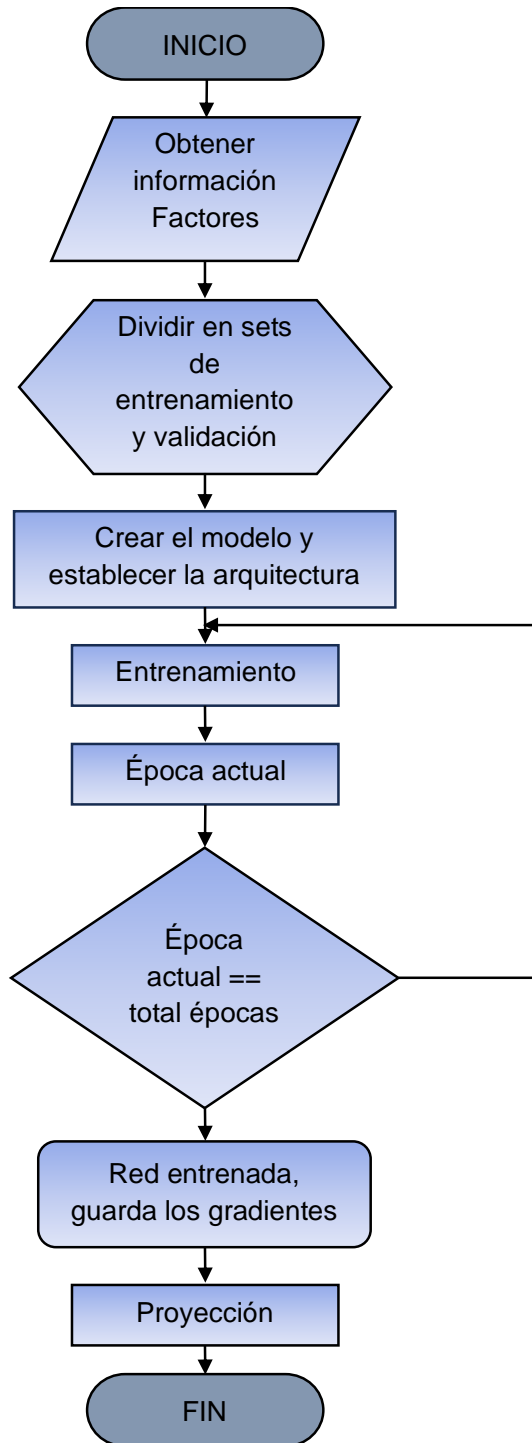


Figura 12 Diagrama de flujo de la CNN

Nota: Fuente, elaboración del autor

## Etapa 2

Una vez terminada la primera etapa, continuamos con el proceso detallado en la Fig. [13]. El CA necesita de 4 parámetros para asignar los clientes en el área de estudio en esta etapa se definen los 3 últimos.

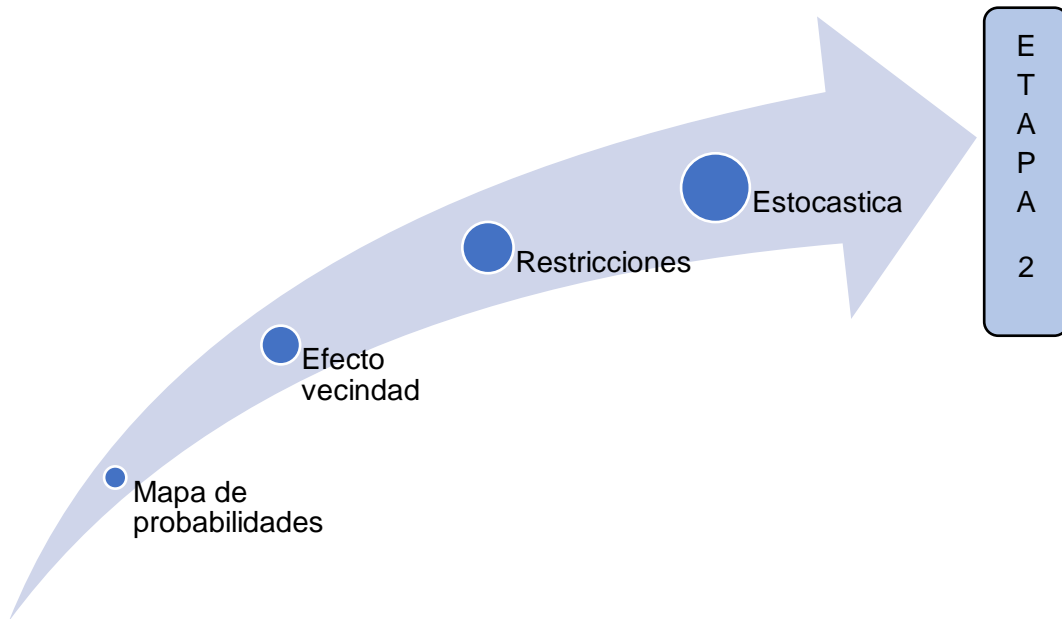


Figura 13 Segunda etapa del proceso

Nota: Fuente, elaboración del autor

### Efecto vecindad

En cuanto a el efecto de la vecindad existe una amplia variedad de posibilidades y métodos a analizar, creando combinaciones interesantes y novedosas para el desarrollo espacial, en la Fig. [14] se puede observar los dos tipos de vecindad más utilizados comúnmente, en el grafico se muestran las celdas de color blanco que representan la vecindad de la celda a analizar que es la celda de color gris, como podemos ver en el literal (a) tenemos 8 celdas que van a influenciar en la toma de decisión si se asigna o no un valor a la celda central, este tipo de vecindario es conocido como vecindad de Moore, debido al pionero Edward F. Moore, este tipo de vecindad es el más utilizado en casos de CA, por otra parte en el literal (b) podemos apreciar un tipo de vecindad llamado Von Neumann debido a su autor Jhon Von Neumann matemático importante que influyo directamente en la investigaciones de CA, en este tipo de vecindario está basado en los puntos cardinales.




Figura 14 Efecto Vecindad. a) Vecindario tipo Moore. b) Vecindario tipo Von Neumann

Nota: Fuente, elaboración del autor

Para esta investigación se estableció analizar y comparar resultados en esta parte con dos funciones, de los dos tipos de vecindario descritos anteriormente

### Restricciones

Para el caso de las restricciones se toman en cuenta en el mapa de probabilidades como una máscara, en el cual esta detallado como 0 cada cuadrícula con restricción, las áreas consideradas como restricción son las siguientes.

