



Inteligencia artificial aplicada a la operación y control de redes eléctricas

Artificial intelligence applied to the operation and control of power grids

Presentado: 09/03/2026

Aprobado: 22/07/2026

Publicado: 20/08/2026

Romero Beneitez Facundo Cruz

Universidad Tecnológica Nacional, Argentina.
fromerobeneitez@frba.utn.edu.ar

Resumen

Este trabajo propone una visión y una arquitectura de inteligencia artificial basadas en redes neuronales profundas para el control masivo y seguro de la red de transmisión. La solución integra datos SCADA y mediciones de sincrofasores (PMU) con contexto operativo (topología, demanda, clima, temperatura de equipos). En este ciclo de decisión: se emplea tanto aprendizaje supervisado con redes neuronales profundas entrenadas con etiquetas de escenarios aportadas por la operación humana, como también aprendizaje por refuerzo para políticas de maniobras que operan dentro de configuraciones aún no conocidos por el humano de una red eléctrica.

El sistema coordina control de tensión, corriente, potencias, frecuencia, gestión de demanda y la actuación sobre equipos (transformadores, generadores, interruptores, bancos de capacitores, etc), habilitando respuestas activas y proactivas ante contingencias y maniobras habituales. Un Tablero operativo ofrece conciencia situacional y recomendaciones explicables, con validaciones previas (flujo de carga, restricciones) antes de ejecutar y con operador en el bucle.

Las pruebas con eventos históricos y escenarios simulados muestran menores tiempos de respuesta, contención de violaciones y alivio de sobrecargas, evidenciando viabilidad y escalabilidad. En perspectiva, la arquitectura habilita control coordinado distribuido, reforzando la estabilidad dinámica y la resiliencia ante acontecimientos habituales y de clima extremo: un paso concreto hacia la red eléctrica del futuro, más inteligente y gobernada por datos.

Palabras clave: Redes neuronales profundas; Redes de alta tensión; Soporte a la decisión; Supervisión inteligente; Centros de control.

Abstract

This work proposes a vision and architecture of artificial intelligence based on deep neural networks for the large-scale and secure control of the transmission grid. The solution integrates SCADA data and phasor measurement unit (PMU) readings with operational context, including network topology, demand, weather, and equipment temperature.

In this decision-making cycle, both supervised learning—using deep neural networks trained with scenario labels derived from human operation—and reinforcement learning—for maneuver policies capable of acting within configurations not yet known to the human operator—are employed.

The system coordinates voltage, current, power, and frequency control, demand management, and equipment operation (transformers, generators, circuit breakers, capacitor banks, etc.), enabling active and proactive responses to contingencies and routine switching. An operational dashboard provides situational awareness and explainable recommendations, with prior validations (load flow and operational constraints) before execution and always keeping the operator in the loop.

Tests with historical events and simulated scenarios show shorter response times, containment of limit violations, and relief of overloads, demonstrating both feasibility and scalability. Looking forward, the proposed architecture enables coordinated distributed control, enhancing dynamic stability and resilience against normal and extreme weather events—representing a concrete step toward the future intelligent, data-governed power grid.

Keywords: Deep neural networks; High voltage networks; Decision support; Intelligent supervision; Control centers.

1 - Introducción

1.1 Antecedentes y propósito del trabajo.

La operación de redes de transmisión en alta tensión enfrenta una complejidad creciente debido a la integración masiva de generación renovable variable, al aumento sostenido de la demanda, a la exposición a eventos meteorológicos extremos y a la creciente interconexión topológica de los sistemas eléctricos. En este contexto, mantener simultáneamente la seguridad operativa bajo criterio N-1, la calidad de servicio —con tensión y frecuencia dentro de bandas admisibles— y la eficiencia técnico-económica exige evolucionar desde esquemas predominantemente manuales hacia estructuras de supervisión y control más automatizadas, predictivas y coordinadas.

En los últimos años, la inteligencia artificial ha mostrado resultados promisorios en múltiples problemas del sector eléctrico. La literatura reporta aplicaciones en pronóstico de demanda y generación renovable, estimación de estados, evaluación de estabilidad, detección de anomalías, mantenimiento predictivo y apoyo a la toma de decisiones operativas. Asimismo, se observa un crecimiento en el uso de técnicas de aprendizaje profundo, aprendizaje por refuerzo y modelos basados en grafos para representar sistemas eléctricos complejos y procesar grandes volúmenes de datos provenientes de SCADA, PMU y otras fuentes digitales.

A nivel metodológico, distintos enfoques han sido propuestos para abordar problemas operativos en sistemas eléctricos. Los modelos basados en aprendizaje profundo, como perceptrones multicapa y redes recurrentes, han sido ampliamente utilizados para predicción de demanda, estimación de estados y detección de anomalías (Raschka, 2015). Por otro lado, el aprendizaje por refuerzo profundo ha sido aplicado al control de sistemas eléctricos, permitiendo sintetizar políticas de operación en entornos simulados bajo restricciones dinámicas (Glavić, 2019). Más recientemente, las redes neuronales sobre grafos (GNN) han cobrado relevancia al permitir incorporar explícitamente la topología de la red eléctrica en el proceso de aprendizaje, mejorando la modelización de flujos y dependencias entre nodos. Asimismo, la disponibilidad de mediciones sincrofasoriales ha impulsado el desarrollo de modelos espacio-temporales capaces de capturar la dinámica rápida del sistema eléctrico con alta resolución temporal (Phadke & Thorp, 2008). Sin embargo, estos enfoques suelen desarrollarse de manera independiente o aplicados a problemas específicos, lo que limita su integración en esquemas unificados orientados a la operación coordinada del sistema en tiempo real.

No obstante, gran parte de estos trabajos se concentra en tareas específicas de predicción, clasificación, diagnóstico o estimación, mientras que son menos frecuentes las propuestas orientadas a la operación coordinada de múltiples recursos del sistema en tiempo casi real. En particular, sigue siendo limitada la cantidad de desarrollos que integran en una misma arquitectura datos estáticos y dinámicos, topología de red, contexto operativo y variables exógenas para transformarlos en recomendaciones de maniobra físicamente consistentes y operacionalmente viables sobre equipos tales como generadores, transformadores, interruptores y elementos de potencia.

Esta limitación resulta especialmente relevante en redes de transmisión, donde la operación segura no depende únicamente de anticipar estados futuros, sino también de seleccionar y coordinar acciones concretas bajo restricciones físicas, topológicas y regulatorias. La disponibilidad conjunta de mediciones SCADA y sincrofasoriales, complementadas con variables contextuales como demanda, clima o temperatura de equipos, permite construir una representación más rica del estado del sistema. Sin embargo, el volumen, la velocidad y la heterogeneidad de estas señales exceden, en muchos casos, la capacidad humana para convertirlas en tiempo operativo en decisiones consistentes y oportunas.

En este marco, el aporte de este trabajo consiste en proponer una arquitectura conceptual de inteligencia artificial orientada al soporte de la operación de redes de transmisión, en lugar de una aplicación aislada para predicción o diagnóstico. La propuesta se diferencia de enfoques más acotados porque articula, dentro de un mismo esquema, la fusión de datos SCADA, PMU y variables contextuales, el uso complementario de aprendizaje supervisado y aprendizaje por refuerzo, la consideración simultánea de múltiples objetivos operativos. También la incorporación del operador humano en el bucle como instancia de validación, supervisión y trazabilidad.

Por lo tanto, este trabajo busca avanzar desde una inteligencia artificial de carácter descriptivo o predictivo hacia una inteligencia artificial orientada a la acción operativa, concebida como un asistente inteligente capaz de recomendar maniobras sobre equipos del sistema dentro de un marco físicamente consistente. Desde esta perspectiva, la contribución principal radica en la formulación de una arquitectura integrada y escalable para soporte a la decisión en la operación de redes eléctricas de transmisión.

2 - Materiales y Métodos

La integración de estos tres componentes —la teoría operativa, la adquisición de datos en tiempo real y el modelado mediante inteligencia artificial— constituye la base metodológica de la arquitectura propuesta de operación asistida por IA. A través de este enfoque combinado, es posible reproducir, analizar y validar los procesos de toma de decisiones en condiciones reales y simuladas de operación, demostrando así la viabilidad y escalabilidad del sistema.

2.1 Criterios generales para operar una red de transmisión.

2.1.1 Propósito y marco

Los Criterios Generales de Operación para los sistemas de transmisión, integrados en los procedimientos, establecen las bases para una operación segura y eficiente: aumentar la fiabilidad, minimizar errores humanos, reducir tiempos de maniobra y asegurar la consistencia de la información transmitida (CAMMESA, s.f., Anexo 16). Todo operador en tiempo real se ajusta a estas prácticas, es importante nombrar algunas de ellas para una mayor comprensión de lo que la IA debe afrontar.

2.1.2 Rangos de tensión en operación normal

Los procedimientos imponen a los transportistas mantener las tensiones de barra lo más cercanas posible al nominal, dentro de los siguientes rangos (CAMMESA, s.f., Anexo 16):

500kV: $\pm 3\%$ (485-515kV).

220 kV: $\pm 5\%$ (209–231 kV).

132 kV: $\pm 5\%$ (125,4–138,6 kV).

66 kV: $\pm 7\%$ (61,38–70,62 kV).

2.1.3 Supervisión continua y normalización

El Operador debe vigilar continuamente tensiones y flujos de potencia reactiva en su red y vínculos, garantizando el cumplimiento de límites. Si se detectan nodos fuera de banda, se normaliza mediante los dispositivos de control de tensión y reactivo disponibles (CAMMESA, s.f., Anexo 16). Buena práctica: priorizar el cierre local del balance de Q para evitar transporte innecesario de reactivo y reducir pérdidas.

2.1.4 Prioridad de recursos para control de tensión/reactivo (CAMMESA, s.f., Anexo 16)

- a. Reactores y capacitores.
- b. Reguladores de excitación de máquinas.
- c. RBC (regulador bajo carga) de transformadores.
- d. Solicitud de Máquinas Forzadas.
- e. Solicitud de máxima/mínima excitación en generadores.

- f. Adecuación de perfiles de tensión en apoyo a áreas con déficit.
- g. Transferencias de carga desde nodos más comprometidos hacia menos comprometidos (vía otros centros de Operación).

2.1.5 Tensiones fuera de rango

Cualquier agente que requiera tensiones fuera de banda debe solicitarlo al Centro de Operaciones de mayor jerarquía. Se podrá aceptar si no excede 1,10 pu continuo del equipo: 242 kV (red 220 kV), 145 kV (132 kV) y 72,6 kV (66 kV) (CAMMESA, s.f., Anexo 16).

2.1.6 Consideraciones en Media Tensión

Aunque el control se ejecuta en el lado de mayor tensión, la mayoría de los servicios se suministra en MT (33 kV y 13,2 kV). En ET se mantienen tensiones nominales o las fijadas por acuerdos de conexión, según necesidades del usuario (CAMMESA, s.f., Anexo 16). En condiciones normales, no se debe superar 1,10 pu continuo: 36,3 kV (33 kV) y 14,52 kV (13,2 kV).

2.1.7 Configuraciones habituales en Alta Tensión (CAMMESA, s.f., Anexo 16)

- a. Se cierran todas las líneas y acoplamientos de AT para redundancia, confiabilidad y calidad.
- b. Existen excepciones justificadas (aportaciones, despacho, potencias de cortocircuito, demanda, sobrecargas).
- c. Salidas de AT (líneas/transformadores) a misma barra o barras separadas según equipamiento de la ET, buscando una distribución conveniente de aportes/demandas y facilitando la recomposición ante perturbaciones. En ET sin acoplador, se concentran en una barra manteniendo la otra desenergizada.

2.1.8 Configuraciones en Media Tensión (CAMMESA, s.f., Anexo 16)

- a. Si la demanda lo permite, se vincula la carga de un nivel de MT a un solo transformador, dejando los demás descargados para reducir potencias de cortocircuito en barras.
- b. Se separan demandas de un mismo nivel en distintos transformadores cuando los valores de tensión solicitados lo requieren.
- c. Barras sin carga se mantienen energizadas para facilitar cambios de configuración.
- d. Alimentadores anillados en distribución se conectan a la misma barra, salvo automatismos específicos que eviten desenganches consecuentes.
- e. A pedido de usuarios, se mantienen alimentadores abiertos con seccionadores cerrados y tensión de retorno para reposición rápida ante fallas.

2.1.9 Paralelos de transformadores y umbrales de carga

El paralelo de transformadores depende del equipamiento y del esquema de control en MT (Maestro/Seguidor, Marcha en Paralelo, etc.). Al 95% de carga nominal de un transformador se ajusta la potencia reactiva y/o se reconfigura la red en previsión de sobrecargas por incremento de demanda (CAMMESA, s.f., Anexo 16).

2.1.10 Nota final

Dadas estas normas y la heterogeneidad de la red, el volumen de información a procesar se hace muy grande cuando las condiciones climáticas o de demanda no ayudan. Esto propone una exigencia a los operadores muy elevada, teniendo en cuenta que muchas de ellas son tareas repetitivas y simples, vistas desde lo operacional (CAMMESA, s.f., Anexo 16).

A continuación, se describe cómo las variables llegan a los Centros de Control (telemedición, comunicaciones, sincronización temporal) y su visualización en esquemas unifilares digitales en tiempo real, base sobre la cual se construye la capa de IA propuesta.

2.2 Datos operativos: SCADA y sincrofasores (PMU).

2.2.1 Definición de datos operativos

Se denominan datos operativos a las señales que describen el estado instantáneo y la evolución temporal de la red eléctrica. Incluyen mediciones analógicas (tensiones, corrientes, potencias), estados lógicos (posición de interruptores, disparos, alarmas), eventos asociados y sus marcas temporales. Estos datos se originan en campo —transformadores de corriente y tensión (TI/TV), unidades terminales remotas (RTU)—, se transmiten a través de la red de comunicaciones y se almacenan en el centro de control en bases de tiempo real y sistemas historiadores. A partir de ellos se alimentan tanto las funciones de supervisión y control tradicionales como los modelos de inteligencia artificial.