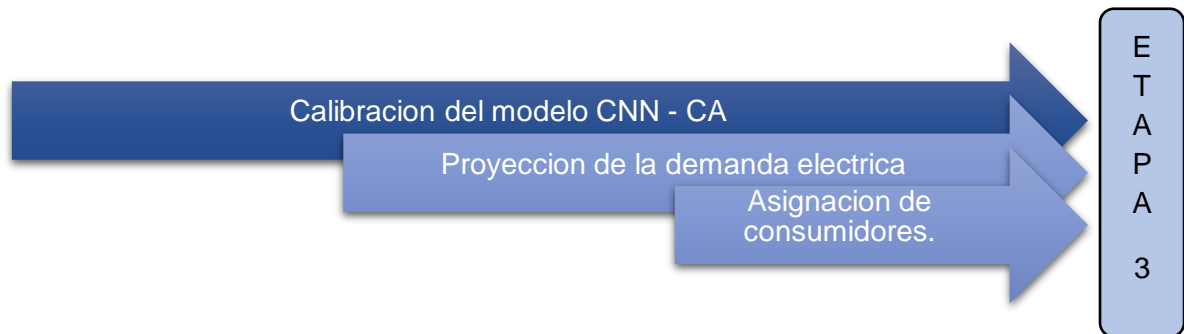
- Aeropuertos
- Áreas recreativas
- Áreas de mayor pendiente
- Cursos de agua
- Miradores turísticos naturales
- Parques
- Zonas militares.

### Termino Estocástico:

Comúnmente en los problemas asociados al desarrollo urbano con CA, es necesario contar con un término estocástico que brinde aleatoriedad en el proceso de evolución de una celda a otra. (White & Engelen, 1993) explica que está definido matemáticamente en la Eq.10 y la distribución de esos valores está muy cercano a la unidad.

### **Etapa 3**

Finalmente, como última parte del proceso se siguen los siguientes pasos detallados en la Fig. [15]



*Figura 15 Tercera y última etapa*

*Nota: Fuente, elaboración del autor*

#### **Calibración del modelo de simulación CNN - CA**

En este apartado se prepara el modelo de simulación en cuanto a la asignación de los clientes para encontrar la proyección espacial para cada sub estación, esto se realiza comparando varias métricas y analizando los mejores resultados, para calibrar el modelo se utiliza la información base que se viene tomando en los pasos anteriores.

#### **Proyección de la demanda eléctrica.**

Toda empresa eléctrica ya sean de distribución, transmisión o generación, cuentan con un método de proyección de demanda eléctrica, para el caso CENTROSUR utiliza un análisis de tendencia para la asignación de carga en grandes áreas, en este caso para cada subestación, la técnica utilizada es la de triple suavizado exponencial o también conocido como el método de Holt-Winters.

Esta técnica utiliza series de tiempo para poder predecir valores futuros en función de patrones históricos. CENTROSUR realiza proyecciones de la carga eléctrica año a año. Para esta investigación se adopta los datos entregados por CENTROSUR.

## CAPITULO 4

### 4. CASO DE ESTUDIO

Para este estudio de investigación se estableció realizar la predicción en una parte de la concesión que tiene la Empresa Eléctrica Regional Centro Sur C.A, la misma que está ubicada en la ciudad de Cuenca, el área para este estudio es de 621.818047 Km<sup>2</sup> y contempla un 75% de cobertura de la totalidad de la empresa distribuidora. A continuación, en la Fig. [16] se encuentra delimitado el área de estudio para esta investigación.




Figura 16 Área de estudio

Nota: Fuente, elaboración del autor

En esta zona se tiene un total de 8 subestaciones que cubren con la demanda total consumida, en la fig. [17] se puede apreciar el área de trabajo de cada S/E, para esta área de estudio en el año base 2022 la empresa cuenta con 227637 clientes, en la tabla [3] se puede observar el número correspondiente de cada clase de consumidor en cada subestación.

Tabla 3 Número de clientes según su tipo de consumidor en cada S/E del año base

Subestación	Residencial	Comercial	Industrial	Otros	Total
1	8448	4116	171	127	<b>12862</b>
2	5975	4097	74	251	<b>10397</b>
3	37935	3825	587	519	<b>42866</b>
4	31433	2223	897	324	<b>34877</b>
5	65644	5072	939	917	<b>72572</b>
7	21710	958	305	309	<b>23282</b>
8	23304	1927	368	380	<b>25979</b>
12	4443	213	38	108	<b>4802</b>
<b>Total</b>	<b>198892</b>	<b>22431</b>	<b>3379</b>	<b>2935</b>	<b>227637</b>

Nota: Fuente, elaboración del autor




Figura 17 Área de concesión de las subestaciones

Nota: Fuente, elaboración del autor

### Procesamiento geo espacial de los factores

El geoprocésamiento de los factores se realiza en Python con algunas librerías como Numpy y Gdal, todos los procesamientos se pueden observar en la Fig. [18]