2.2.2 Cadena de medición y referencia temporal

La cadena típica de adquisición puede representarse como: sensor → acondicionamiento → RTU → concentrador → servidor.

Cada señal debe estar acompañada de una marca temporal coherente. La sincronización se realiza mediante sistemas satelitales (GPS). El alineamiento temporal entre diferentes fuentes de datos —particularmente entre SCADA y PMU— constituye un requisito esencial para los análisis operativos, la reproducción de eventos y el entrenamiento confiable de modelos de IA.

2.2.3 Datos SCADA: alcance y características

Variables: magnitudes de tensión y corriente ($|V|$, $|I|$), potencias activa y reactiva (P , Q), estados, alarmas y contadores.

Resolución temporal: sondeos típicos cada 2–4 s (rango habitual 1–10 s), con latencias del orden de segundos.

Precisión: adecuada para estudios cuasi-estacionarios (perfiles de tensión, balances P/Q , sobrecargas).

Fortalezas: cobertura amplia de la red y disponibilidad de estados y alarmas.

Limitaciones: resolución insuficiente para capturar fenómenos de escala sub-segundo (oscilaciones, transitorios) (Radvanovsky & Brodsky, 2016).

2.2.4 Datos de sincrofasores (PMU): alcance y características

Mediciones: fasores de tensión y corriente (magnitud y ángulo), frecuencia instantánea y su derivada (ROCOF).

Resolución temporal: 25/50/100 fps en sistemas de 50 Hz, con latencias de decenas de milisegundos.

Sincronización: marcas de tiempo satelitales, directamente comparables entre estaciones.

Fortalezas: permiten observar la dinámica rápida del sistema, detectar oscilaciones interárea, evaluar coherencias angulares y fenómenos de islanding.

Limitaciones: cobertura aún parcial y mayor sensibilidad a ruido o pérdidas de paquetes en redes no robustas (Phadke & Thorp, 2008).

2.2.5 Metadatos y codificación esencial

Cada punto de medida debe estar acompañado de: identificador único, unidad de medida, relación de transformación (TI/TV), ubicación (estación, barra, circuito), asociación topológica, marca de tiempo, bandera de calidad (válido, estimado, fuera de servicio) y fuente (SCADA o PMU). Para aplicaciones de IA, los datos se normalizan en per-unit y la topología puede codificarse mediante técnicas de embeddings (representación vectorial).

2.2.6 Calidad de datos y procesos de limpieza

El preprocesamiento requiere: chequeos de rango y plausibilidad respecto a límites físicos y operativos, consistencia temporal (evitando saltos no plausibles y respetando tasas de variación), consistencia física aproximada, tratamiento de faltantes y duplicados mediante imputación o descarte, resincronización frente a jitter (variabilidad aleatoria en la demora de los paquetes de datos) o drift temporal, reconciliación de series frente a cambios topológicos (conmutación de interruptores).

Todo proceso de limpieza y transformación debe quedar versionado para garantizar trazabilidad operativa.

2.2.7 Fusión SCADA-PMU y alineamiento multiescala

Para integrar ambas fuentes se emplea un remuestreo hacia una malla común: de 1 s para aplicaciones estáticas o de 20 ms para aplicaciones dinámicas. Ventanas deslizantes permiten combinar historia breve (dinámica) con contexto de más largo plazo (tendencias).

El SCADA aporta contexto de cargas, estados y límites.

El PMU captura la dinámica rápida y la coherencia angular.

Se aplican filtros de tiempo para reducir jitter, preservando las banderas de calidad hacia la capa de IA.

2.2.8 Ingeniería de características para IA

Estático (SCADA): magnitudes de tensión por barra, márgenes a límites, potencias P/Q por línea o transformador, tasas de variación de tensión, sobrecargas normalizadas, temperaturas de equipos, variables climáticas y banderas de alarma (Radvanovsky & Brodsky, 2016).

Dinámico (PMU): ángulos de tensión y coherencias inter-áreas, frecuencia y ROCOF, densidad espectral de 0.1–2 Hz (oscilaciones interárea/locales), índices de amortiguamiento.

Etiquetas y targets: violaciones de tensión o frecuencia, márgenes N-1, sobrecargas incipientes, probabilidad de colapso local.

Balance de clases: eventos raros requieren técnicas de oversampling, focal loss o cost-sensitive learning (Phadke & Thorp, 2008).

2.2.9 Preparación de conjuntos de entrenamiento y validación

División temporal (train/val/test) para evitar data leakage. Etiquetado robusto mediante histéresis (ej.: violación si $|V| < V_{min}$ durante más de X segundos).

Definición de ventanas de entrada $[t-T, t]$ y horizontes de predicción $[t+\Delta, t+\Delta+H]$ (10–60 s en estático; 200–500 ms en dinámico) (Phadke & Thorp, 2008).

2.2.10 Ciberseguridad y gobernanza de datos

La gestión de datos debe garantizar control de acceso basado en roles, auditoría de lectura/escritura, cifrado en tránsito y políticas de retención o anonimización según normativa. Además, todo modelo que emita recomendaciones debe registrar entradas, versión utilizada y salidas generadas, con el fin de asegurar trazabilidad y responsabilidad operativa.

Comparación SCADA vs PMU		
Aspecto	SCADA	PMU (sincrofasores)
Naturaleza	Cuasi-estacionaria, cobertura amplia	Dinámica, alta resolución temporal
Variables	P Q S I V st	I V θ f
Tasa típica	1-10 s (usual: 2-4 s)	25/50/100 fps (50 Hz)
Latencia	Segundos	Decenas de milisegundos
Cobertura	Alta (muchas barras y equipos)	Media (puntos estratégicos)
Uso principal	Perfiles de tensión, sobrecargas, topología	Oscilaciones, coherencia angular, transitorios
Limitación	No captura fenómenos sub-segundo	Cobertura parcial, sensible a QoS

Tabla 1: SCADA VS Sincrofasores.

2.3 Redes neuronales Artificiales.

2.3.1 Definición y estructura básica

Las redes neuronales artificiales (RNA) son modelos computacionales que aproximan funciones complejas a partir de datos. Están inspiradas en el sistema nervioso y se emplean extensamente en clasificación, regresión y modelado secuencial. Una RNA organiza neuronas en capas (entrada, ocultas y salida) donde cada neurona aplica una transformación afín seguida de una función de activación (p. ej., ReLU, sigmoide, tanh). La Figura 1 ilustra su organización general (Raschka, 2015).

2.3.2 Entrenamiento, funciones de pérdida y activaciones

El entrenamiento ajusta pesos y sesgos para minimizar una función de pérdida entre predicciones y valores reales, mediante retropropagación y optimizadores (descenso de gradiente, Adam).. Las activaciones introducen no linealidad: ReLU es común en capas internas; sigmoide/softmax para probabilidades; tanh en modelos secuenciales. Cuando existen múltiples capas ocultas hablamos de redes profundas (DNN), que han mostrado alta eficacia en tareas complejas (Raschka, 2015).