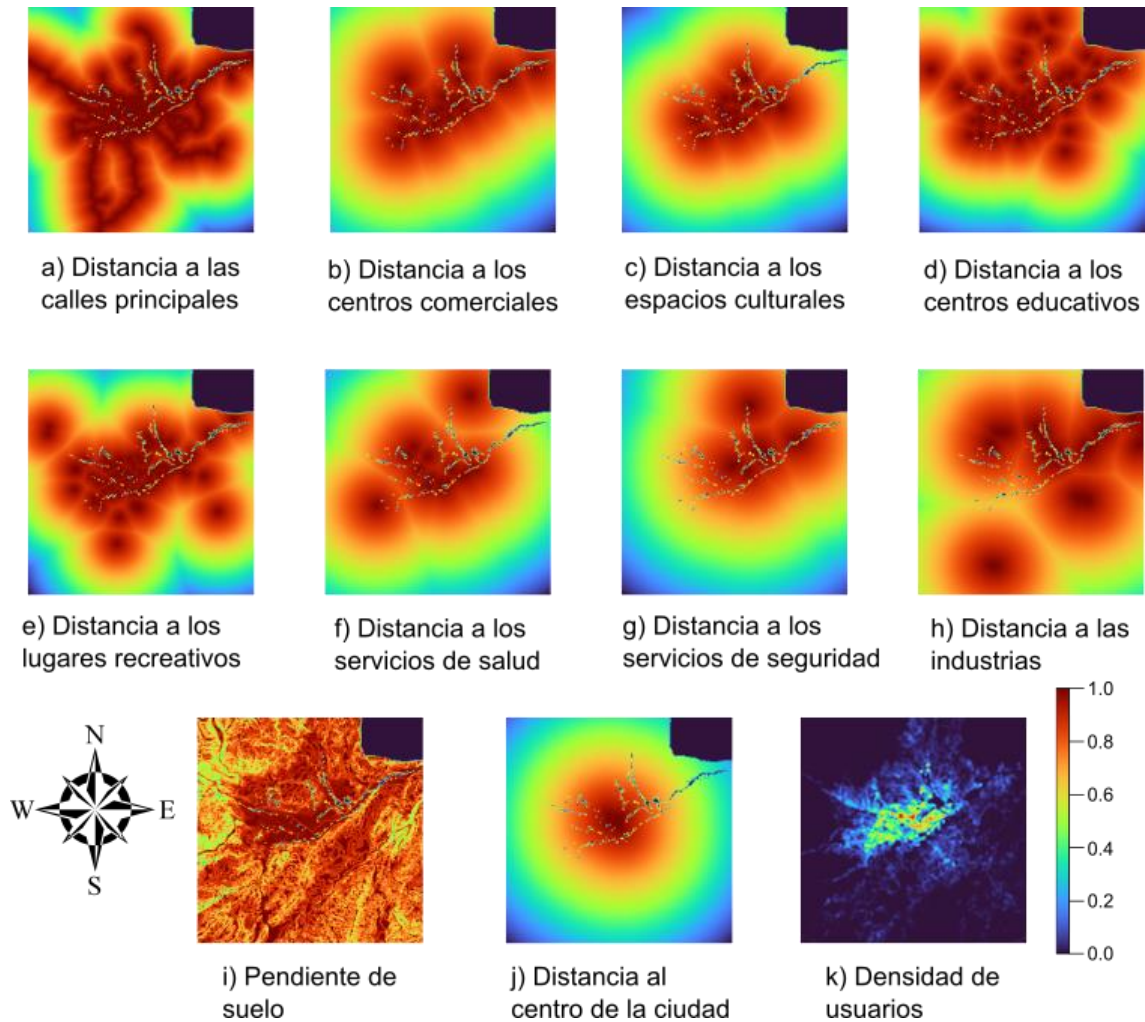


Figura 18 Factores geo procesados

Nota: Fuente, elaboración del autor

Para el caso de estudio como se detalla en la sección 3.3 contamos con 3 tipos de factores como son los de proximidad, locales y de entorno, para los factores de proximidad se realiza un cálculo de la distancia euclidiana, por otra parte, para el factor local se realiza el análisis de la pendiente del suelo, y por último el factor de entorno toma en cuenta el efecto vecindario o estadísticas focales.

Para determinar el mapa de idoneidad es importante normalizar estos criterios, para nuestro caso se realiza en un rango de valores entre [0-1], donde 1 representa la puntuación más deseable como podemos observar en la sección 4.2.

Una vez realizado todos los cálculos se los almacena en una matriz de 3 dimensiones que está formada de la siguiente manera en el eje de las “ordenadas” se encuentran los factores almacenados en cada columna, en el eje de las “abscisas” se encuentra toda la información geoespacial, y en la última dimensión se encuentra apilado los factores en secuencia de tiempo.

#### **4.1. Mapa de probabilidad**

La predicción de la demanda eléctrica determina donde ocurrirán los cambios de acuerdo al uso de la tierra por ejemplo cuando existe nuevos desarrollos o reurbanización en áreas existentes, etc. El mapa de probabilidad se lo crea para cada tipo de consumidor y en cada caso se obtiene una puntuación asignando a cada área para reflejar una probabilidad de cambio (Ariza Ramírez, 2013)

Para obtener dicho mapa se lo consigue mediante el aprendizaje supervisado con la CNN, para nuestro caso cada factor representa una característica y el resultado de todas las combinaciones de los factores es el número de clientes que existe en cada celda.

Para el entrenamiento de la red se utiliza la librería de scikit-learn, la misma que esta familiarizada con el aprendizaje profundo, y posee funciones que ayudan a preparar la base de datos en tensores de entrenamiento y validación, para esta investigación se determinó en un 70 % de los datos para la prueba y un 30% para la validación.

#### **4.2. Calibración del modelo CNN**

Para calibrar el modelo y calcular el mapa de probabilidades de desarrollo se utiliza la información base del año 2022, esto como punto de partida hacia los años anteriores, cabe recalcar que para esta investigación se toma en cuenta 3 años anteriores desde el año base. Esto porque en las pruebas se evidencio que si se toma información de años anteriores los resultados no satisfacen las necesidades, generando varios errores en las pruebas y calibraciones.

La arquitectura que se utilizó para este caso de estudio está basada en la arquitectura VGG-16, adaptada a nuestro caso de estudio, en la Fig. [19] se puede ver la arquitectura propuesta.




Figura 19 Arquitectura propuesta

Nota: Fuente, elaboración del autor

Es importante mencionar que mientras más robusta sea la arquitectura de la CNN, más rendimiento computacional será necesario para satisfacer dicha petición, y no siempre garantiza mejores resultados.

### 4.3. Entrenamiento del modelo CNN

En esta etapa, se realiza un entrenamiento para cada tipo de consumidor con la arquitectura planteada, esto con la finalidad de obtener los pesos de conexión entre cada factor y los usuarios existentes en cada celda del mapa.

En la Tabla 4 se puede apreciar las diferencias en las pérdidas del entrenamiento, entre los diferentes grupos de consumidor.