2.3.3 Familias de modelos y usos habituales

- Perceptrón Multicapa (MLP): se utiliza para el análisis de datos tabulares provenientes de múltiples fuentes, permitiendo el pronóstico de estados, márgenes operativos y estimación de riesgos en la red eléctrica.
- Redes Neuronales Recurrentes (RNN), Long Short-Term Memory (LSTM), Gated Recurrent Units (GRU), Temporal Convolutional Networks (TCN) y Transformers temporales: están orientadas al procesamiento de series de tiempo, siendo especialmente útiles para la detección de anomalías y oscilaciones en variables eléctricas.
- Redes Neuronales Convolucionales (CNN 1D/2D): trabajan con ventanas temporales y mapas de calor, facilitando la clasificación de eventos y la extracción de patrones locales en señales o registros históricos.
- Redes Neuronales sobre Grafos (GNN): integran explícitamente la topología de la red eléctrica, permitiendo estimar flujos de potencia, congestiones y la propagación de contingencias entre nodos.
- Autoencoders (AE) y Variational Autoencoders (VAE): se aplican para la detección no supervisada de desviaciones, como derivas de datos o fallas en sensores, al comparar reconstrucciones con valores medidos.
- Redes Neuronales Físico-Informadas (PINN) o modelos híbridos físico-datos: incorporan restricciones físicas dentro de la función de pérdida, asegurando coherencia con las leyes eléctricas fundamentales.
- Aprendizaje por Refuerzo Profundo (DRL) —en sus variantes como Deep Q-Network (DQN), Deep Deterministic Policy Gradient (DDPG) y Proximal Policy Optimization (PPO)—: se emplea para la síntesis de políticas de maniobra bajo restricciones operativas, aprendiendo estrategias óptimas mediante interacción con entornos simulados del sistema eléctrico.

2.3.4 Datos y despliegue en operación

Para despliegues operativos, importan la sincronización temporal, la calidad de datos y la latencia de inferencia. Se emplean normalización (per-unit), codificación de estados/topología y ventanas deslizantes para combinar contexto y dinámica. La explicabilidad (p. ej., SHAP) y la trazabilidad de entradas/salidas favorecen la adopción por parte del operador (Raschka, 2015).

2.3.5 Limitaciones y mitigaciones

- Necesidad de datos amplios y representativos; riesgo de sobreajuste → regularización, validación temporal.
- Deriva de datos/modelo → reentrenos periódicos, monitoreo de desempeño y recalibración.
- Interpretabilidad limitada → métodos de explicación y umbrales de seguridad antes de recomendar acciones.




Figura 1: Representación gráfica de una red neuronal.

2.4 Esquema general del perceptrón.

2.4.1 Definición y formulación

A continuación, veremos la forma simple de la red neuronal para aprender sus bases y poder interpretar mejor aun su forma de ejecutar. Para esto comenzaremos con el perceptrón que es la unidad fundamental. Recibe un conjunto de entradas $\{x_1, x_2, \dots, x_n\}$, las combina mediante una suma ponderada con pesos $\{w_1, w_2, \dots, w_n\}$ agrega un sesgo b , y aplica una función de activación $\sigma(\cdot)$ (Raschka, 2015).

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

$$\hat{y} = \sigma(z) \quad (2)$$

donde:

X_i : variables de entrada (ej. tensiones, frecuencias, potencias SCADA/sincrofasores),

W_i : pesos que ajustan la importancia relativa de cada variable,

b : sesgo que permite desplazar la frontera de decisión,

$\sigma(\cdot)$: función de activación (ReLU, sigmoide, tanh, lineal).

En redes profundas, esta operación se repite capa por capa, permitiendo modelar relaciones no lineales complejas entre los estados eléctricos y las acciones de control.

2.4.2 Entradas y muestreo

Las entradas x provienen de SCADA: tensiones $|V|$, corrientes $|I|$, potencias P/Q , estados binarios (interruptores, alarmas), temperatura de equipos y variables de contexto. Se

normalizan (per-unit) y se codifican los estados/topología. Con períodos de muestreo típicos mayores a 2 s, el perceptrón opera en régimen cuasi-estacionario, adecuado para pronóstico y diagnóstico del módulo estático (Raschka, 2015).

2.4.3 Componentes principales

- Pesos (w): valores ajustables que cuantifican la relevancia de cada rasgo; se actualizan durante el entrenamiento.
- Sesgo (b): término adicional que desplaza la frontera de decisión y mejora la capacidad de ajuste.
- Suma ponderada: cálculo de $z = w^T x + b$ que integra entradas y sesgo.
- Función de activación (σ): introduce no linealidad; ReLU en capas internas, sigmoide/softmax para probabilidades.
- Salida ($\hat{y}$): valor predicho (continuo o probabilidad), que puede umbralizarse para tomar decisiones operativas.

2.4.4 Entrenamiento

El entrenamiento ajusta $\{w, b\}$ para minimizar una función de pérdida entre predicciones y valores reales mediante retropropagación y optimizadores (descenso de gradiente, Adam) (Raschka, 2015).

2.4.5 Limitaciones y extensión

Un perceptrón simple sólo separa clases linealmente separables. Para capturar la no linealidad del sistema eléctrico y su topología, se apilan múltiples perceptrones en capas (MLP/DNN) y se integran con modelos secuenciales o sobre grafos según la señal (SCADA/PMU) (Raschka, 2015).




Figura 2: Esquema red neuronal.

2.5 Desarrollo del Aprendizaje por Refuerzo Profundo (DRL) en la Red Eléctrica

A diferencia de los modelos supervisados que aprenden de etiquetas históricas, el Aprendizaje por Refuerzo Profundo (DRL) permite sintetizar políticas de maniobra mediante la interacción directa con un entorno simulado. En el presente trabajo, el aprendizaje por refuerzo profundo se introduce como una extensión conceptual de la arquitectura

propuesta. Si bien el caso de estudio desarrollado se basa en modelos supervisados para ilustrar la lógica de decisión, el enfoque de aprendizaje por refuerzo se presenta como una línea futura orientada a la automatización de políticas de maniobra en entornos simulados del sistema eléctrico.

En este contexto, el problema de la operación se formaliza como un Proceso de Decisión de Markov (MDP), definido por la tupla (S, A, P, R) (Sutton & Barto, 2018):

Espacio de Estados (S): Representa la conciencia situacional instantánea capturada por SCADA y PMU. Incluye el vector de tensiones por barra (V_i), ángulos fasoriales (θ_i), frecuencias (f_i) y estados lógicos de los interruptores.

Espacio de Acciones (A): Define las operaciones discretas y continuas que el agente puede ejecutar. Estas incluyen la conexión/desconexión de generadores (ON/OFF), el cambio de taps en transformadores y la maniobra de bancos de capacitores o reactores.

Función de Recompensa (R): Es el mecanismo crítico de entrenamiento que guía al agente hacia una operación segura. Se define para penalizar las violaciones de los criterios operativos de la red. En particular, se aplican penalizaciones severas cuando la tensión excede los rangos permitidos, mientras que se otorgan recompensas positivas cuando el sistema se mantiene estable con mínimas pérdidas.