Tabla 4 Resultados del entrenamiento del CNN según clase de consumidor

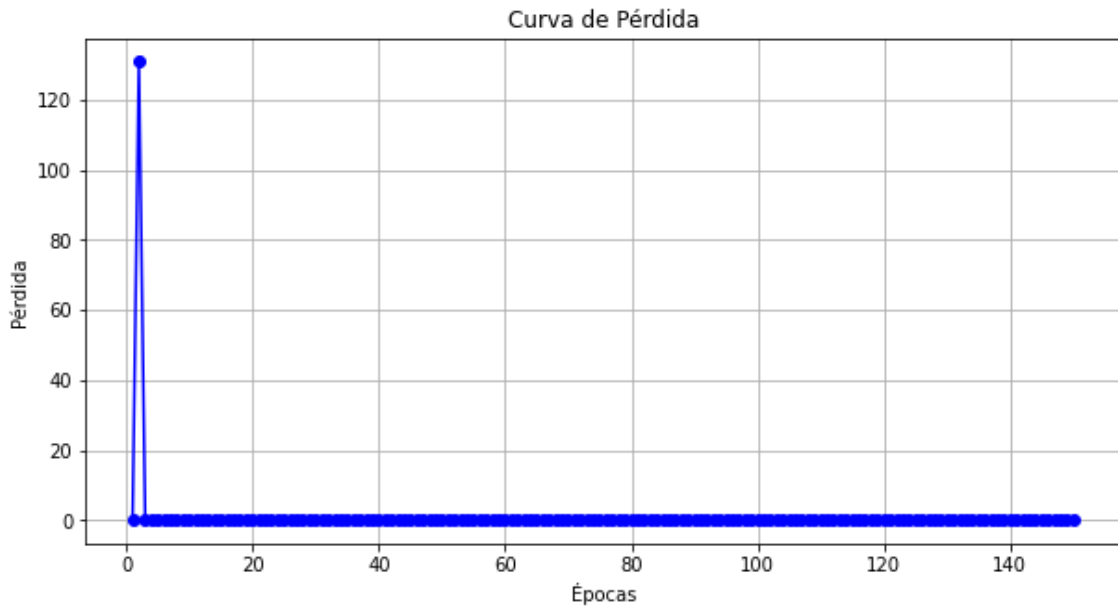
Clase de consumidor	Perdida MSE
Residencial	0.0016
Comercial	0.0003
Industrial	0.0032

Nota: Fuente, elaboración del autor

Adicionalmente en la Fig. [20] se puede apreciar la pérdida que existe en el entrenamiento de la clase residencial, para lograr estos resultados se estableció en 150

épocas el entrenamiento y un Lr de 0.01. El grafico representa el error cuadrado promedio de cada predicción, mientras menor sea el valor, más eficaz es el modelo para realizar predicciones.

En el grafico se puede apreciar que el modelo va logrando su objetivo, el cual es entrenar y mejorar las predicciones durante cada iteración.



*Figura 20 Curva de error en el entrenamiento de la clase Residencial*

*Nota: Fuente, elaboración del autor*

En la Fig. [21] se observa los diferentes mapas de probabilidad, siendo 0 nada de probabilidad de crecimiento y 1 máxima probabilidad de desarrollo. Para obtener estos resultados.

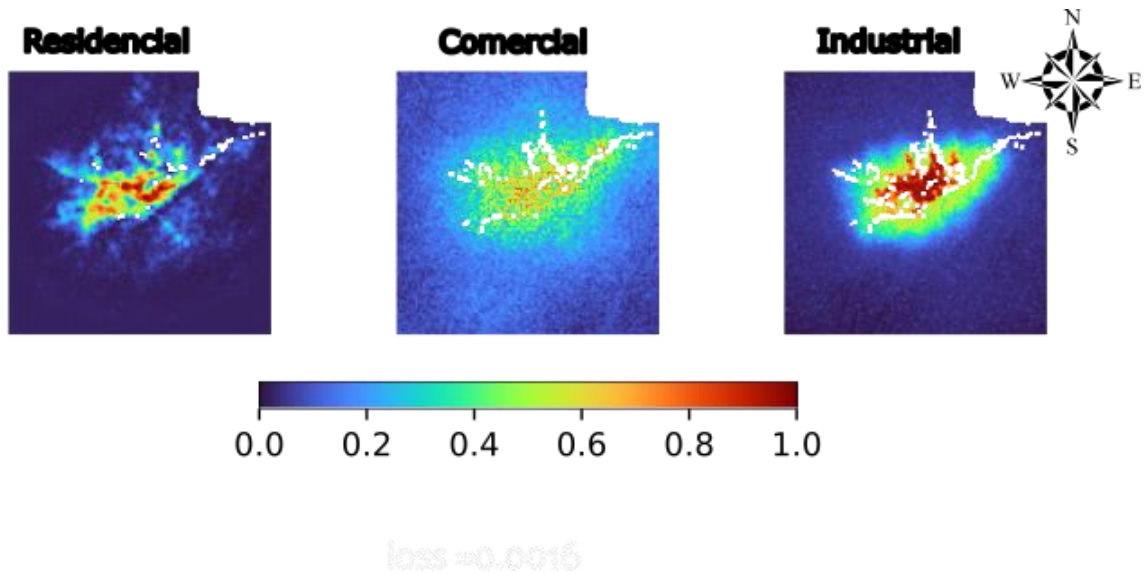


Figura 21 Mapa de probabilidades de desarrollo establecidas por la CNN

Nota: Fuente, elaboración del autor

#### 4.4. Calibración del modelo CNN-CA

Como lo mencione anteriormente en la sección 3.3, el modelo CNN-CA se calibra mediante el análisis de las métricas, en las tablas [5], [6] se puede apreciar las diferentes métricas calculadas con diferentes valores para  $P_b$ .

Tabla 5 Métricas de precisión en vecindario tipo Von Neumann

Vecindad de Neumann			
	Precisión	Exactitud	F1-Score
Pb = 0,3	0,447	0,862	0,414
Pb = 0,5	0,452	0,865	0,369
Pb = 0,7	0,45	0,866	0,354

Tabla 6 Métricas de precisión en vecindario tipo Moore

Vecindad de Moore			
	Precisión	Exactitud	F1-Score
Pb = 0,3	0,441	0,862	0,39
Pb = 0,5	0,425	0,86	0,363
Pb = 0,7	0,449	0,865	0,355

Una vez comparado varios tipos de vecindario, para proceder se establece que para la asignación de clientes en cada S/E se tomara en cuenta la vecindad de Von Neumann con un  $P_b = 0.3$ .

En la Fig. [22] se aprecia la distribución que el modelo asigna en la simulación literal (b), en comparación de la distribución espacial real literal (a) en el año base, el modelo escogió 1955 celdas y lo real es 1957. Se puede notar que el modelo aplicando el modelo CNN-CA ejerce un mayor crecimiento en la zona central de la ciudad de Cuenca, acertando pocas celdas en los extremos de la área de estudio.




Figura 22 Distribución de los consumidores tipo residencial en el año base

Nota: Fuente, elaboración del autor

#### 4.4. Proyección de la demanda y usuarios

Como dato de entrada para el modelo de simulación CNN-CA se tiene las proyecciones de incremento de la demanda eléctrica en áreas grandes como se puede observar en la Fig. [23] La potencia desde el año 2023 hasta el año 2035 que es la información proporcionada por CENTROSUR.




Figura 23 Proyección de la demanda eléctrica para los siguientes años por cada subestación de CENTROSUR

Nota: Fuente, elaboración del autor

Por otra parte, en la tabla [7] se aprecia la estimación detallada para los lapsos de tiempos establecidos desde el año base a futuro.