2.5.1 Algoritmos y entrenamiento

Para la arquitectura propuesta, se consideran algoritmos como Proximal Policy Optimization (PPO) o Deep Deterministic Policy Gradient (DDPG) debido a su capacidad para manejar espacios de acciones continuos y garantizar una convergencia estable. El entrenamiento se realiza en paralelo con un estimador de estados o simulador matemático, donde la red aprende todas las combinaciones posibles antes de ser validada por el operador humano en el bucle (Glavić, 2019).

Este enfoque permite que, en etapas futuras, la IA pueda proponer políticas de maniobra para configuraciones de red no previstas explícitamente en la experiencia operativa, reforzando la resiliencia ante contingencias complejas o eventos de clima extremo.




Figura 3: Esquema básico de aprendizaje por refuerzo (Agente, acción, ambiente y recompensa).

3- Caso de Estudio.

3.1 Arquitectura propuesta para la operación.

En esta sección se presenta un caso de estudio simplificado con el objetivo de ilustrar el funcionamiento de la arquitectura propuesta. El sistema analizado corresponde a una red radial de tres barras, seleccionada por su capacidad para representar de manera controlada las interacciones fundamentales entre tensión, demanda, generación y flujo de potencia. Si bien se trata de un esquema reducido, permite evaluar la lógica de decisión de la inteligencia artificial en escenarios operativos típicos, tales como condiciones de baja demanda, caídas de tensión y sobrecargas de línea. Este enfoque tiene carácter demostrativo y constituye una primera aproximación al problema, previa a su extensión a sistemas de mayor escala.

3.1.1 Escenario y configuración inicial

Elemento	Parámetro	Valor
Red	Tipo de configuración	Radial (3 barras)
Barra 1	Tipo	Swing (Slack Bus)
Línea 1-2	Longitud Impedancia	15 km (aprox) $0.12 + j0.40 \Omega/\text{km}$
Línea 2-3	Longitud Impedancia	30 km (aprox) $0.12 + j0.40 \Omega/\text{km}$
Generador G1	Ubicación	Barra 3
	Despacho mínimo técnico	35 MW
	Rango operativo	35 – 50 MW
Límite térmico	Corriente máxima (Línea 1-2)	400 A
Demanda base	Barra 2	15 MW / 5 Mvar
	Barra 3	25 MW / 10 Mvar
Demanda máxima	Barra 3	60 MW / 20 Mvar

Tabla 2: Parametros para el escenario de estudio.

Implementándolo a nuestra propuesta, visualizaremos una red neuronal aplicada sobre un esquema unifilar simple de solo tres barras y la configuración que se explica en la Figura 4.




Figura 4: Configuración inicial.

Tenemos las tres barras con sus respectivos valores de tensión, la corriente de línea 1-2, los valores de potencia activa y reactiva de las demandas, y el generador G1 con su interruptor abierto para configuración inicial (Stevenson, 1979).

3.1.2 Esquema de la red neuronal para G1

En la Figura 5 se muestra el esquema de la red neuronal. Las entradas V_1 , V_2 y V_3 corresponden a las tensiones de cada barra. La salida obtiene los dos posibles estados del G1 (generador): G1-OFF (fuera de servicio) y G1-ON (mínimo técnico). Dependiendo del tipo de generador y las condiciones de despacho podrían existir más estados de salida; aquí se emplean estos tres para simplificar.




Figura 5: Red neuronal para G1. Las capas ocultas pueden variar; no se especifican en el dibujo.

3.1.3 Caso 1 — Baja demanda y tensiones cercanas al nominal: salida G1-OFF

Comenzaremos con el primer caso en donde el sistema se encuentra con bajos niveles de demanda y la tensión en la barra 3 se mantiene muy cerca de los valores nominales. La red neuronal entrenada con eventos históricos, interpretará que para esos valores que no es necesario despachar generación. Los valores históricos son resultado de meses de operación real, donde operadores de centros de control en maniobras habituales evitarían despachar la máquina para un escenario de este tipo.

3.1.4 Caso 2 — Tensiones bajas: salida G1-ON y uso de curva de capacidad

En la Figura 6 se observa que la demanda aumentó y los niveles de tensión se ubican por debajo de la banda admisible $132 \text{ kV} \pm 5\%$ (de 125.4 a 138.6 kV). En base a su entrenamiento,

la red interpreta que debe despachar el G1 para mejorar los perfiles de tensión. La red emite G1-ON para despachar la mínima potencia activa y aprovechar la curva de capacidad (Figura 7) (Stevenson, 1979; PowerWorld Corporation, s.f.; CAMMESA, s.f., Anexo 16).




Figura 6: Caso 2 — Red con bajas tensiones (PowerWorld Corporation, s.f.).




Figura 7: Caso 2 — G1 despachado; perfiles de tensión nominales.

3.1.5 Caso 3 — Sobrecarga por corriente de línea: coordinación con segunda red

Para el último caso, el de la figura 8, necesitaremos incorporar otra red neuronal. Una que para valores de entrada tenga las corrientes de línea. Estas determinarán los límites de los equipos. Dependiendo de cada equipo los límites podrían ser varios. Para nuestro caso el límite será un TI de 400 A (PowerWorld Corporation, s.f.; Stevenson, 1979).




Figura 8: Caso 3 — Escenario de alta demanda con sobrecarga de un TI de 400 A (423 A).

Al sobrepasar el valor, la red resuelve que tiene que completar al G1. Aportando potencia activa, descarga el TI de la línea 1-2, llevando este a un valor menor y admisible de 299 A (PowerWorld Corporation, s.f.; Stevenson, 1979).




Figura 9: Caso 3 — Escenario sin sobrecargas y tensiones nominales.

3.1.6 Recomendación operativa

La figura 9 nos muestra la resolución de la red neuronal, despachando el G1 completo (el estado completo corresponde a un ON en la red neuronal de corrientes Vs Generador). Se recomienda que ambas redes neuronales para un caso como este, trabajen en conjunto (PowerWorld Corporation, s.f.; Stevenson, 1979).

3.2 Modelo simple de operación en python.

A continuación, veremos un ejemplo similar al caso 2, un caso simple con una red neuronal para demostrar lo antes propuesto. Obtenemos los valores del comportamiento de una pequeña red. Estos valores, nos servirán para entrenarla, cuanto más tengamos, con más precisión podremos hacer la predicción. Las tensiones de tres barras son el valor de entrada y el estado del generador los valores de salida.

3.2.1 Librerías

Empezaremos importando las bibliotecas necesarias, como NumPy para manipulación de matrices, TensorFlow y Keras para construir y entrenar la red neuronal, y scikit-learn para dividir y normalizar los datos (Google, s.f.; Python Software Foundation, s.f.).

```
import numpy as np
import tensorflow as tf
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
```

3.2.2 Datos de entrada y etiquetas

Se definen los datos de entrada (datos_entrada) y las etiquetas de salida (etiquetas_salida). Los datos son matrices donde cada fila representa una muestra y cada columna representa una característica (Google, s.f.; PowerWorld Corporation, s.f.; Raschka, 2015; Python Software Foundation, s.f.).

```
# Datos de entrenamiento
datos_entrada = np.array([
    [132, 132, 132],
    [140, 140, 140],
    [130, 125, 124],
    [130, 124, 122],
    [128, 122, 117],
    [130, 130, 129],
    [131, 131, 131],
    [130, 130, 130],
    [120, 120, 120],
    [129, 125, 122],
    [130, 128, 127],
    [142, 142, 142],
])

# Etiquetas de salida (0: OFF, 1: ON)
etiquetas_salida = np.array([0, 0, 1, 1, 0, 0, 0, 0, 1, 1, 0, 0])
```

3.2.3 División en entrenamiento y prueba

Se dividen los datos en conjuntos de entrenamiento y prueba utilizando `train_test_split` de `scikit-learn` (Google, s.f.; PowerWorld Corporation, s.f.; Raschka, 2015; Python Software Foundation, s.f.).

```
# Dividir los datos en conjuntos de entrenamiento y prueba
X_train, X_test, y_train, y_test = train_test_split(datos_entrada,
    etiquetas_salida, test_size=0.2, random_state=42)
```

3.2.4 Normalización

Se utiliza `StandardScaler` de `scikit-learn` para normalizar los datos. La normalización es importante para que todas las características tengan una escala similar (Google, s.f.; PowerWorld Corporation, s.f.; Raschka, 2015; Python Software Foundation, s.f.).

```
# Normalizar los datos
scaler = StandardScaler()
X_train = scaler.fit_transform(X_train)
X_test = scaler.transform(X_test)
```

3.2.5 Construcción del modelo

Se construye el modelo de red neuronal utilizando `Keras`. El modelo tiene dos capas ocultas con funciones de activación `ReLU` y una capa de salida con función de activación `sigmoid` para clasificación binaria (Google, s.f.; PowerWorld Corporation, s.f.; Python Software Foundation, s.f.).

```
# Construir el modelo de red neuronal
model = tf.keras.Sequential([
    tf.keras.layers.Dense(64, activation='relu', input_shape=(3,)),
    tf.keras.layers.Dense(32, activation='relu'),
    tf.keras.layers.Dense(1, activation='sigmoid') # Capa de salida con
    activación sigmoid para clasificación binaria
])
```

3.2.6 Compilación

Se compila el modelo especificando el optimizador, la función de pérdida (binary_crossentropy para clasificación binaria) y la métrica a seguir durante el entrenamiento (precisión en este caso) (Google, s.f.; PowerWorld Corporation, s.f.; Raschka, 2015).

```
# Compilar el modelo
model.compile(optimizer='adam', loss='binary_crossentropy',
    metrics=['accuracy'])
```

Se entrena el modelo en los datos de entrenamiento durante 50 épocas con un tamaño de lote de 32. Se utiliza la validación en los datos de prueba para monitorear el rendimiento durante el entrenamiento.

3.2.7 Entrenamiento

```
# Entrenar el modelo
model.fit(X_train, y_train, epochs=50, batch_size=32, validation_data=(X_
    test, y_test))
```

Se utilizan los nuevos datos (en este caso, un solo conjunto de datos) para hacer predicciones. Los datos se normalizan antes de pasarlos al modelo (Google, s.f.; PowerWorld Corporation, s.f.; Raschka, 2015).

```
# Hacer predicciones para nuevos datos
nuevos_datos = np.array([[132, 132, 132]])
nuevos_datos_normalizados = scaler.transform(nuevos_datos)
prediccion = model.predict(nuevos_datos_normalizados)
```

Se asigna una etiqueta ("OFF" o "ON") según la probabilidad predicha. En este caso, si la probabilidad es menor que 0.5, se clasifica como "OFF", de lo contrario, se clasifica como "ON" (Google, s.f.; PowerWorld Corporation, s.f.; Python Software Foundation, s.f.).

```
# Convertir el resultado a la etiqueta predicha
etiqueta_predicha = "OFF" if prediccion < 0.5 else "ON"
```

Se imprimen las probabilidades de predicción y la etiqueta predicha para los nuevos datos (Python Software Foundation, s.f.).

```
print(f'Probabilidades de predicción: {prediccion}, Etiqueta predicha:  
{etiqueta_predicha}')
```

```
1/1 [=====] - 0s 29ms/step
```

```
Probabilidades de predicción: [[0.32143956]], Etiqueta predicha: OFF
```

3.3 Red neuronal con datos de sincrofasores

3.3.1 Definición y propósito

Un PMU (Phasor Measurement Unit) instalado en cada barra es capaz de entregar múltiples variables en tiempo casi real (30–120 muestras por segundo), todas ellas sincronizadas mediante GPS. Entre las magnitudes típicamente disponibles se incluyen:

- Tensión (V): magnitud y ángulo fasorial por fase.
- Corriente (I): magnitud y ángulo fasorial en cada salida.
- Frecuencia (f): frecuencia instantánea de la barra.
- ROCOF (Rate of Change of Frequency): derivada temporal de la frecuencia.
- Potencia activa y reactiva (P, Q): estimadas a partir de los fasores de tensión y corriente.
- Calidad de señal y marcas de tiempo: información de validación y sincronización GPS.

Esto implica que las entradas de un PMU son mucho más ricas que las de un sistema SCADA convencional y permiten construir vectores de entrada de gran dimensionalidad (Phadke & Thorp, 2008).

3.3.2 Metodología de prueba

Para ilustrar la lógica de control del generador en función de las condiciones de la red, se elaboró un ejemplo simplificado utilizando únicamente tres variables por barra:

Magnitud de tensión $|V|$ (pu).

Ángulo de tensión θ (°).

Frecuencia local f (Hz).

De esta forma, el vector de entrada quedó definido por nueve variables:

$[V1, \theta1, f1, V2, \theta2, f2, V3, \theta3, f3]$

La salida corresponde al estado del generador en el extremo de la red, codificado en forma binaria: 0 (OFF) o 1 (ON).

3.3.3 Datos de entrenamiento

En el siguiente bloque de código se muestran cinco escenarios de operación, representados por las tensiones, ángulos y frecuencias medidas en las tres barras mediante sincrofasores, junto con la etiqueta correspondiente al estado del generador:

```
# === Datos de entrada (ejemplo con 5 muestras) ===
# Formato: [V1, θ1, f1, V2, θ2, f2, V3, θ3, f3]
datos_entrada = np.array([
    [1.02, 5.0, 50.1, 1.00, 2.0, 50.1, 0.98, -1.5, 50.1], # Caso 1
    [0.97, -10.0, 49.8, 1.03, 4.0, 49.8, 1.04, 6.0, 49.8], # Caso 2
    [1.01, 3.0, 50.0, 1.02, 5.0, 50.0, 0.99, 0.5, 50.0], # Caso 3
    [1.05, 7.0, 50.3, 1.01, 2.5, 50.3, 1.00, 1.0, 50.3], # Caso 4
    [0.95, -12.0, 49.7, 1.01, 3.0, 49.7, 1.03, 5.0, 49.7], # Caso 5
])

# === Etiquetas de salida ===
# 0 = Generador OFF, 1 = Generador Carga Base
```

3.3.4 Interpretación de resultados

Este esquema simplificado muestra cómo, a partir de pequeñas variaciones en las magnitudes de tensión y frecuencia registradas por los PMU, el modelo es capaz de recomendar la conexión o desconexión del generador. En particular, situaciones de baja tensión o frecuencia comprometida producen salidas que activan el estado mínimo del generador, lo que resulta consistente con criterios de operación real.