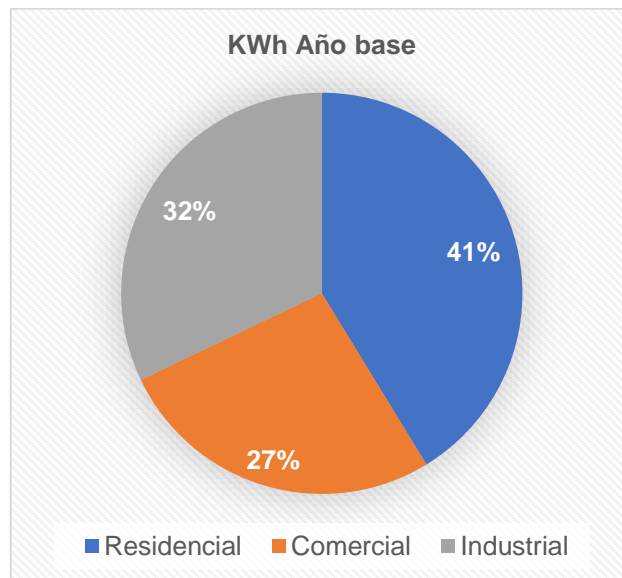
Tabla 7 Potencia KWh de cada S/E por cada tipo de consumidor

S/E	Tipo de Consumidor	Base	Año 5	Año 10	Año 15	Δ Año 5	Δ Año 10	Δ Año 15
SE01	Residencial	2,29	2,33	2,41	2,43	0,04	0,07	0,03
	Comercial	3,21	3,27	3,37	3,41	0,06	0,10	0,04
	Industrial	0,22	0,23	0,23	0,23	0,00	0,01	0,00
SE02	Residencial	1,76	1,85	1,96	2,04	0,09	0,11	0,08
	Comercial	5,22	5,48	5,82	6,07	0,25	0,34	0,25
	Industrial	0,09	0,10	0,10	0,11	0,00	0,01	0,00
SE03	Residencial	10,69	11,29	12,15	12,83	0,60	0,85	0,68
	Comercial	6,78	7,17	7,71	8,14	0,38	0,54	0,43
	Industrial	1,31	1,38	1,48	1,57	0,07	0,10	0,08
SE04	Residencial	6,67	7,14	7,63	8,05	0,47	0,49	0,42
	Comercial	3,16	3,38	3,62	3,82	0,22	0,23	0,20
	Industrial	18,67	19,98	21,36	22,52	1,30	1,38	1,16

<b>SE05</b>	Residencial	16,90	18,31	20,24	21,97	1,41	1,93	1,74
	Comercial	7,44	8,06	8,91	9,68	0,62	0,85	0,76
	Industrial	10,07	10,91	12,06	13,09	0,84	1,15	1,03
<b>SE07</b>	Residencial	4,32	4,77	5,43	6,07	0,45	0,66	0,64
	Comercial	1,08	1,19	1,36	1,52	0,11	0,17	0,16
	Industrial	7,93	8,76	9,97	11,15	0,83	1,22	1,18
<b>SE08</b>	Residencial	6,83	7,36	8,14	8,83	0,53	0,78	0,69
	Comercial	4,90	5,29	5,84	6,34	0,38	0,56	0,50
	Industrial	1,08	1,16	1,28	1,39	0,08	0,12	0,11
<b>SE12</b>	Residencial	1,62	1,77	2,00	2,21	0,15	0,22	0,21
	Comercial	1,16	1,28	1,44	1,59	0,11	0,16	0,15
	Industrial	0,36	0,40	0,45	0,49	0,03	0,05	0,05

*Nota: Fuente, elaboración del autor*

Dando como resultado los valores establecidos en la figura [24] como referencia a los siguientes años, como es una proyección tendencial, los valores para los siguientes lapsos de tiempo se mantienen constantes tal y como se muestra en el gráfico.



*Figura 24 Repartición porcentual de potencia KWh para el año base*

*Nota: Fuente, elaboración del autor*

CENTROSUR también realiza una proyección de nuevos usuarios para cada S/E, la información en cuanto al incremento de dichos consumidores esta detallada en la tabla [8]. Hay que mencionar que para el área de estudio es necesario recortar la información de cada S/E hasta el límite del área de estudio, puesto que algunas de las S/E abarcan más de lo indicado como se puede apreciar en la Fig. [17].

*Tabla 8 Incremento de usuarios en cada S/E según tipo de consumidor*

S/E	Tipo de Consumidor	Base	Año 5	Año 10	Año 15	$\Delta$ Año 5	$\Delta$ Año 10	$\Delta$ Año 15
<b>SE01</b>	Residencial	8.332	9.461	10.624	11.787	1.129	1.163	1.163
	Comercial	4.469	4.992	5.527	6.061	523	535	534
	Industrial	193	194	198	205	1	4	7
<b>SE02</b>	Residencial	5.915	6.716	7.542	8.367	801	826	825
	Comercial	4.499	5.024	5.563	6.101	525	539	538
	Industrial	86	86	87	91	-	1	4
<b>SE03</b>	Residencial	36.531	41.479	46.578	51.677	4.948	5.099	5.099
	Comercial	4.219	4.712	5.217	5.722	493	505	505
	Industrial	676	680	691	715	4	11	24
<b>SE04</b>	Residencial	28.924	32.842	36.880	40.917	3.918	4.038	4.037
	Comercial	2.410	2.691	2.979	3.268	281	288	289
	Industrial	967	970	988	1.023	3	18	35
<b>SE05</b>	Residencial	60.686	68.905	77.375	85.847	8.219	8.470	8.472
	Comercial	5.761	6.434	7.125	7.816	673	691	691
	Industrial	1.042	1.050	1.068	1.102	8	18	34
<b>SE07</b>	Residencial	19.798	22.479	25.243	28.006	2.681	2.764	2.763
	Comercial	1.120	1.251	1.384	1.518	131	133	134
	Industrial	330	333	338	350	3	5	12
<b>SE08</b>	Residencial	21.445	24.350	27.343	30.336	2.905	2.993	2.993
	Comercial	2.125	2.373	2.627	2.881	248	254	254
	Industrial	443	450	453	469	7	3	16
<b>SE12</b>	Residencial	3.785	4.297	4.826	5.354	512	529	528

Comercial	288	322	356	391	34	34	35
Industrial	40	40	41	43	-	1	2

Nota: Fuente, elaboración del autor

Los  $\Delta$  son la representación del incremento de un lapso de tiempo a otro, para este caso se calcula ( $\Delta$  año 5 = año 5 – año base). La comparación del crecimiento por cada tipo de consumidor se observa en la Fig. [25], dando como resultado un mayor incremento en el ámbito residencial, por otra parte, en lo industrial se observa muy pocos cambios a futuro según la tendencia marcada por la CENTROSUR.

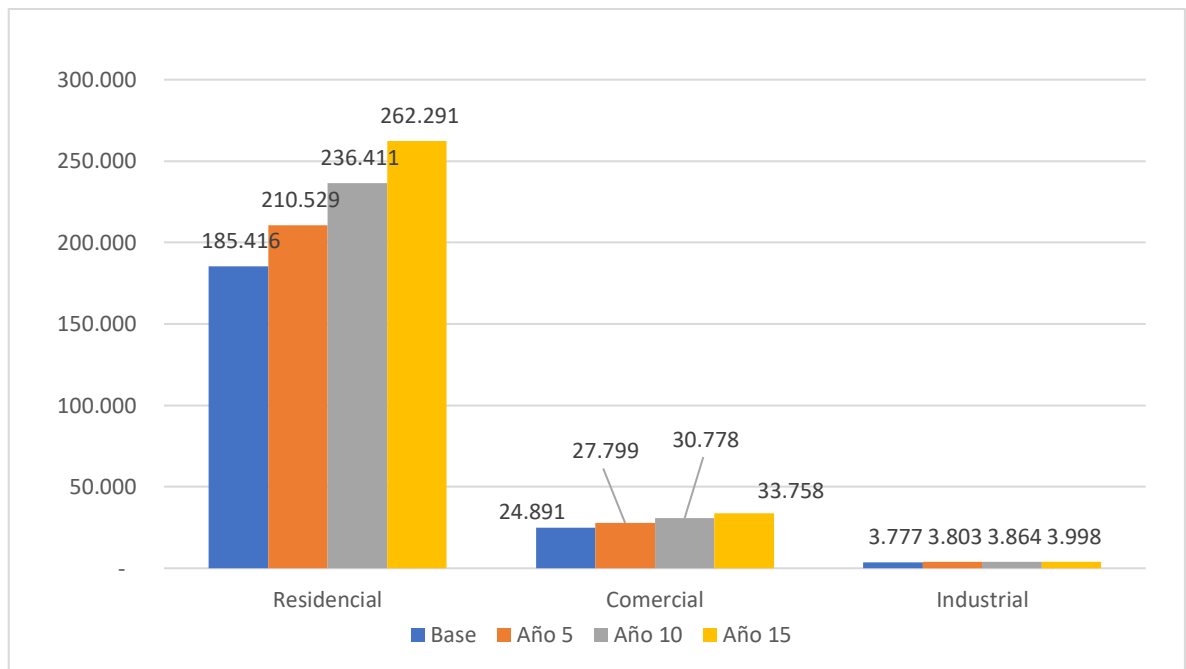


Figura 25 Comparación del crecimiento total en los diferentes lapsos de tiempo

Nota: Fuente, elaboración del autor

Dando como resultado una distribución porcentual de los nuevos usuarios según su tipo de consumidor como esta expresado en la Fig. [26]

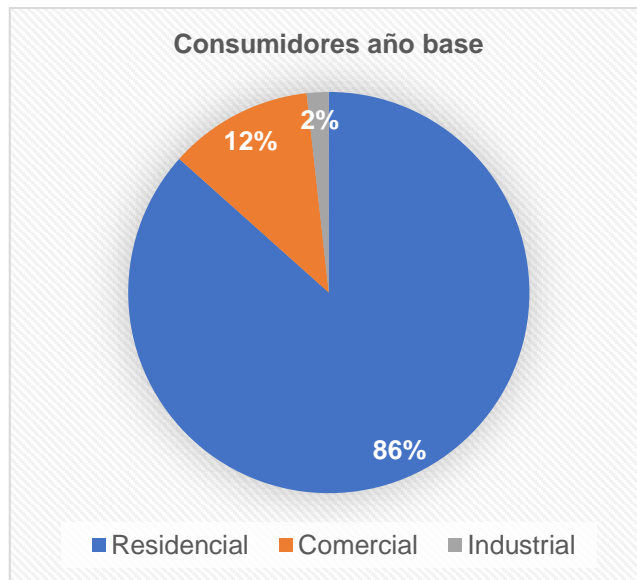


Figura 26 Repartición porcentual de los tipos de consumidor para el año base

Nota: Fuente, elaboración del autor

Una vez contando con todos estos datos se procede al último paso de la investigación que es obtener los resultados de la simulación.

#### 4.5. Resultados obtenidos de la proyección espacio – tiempo

Para este último proceso se cuenta con los datos anteriores como datos de ingreso para el modelo CNN-CA que ya se encuentra calibrado anteriormente y nos entrega los siguientes resultados.

Para la clase residencial se puede apreciar la distribución espacial de los clientes en la Fig. [27] en el literal (a) tenemos un máximo de 984 clientes / km<sup>2</sup>, en comparación con el literal (d) que obtenemos un máximo de 1239 clientes / km<sup>2</sup>

Observando los gráficos se puede deducir que en la clase residencial la proyección mantiene un crecimiento constante en el casco urbano de la ciudad de Cuenca, enfocándose principalmente por crecer en las áreas centrales y aledañas.

En cuanto a los resultados de la distribución tanto de los usuarios como de la demanda eléctrica para los demás tipos de consumidores los gráficos se pueden apreciar en la sección ANEXOS. Para el tipo de consumidor comercial la asignación de clientes se da mayoritariamente en el centro urbano con un máximo de 1860 clientes para el año base y 1863 para el año horizonte, a diferencia de la clase residencial en

cuanto a la distribución energética se da netamente donde existe el incremento de los clientes proyectados.




Figura 27 Distribución espacial de clientes en los diferentes años de la clase "Residencial"

Nota: Fuente, elaboración del autor

En cuanto a la distribución de potencia demandada para la clase residencial se obtiene los resultados expresados en la Fig. [28]. Realizando una comparación entre el

año base (literal a) vs año 15 (literal d) se aprecia el incremento que va a tener la demanda eléctrica tanto en el casco urbano de la ciudad de Cuenca y sus alrededores.

Para el año base se obtiene un máximo de 69 kW/ km<sup>2</sup>, a diferencia del año 15 que tenemos 120 kW/ km<sup>2</sup>, a diferencia de la distribución espacial para los usuarios, se nota que el incremento del consumo eléctrico se va a dar por las afueras del centro histórico, esto con relación desde el año base hasta el año 15.