3.3.5 Extensión a escenarios complejos

Si bien en este ejemplo se restringieron las entradas a un conjunto reducido de variables, en aplicaciones reales se pueden incorporar todos los datos disponibles de los PMU. La utilización de sincrofasores, con su mayor frecuencia de muestreo respecto de SCADA, garantiza que el sistema pueda procesar gran cantidad de datos en tiempo real, permitiendo a la red neuronal anticipar situaciones de inestabilidad y emitir recomendaciones operativas robustas para contribuir a la estabilidad global del sistema de potencia (Phadke & Thorp, 2008).

4 - Resultados

4.1 Evaluación y Análisis de Sensibilidad

4.1.1 Definición y propósito

La evaluación de sensibilidad busca analizar el comportamiento de la red neuronal frente a variaciones de tensión y condiciones simplificadas del sistema. El objetivo es comprender cómo el modelo aproxima decisiones operativas en escenarios reducidos, antes de su extensión a entornos reales con múltiples variables y restricciones (Raschka, 2015).

4.1.2 Metodología de prueba

Se realizaron 10 corridas independientes del modelo propuesto, variando los valores de tensión en tres barras principales. Cada escenario representa un estado distinto del mismo sistema, lo que permite verificar la robustez del algoritmo bajo diferentes condiciones de entrada (Raschka, 2015).

4.1.3 Resultados del sistema estático

En la primera corrida, las tensiones se mantuvieron en valores nominales, obteniéndose una probabilidad de predicción de 0.2427. Este valor, al ser cercano a 0, indicó correctamente el estado OFF del generador.

En contraste, en la prueba n.º 5, los valores de tensión (126 kV en barras 1 y 2, y 127 kV en barra 3) arrojaron una probabilidad de 0.5747, lo que superó el umbral de 0.5 y condujo a la decisión de ON (mínimo técnico o Carga base según preferencias de configuración). Esto coincide con la necesidad operativa de despachar un generador para mejorar el perfil de tensiones (Raschka, 2015).

4.1.4 Interpretación de resultados

Los resultados muestran que la red neuronal es capaz de replicar decisiones coherentes con la operación real incluso bajo un esquema simplificado. La relación entre valores de tensión y probabilidad de salida permite validar la lógica del modelo y su adecuación para tareas de predicción binaria (OFF/ON) (Raschka, 2015).

4.1.5 Extensión a escenarios complejos

Este ejemplo constituye una primera validación. La extensión natural del enfoque incluye incorporar:

Tensiones, corrientes y potencias activas/reactivas de todas las barras.

Estados binarios de interruptores y equipos.

Variables ambientales y climáticas.

Condiciones topológicas dinámicas.

Con estas entradas adicionales, la red neuronal podrá tomar decisiones más complejas, integrando de manera no lineal las interacciones del sistema eléctrico y ofreciendo una herramienta predictiva de mayor utilidad operativa.

N.º de Prueba	Tensión Barra 1 (kV)	Tensión Barra 2 (kV)	Tensión Barra 3 (kV)	Probabilidad de la predicción	Predicción del Generador
1	132	132	132	0.2427	OFF
2	138	138	138	0.0704	OFF
3	142	143	144	0.0206	OFF
4	128	129	128	0.4308	OFF
5	126	126	127	0.5747	ON
6	129	128	125	0.5027	ON
7	125	124	122	0.6871	ON
8	122	123	121	0.7485	ON
9	115	116	114	0.9074	ON
10	110	110	109	0.9614	ON

Tabla 3: predicciones

5 - Discusión

5.1 Esquema general de redes neuronales.

5.1.1 Enfoque integral de la red

Considerar al sistema eléctrico como una entidad integral permite avanzar hacia un marco conceptual donde las redes neuronales se organizan en bloques funcionales. Cada bloque aborda la resolución de un problema específico pero convergente: la decisión de activar o no un generador, subir o bajar el tap de un transformador, entrar o sacar un banco de capacitores, etc. Este enfoque no se limita a la evaluación de tensiones nodales, o variables de un sistema de potencia, sino que incorpora variables adicionales tales como criterios de despacho económico, temperatura regional asociada a condiciones climáticas, capacidad y disponibilidad de combustible, así como la presencia de eventos meteorológicos adversos.

5.1.2 Bloques neuronales en paralelo

Una primera estrategia consiste en organizar el sistema mediante subredes neuronales en paralelo, cada una dedicada a un conjunto específico de variables. Las salidas de estas subredes convergen en una red de mayor jerarquía, que cumple la función de supervisor y coordinador, integrando las predicciones de manera coherente para establecer la necesidad de incorporar un generador al servicio (para nuestro ejemplo) (Chen, 2015).

El paralelismo ofrece ventajas claras:

Facilidad de entrenamiento: cada subred aprende un problema acotado, reduciendo tiempos de cómputo y la complejidad del ajuste.

Modularidad: permite reentrenar o reemplazar una subred sin alterar el sistema completo.

Robustez: la falla de una subred no compromete el desempeño global.

Sin embargo, la integración de resultados puede generar inconsistencias y requiere un bloque supervisor sofisticado.




Figura 10: Esquema de red en paralelo.

5.1.3 Red neuronal única multivariable

En contraposición, una segunda estrategia consiste en diseñar una red única multivariable, que recibe de manera simultánea todas las entradas relevantes del sistema eléctrico. Esta arquitectura, potenciada por las capacidades de cómputo actuales (GPU, TPU y clusters en la nube), resulta más poderosa para capturar interacciones complejas entre variables heterogéneas (Chen, 2015).

Sus beneficios incluyen:

Mayor capacidad predictiva: al considerar correlaciones globales entre tensión, corriente, clima, costos y disponibilidad de equipos.

Eficiencia en operación: un único modelo genera salidas consistentes sin necesidad de integración posterior.

No obstante, presenta desafíos significativos:

Entrenamiento complejo: demanda grandes volúmenes de datos de calidad.

Mantenimiento más costoso: la modificación de una variable obliga al reentrenamiento de toda la red.

Menor explicabilidad: resulta más difícil interpretar la contribución individual de cada variable (Chen, 2015).




Figura 11: Esquema de red multivariable

5.1.4 Comparación y proyección hacia arquitecturas híbridas

La elección entre arquitecturas paralelas o multivariables depende del balance entre potencia predictiva, facilidad de entrenamiento y capacidad de mantenimiento. En 2025, la tendencia tecnológica apunta hacia enfoques híbridos, donde subredes especializadas procesan subconjuntos de información heterogénea, y sus representaciones intermedias se integran en un bloque central unificador basado en arquitecturas profundas o transformadores multimodales (Chen, 2015).