Figura 28 Resultados de la distribución espacial de la demanda eléctrica en los diferentes lapsos de tiempo para la clase "Residencial"

Nota: Fuente, elaboración del autor

## CONCLUSIONES

Los resultados obtenidos por el método de proyección planteado son superiores a los métodos planteados anteriormente por la CENTROSUR, obteniendo un 12.80% de ganancia y eficacia en cuanto a los trabajos previos. El cálculo de la ganancia se obtuvo sumando la diferencia que existió entre el trabajo previo y esta investigación luego dividiendo para el valor anterior y multiplicando por 100. Para la empresa distribuidora del servicio eléctrico estos resultados caben dentro de la confiabilidad del sistema con un horizonte próspero y se empieza a analizar la creación de una nueva S/E en las afueras del casco urbano, por el sector de Chaullabamba o Ricaurte.

El efecto de la vecindad juega un papel muy importante en los resultados de la calibración del método CNN-CA. Por lo que se determinó que el tipo de vecindad de Von Neumann fue el más adecuado para este tipo de estudio obteniendo un 5.79% de mejora en comparación con el tipo de vecindad de Moore.

Tanto las proyecciones del alumbrado público como las cargas especiales fueron descartadas para la predicción del modelo puesto que estas aumentan las tasas de crecimiento de una manera considerable. Causando que en el momento del entrenamiento el método CNN-CA se ve afectado de manera directa influyendo en los resultados en la asignación de la demanda eléctrica.

Aunque la métrica F1-Score resulto ser medio bajo 0.41, se clasifica en la categoría "Moderada", ya que presento una coincidencia del 86,2% comparado con el crecimiento real de clientes, demostrando que la simulación del modelo establecido para la investigación proyecta de manera satisfactoria el desarrollo de nuevos usuarios.

Para el proceso de calibración en el CA, consta de valores elegidos de manera empírica, estableciendo los valores según varios intentos y observando tanto las métricas como los gráficos en la asignación de los clientes en la simulación vs lo real, estableciendo  $r = 1.5$  y  $\lambda = 0.5$  en la ecuación (7), (8) respectivamente.

## RECOMENDACIONES

Para mejorar la confiabilidad del modelo de proyección planteado es recomendable para futuros proyectos de investigación indagar profundamente o buscar nuevos tipos o algoritmos que se enfoquen en el segundo término de la formulación matemática del CA, mismo que trata sobre el efecto de la vecindad.

Para la distribución espacial de los nuevos usuarios, existen varios métodos que se pueden emplear, es recomendable estudiarlos y realizar una comparación para ver la diferencia entre los resultados.

La proyección de la demanda y el incremento de los consumidores establecidos por el método Holt Winters es de vital importancia para el modelo de simulación, se recomienda realizar una comparación con otros métodos de proyección para evaluar resultados.

## REFERENCIAS BIBLIOGRÁFICAS

- Arias Román, L. F. (2000). *Programa digital para el pronóstico de carga eléctrica espacial* [bachelorThesis, QUITO/EPN/2000]. <http://bibdigital.epn.edu.ec/handle/15000/5128>
- Ariza Ramírez, A. M. (2013). *Métodos utilizados para el pronóstico de demanda de energía eléctrica en sistemas de distribución*. <https://hdl.handle.net/11059/3862>
- Ariza Ramírez, Adriana Marcela. (2013). *Métodos utilizados para el pronóstico de demanda de energía eléctrica en sistemas de distribución*. <https://repositorio.utp.edu.co/items/28cc0292-10dd-4bce-9282-80606958278e>
- Artola Moreno, Á. (2019). *Clasificación de imágenes usando redes neuronales convolucionales en Python*. <https://idus.us.es/handle/11441/89506>
- Berrezueta Suárez, J. R., & Encalada Serrano, A. P. (2014). *Análisis de los factores que afectan la demanda de energía eléctrica y su estimación. Sector residencial del área de concesión de la Empresa Eléctrica Regional Centro Sur C.A., período 2002-2012* [bachelorThesis]. <http://dspace.ucuenca.edu.ec/handle/123456789/5184>
- Cabello, J. J., Garcia, D., Sagastume, A., Priego, R., Hens, L., & Vandecasteele, C. (2012). An approach to sustainable development: The case of Cuba. *Environment, Development and Sustainability*, 14(4), 573-591. <https://doi.org/10.1007/s10668-012-9338-8>
- Carreno, E. M., Rocha, R. M., & Padilha-Feltrin, A. (2011). A Cellular Automaton Approach to Spatial Electric Load Forecasting. *IEEE Transactions on Power Systems*, 26(2), 532-540. <https://doi.org/10.1109/TPWRS.2010.2061877>
- David Alejandro Reyes Gómez. (2011). Descripción y Aplicaciones de los Autómatas Celulares. *Departamento de Aplicación de Microcomputadoras Universidad Autónoma de Puebla*. [http://delta.cs.cinvestav.mx/~mcintosh/cellularautomata/Summer\\_Research\\_files/Arti\\_Ver\\_Inv\\_2011\\_DARG.pdf](http://delta.cs.cinvestav.mx/~mcintosh/cellularautomata/Summer_Research_files/Arti_Ver_Inv_2011_DARG.pdf)
- Dávila Arias, R. A. (2019). *Proyección espacial de la demanda eléctrica a mediano plazo en empresas de distribución en el Ecuador* [masterThesis, Quito, 2019.]. <http://bibdigital.epn.edu.ec/handle/15000/19996>

- Deadman, P., Brown, R. D., & Gimblett, H. R. (1993). Modelling Rural Residential Settlement Patterns with Cellular Automata. *Journal of Environmental Management*, 37(2), 147-160. <https://doi.org/10.1006/jema.1993.1011>
- Ediger, V. Ş., & Tatlıdil, H. (2002). Forecasting the primary energy demand in Turkey and analysis of cyclic patterns. *Energy Conversion and Management*, 43(4), 473-487. [https://doi.org/10.1016/S0196-8904\(01\)00033-4](https://doi.org/10.1016/S0196-8904(01)00033-4)
- Hathout, S. (2002). The use of GIS for monitoring and predicting urban growth in East and West St Paul, Winnipeg, Manitoba, Canada. *Journal of Environmental Management*, 66(3), 229-238. <https://doi.org/10.1006/jema.2002.0596>
- Haugeland, J. (1989). *Artificial Intelligence: The Very Idea*. The MIT Press. <https://doi.org/10.7551/mitpress/1170.001.0001>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
- Li, X., & Yeh, A. G.-O. (2002). Neural-network-based cellular automata for simulating multiple land use changes using GIS. *International Journal of Geographical Information Science*, 16(4), 323-343. <https://doi.org/10.1080/13658810210137004>
- Mayorga Márquez, B. J. (2018). *Pronóstico espacial de demanda eléctrica mediante la técnica de agrupamiento (clustering) de curvas S históricas – Aplicación a la Empresa Eléctrica Ambato Regional Centro Norte S.A.* [bachelorThesis, Quito, 2018.]. <http://bibdigital.epn.edu.ec/handle/15000/19297>
- Monteiro, C. D. M. (2003). *Fuzzy spatial load forecasting*. <https://repositorio-aberto.up.pt/handle/10216/12664>
- Morales, D. X., Besanger, Y., Moscoso, S. A., & Pesantez, P. A. (2017). Development of a spatial load-forecasting module for optimizing planning of electricity supply. *2017 IEEE PES Innovative Smart Grid Technologies Conference - Latin America (ISGT Latin America)*, 1-6. <https://doi.org/10.1109/ISGT-LA.2017.8126738>
- Nilsson, N. J. (1998). *Artificial intelligence: A new synthesis*. Morgan Kaufmann.
- Predicción Espacial de La Demanda Eléctrica en La Ciudad de Maracaibo. | PDF | Predicción | Planificación.* (s. f.). Scribd. Recuperado 24 de agosto de 2023, de

- <https://es.scribd.com/document/52804258/Prediccion-Espacial-de-la-Demanda-Elctrica-en-la-Ciudad-de-Maracaibo>
- Ramirez Castaño, S. (2004). *Redes de Distribución de Energía* (1-3 ed). Universidad Nacional de Colombia.
- Rich, E., & Knight, K. (1991). *Artificial intelligence* (2. ed). McGraw-Hill.
- Russell, S. J., & Norvig, P. (2011). *Inteligencia artificial: Un enfoque moderno* (2ª ed., reimp). Pearson Educación.
- Santiesteban Velázquez, A., Nápoles González, O. J., Rodríguez Peña, D., & Jaime García, D. (2014). Pronostico de consumo de energía eléctrica usando redes neuronales artificiales. *Tlatemoani: revista académica de investigación*, 16, 19-28.
- Simbaña Guamanzara, M. V. (2015). *Optimización mediante el método de Montecarlo de la demanda eléctrica residencial* [bachelorThesis].  
<http://dspace.ups.edu.ec/handle/123456789/11279>
- Simonyan, K., & Zisserman, A. (2014). *Very Deep Convolutional Networks for Large-Scale Image Recognition*. <https://doi.org/10.48550/ARXIV.1409.1556>
- Vieira, D. A. G., Silva, B. E., Menezes, T. V., & Lisboa, A. C. (2020). Large scale spatial electric load forecasting framework based on spatial convolution. *International Journal of Electrical Power & Energy Systems*, 117, 105582.  
<https://doi.org/10.1016/j.ijepes.2019.105582>
- White, R., & Engelen, G. (1993). Cellular Automata and Fractal Urban Form: A Cellular Modelling Approach to the Evolution of Urban Land-Use Patterns. *Environment and Planning A: Economy and Space*, 25(8), 1175-1199. <https://doi.org/10.1068/a251175>
- Willis, H. L. (2002). *Spatial Electric Load Forecasting* (0 ed.). CRC Press.  
<https://doi.org/10.1201/9780203910764>
- Willis, H. L. (2004). *Power Distribution Planning Reference Book* (0 ed.). CRC Press.  
<https://doi.org/10.1201/9781420030310>
- Willis, H. L., & Northcote-Green, J. E. D. (1983). Spatial electric load forecasting: A tutorial review. *Proceedings of the IEEE*, 71(2), 232-253.  
<https://doi.org/10.1109/PROC.1983.12562>
- Winston, P. H. (1992). *Artificial intelligence* (3rd ed). Addison-Wesley Pub. Co.

Zambrano, S., Molina, M., Chumbi, W., & Patiño, C. (2018). Modelo de Simulación Jerárquico para la Proyección Espacio Temporal de la Demanda Eléctrica: Caso de estudio en CENTROSUR. *Revista Técnica «Energía»*, 14(1).

<https://doi.org/10.37116/revistaenergia.v14.n1.2018.91>

Zavala, V. M., Constantinescu, E. M., Krause, T., & Anitescu, M. (2009). On-line economic optimization of energy systems using weather forecast information. *Journal of Process Control*, 19(10), 1725-1736. <https://doi.org/10.1016/j.jprocont.2009.07.004>

## ANEXOS

### ANEXO 1

#### MAPAS DE DISTRIBUCION ESPACIAL DE CLIENTES DE LA CLASE COMERCIAL





Figura 29 Distribución espacial de clientes para la clase comercial

**ANEXO 2**


**MAPAS DE DISTRIBUCION ESPACIAL DE LA DEMANDA ELECTRICA DE LA CLASE COMERCIAL**



*Figura 30 Distribución espacial de la demanda eléctrica de la clase comercial*

**ANEXO 3**


**MAPAS DE DISTRIBUCION ESPACIAL DE CLIENTES DE LA CLASE INDUSTRIAL**



*Figura 31 Distribución espacial de clientes para la clase industrial*

**ANEXO 4**

**MAPAS DE DISTRIBUCION ESPACIAL DE LA DEMANDA ELECTRICA DE LA CLASE INDUSTRIAL**




*Figura 32 Distribución espacial de la demanda eléctrica para la clase industrial*

## **AUTORIZACION DE PUBLICACION EN EL REPOSITORIO INSTITUCIONAL**

Yo, Christian Andrés Macao Piña portador de la cédula de ciudadanía N.º 0105782023. En calidad de autor/a y titular de los derechos patrimoniales del trabajo de titulación "Previsión espacio temporal de la demanda eléctrica en la empresa Regional Centro Sur" de conformidad a lo establecido en el artículo 114 Código Orgánico de la Economía Social de los Conocimientos, Creatividad e Innovación, reconozco a favor de la Universidad Católica de Cuenca una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos, Así mismo; autorizo a la Universidad para que realice la publicación de este trabajo de titulación en el Repositorio Institucional de conformidad a lo dispuesto en el artículo 144 de la Ley Orgánica de Educación Superior.

Cuenca, 24 de noviembre de 2023

F:   
Christian Andrés Macao Piña  
0105782023