Este esquema híbrido busca:

- Preservar la modularidad y explicabilidad del enfoque paralelo.
- Incorporar la potencia de correlación y generalización del enfoque multivariable.

Arquitectura	Ventajas	Desventajas
Paralela (subredes especializadas)	- Modularidad y fácil mantenimiento. - Entrenamiento más rápido. - Falla local no compromete todo.	- Integración de salidas compleja. - Posibles inconsistencias.
Única multivariable	- Mayor capacidad predictiva. - Captura correlaciones globales. - Modelo único consistente.	- Necesita más datos. - Entrenamiento complejo. - Difícil mantenimiento.
Híbrida (paralelo + multivariable)	- Combina modularidad y potencia. - Preserva explicabilidad. - Tendencia tecnológica 2025.	- Mayor complejidad de diseño. - Requiere integración arquitectónica compleja.

Tabla 4: Arquitecturas de redes neuronales.

5.1.5 Extensión a otros equipos del sistema

La metodología propuesta, como habíamos mencionado tiene aplicaciones inmediatas que incluyen la regulación de taps en transformadores de potencia, la maniobra de reactores y la optimización del uso de bancos de capacitores, entre otros. En todos los casos, las decisiones se guían por probabilidades inferidas a partir de datos históricos, lo que permite una operación más confiable y eficiente del sistema (Chen, 2015).

5.1.6 Naturaleza estática y etapa inicial

En la fase inicial de implementación, el sistema operará de manera estática, replicando patrones aprendidos sin adaptación en línea. Las recomendaciones se presentarán como salidas explícitas para el operador en tiempo real, sin actuación directa sobre los equipos. Esta modalidad constituye un paso intermedio entre la automatización asistida y la futura operación autónoma, garantizando trazabilidad y confianza (Chen, 2015).

5.1.7 Proyección hacia sistemas de apoyo al operador

El marco metodológico aquí planteado sienta las bases para un sistema inteligente de soporte a la operación en tiempo real, escalable hacia arquitecturas con mayor autonomía. La convergencia de subredes especializadas, redes multivariadas y bloques híbridos de coordinación permitirá avanzar hacia un sistema capaz de integrar operación estática y dinámica, con un nivel creciente de automatización, resiliencia y confiabilidad (Chen, 2015).

5.2 Análisis Comparativo: IA vs. Operación Convencional

La principal ventaja de la arquitectura propuesta radica en su capacidad para mitigar las limitaciones cognitivas del ser humano ante el volumen y la heterogeneidad de las señales operativas. Mientras que en un centro de control real el operador debe procesar datos SCADA con latencias de segundos para tomar decisiones bajo presión, la inteligencia artificial analiza simultáneamente tensiones, corrientes y estados lógicos, proponiendo maniobras de despacho en milisegundos. La incorporación de sincrofasores (PMU) es determinante en esta comparativa, ya que permite comprender la dinámica rápida de la red con una resolución temporal superior al SCADA tradicional. Este enfoque no solo reduce los tiempos de respuesta ante contingencias, sino que sienta las bases para el futuro de los esquemas de

protección de grandes áreas y la estabilidad dinámica del SADI. De esta manera, se evoluciona hacia una gobernanza de datos proactiva que no sustituye el criterio humano, sino que amplía su alcance ante fenómenos que escapan a la intuición operativa.

5.3 Escalabilidad y Proyección al SADI

La aplicación de esta arquitectura al Sistema Argentino de Interconexión (SADI) implica gestionar una red de gran escala con miles de nodos. Ante la preocupación por el incremento del costo computacional, se proponen estrategias basadas en la modularidad y la eficiencia de las Redes Neuronales Profundas (DNN):

5.3.1 Arquitectura de Bloques Neuronales por Jurisdicción y Control Regional

Para abordar la complejidad del SADI sin alterar su esquema de mando actual, se propone que la arquitectura de bloques neuronales en paralelo se mimetice con la estructura organizativa de la red eléctrica nacional. En lugar de centralizar el procesamiento en un único núcleo, la IA se despliega de forma distribuida, respetando las fronteras operativas de los Centros de Control de Área (COT) y los centros de transporte: Integración en Centros de Control Regionales: Cada región operativa (ej. Comahue, GBA, Litoral, NOA) incorpora su propio bloque neuronal especializado. Esta red regional se entrena exclusivamente con las variables locales de su jurisdicción —nodos, niveles de tensión específicos (500 kV, 220 kV, 132 kV) y equipamiento propio—, permitiendo que la IA se convierta en un experto local de su área de influencia. Respeto a la Jerarquía Operativa: El esquema propuesto mantiene la subordinación técnica actual. Los bloques neuronales regionales actúan como soporte a la decisión para los operadores de cada área, mientras que sus salidas (predicciones de estado, márgenes de reserva o recomendaciones de maniobra) convergen hacia una red neuronal de jerarquía superior ubicada en el centro de control nacional (CMMESA, s.f.). Modularidad por Niveles de Tensión: La arquitectura permite subdividir el aprendizaje no solo geográficamente, sino por niveles de tensión. Esto facilita que las redes dedicadas a la red de 500 kV operen con criterios de estabilidad interárea, mientras que las redes regionales de 132 kV se enfoquen en perfiles de tensión locales y distribución de demanda. Seguridad y Autonomía Jurisdiccional: Al operar de forma paralela, una falla en el procesamiento de datos de un centro regional no compromete la supervisión de las demás áreas. Esta compartimentación asegura que cada transportista o agente mantenga la gobernanza sobre sus datos y activos, entregando al supervisor nacional únicamente la información procesada necesaria para la coordinación global del sistema.

5.3.2 Aceleración mediante Hardware y Computación de Alto Rendimiento

La capacidad de procesamiento actual, mediante el uso de GPU, TPU y clusters en la nube, permite capturar interacciones complejas entre variables heterogéneas de manera simultánea.

Inferencia en Tiempo Real: Mientras que el entrenamiento es un proceso intensivo que ocurre offline, la inferencia (generación de la recomendación operativa) se realiza en milisegundos.

Gestión de Datos PMU: Esto asegura que la latencia se mantenga en rangos operativos, permitiendo al sistema procesar el volumen masivo de señales provenientes de múltiples PMU y actuar de forma proactiva ante oscilaciones transitorias.

6 - Conclusión.

6. Transición hacia una operación eléctrica gobernada por datos.

La red eléctrica ya no es sólo un mosaico de equipos: es un sistema vivo cuyo pulso podemos leer y anticipar. Este trabajo delineó una arquitectura donde redes profundas aprenden de SCADA y PMU, y convierten datos en conciencia situacional y acciones confiables, manteniendo siempre al operador en el bucle. Así, la operación evoluciona desde la reacción hacia un control proactivo y coordinado, capaz de amortiguar contingencias y sostener la estabilidad dinámica.

Mirando adelante, la red de transmisión se perfila como un organismo cognitivo: IA que ensayan maniobras antes de ejecutarlas; políticas aprendidas que dialogan con clima, demanda y generación distribuida; decisiones que fluyen para una operación completa. No se trata de sustituir criterio humano, sino de ampliar su alcance, llevando la mirada del operador a milisegundos y kilómetros que hoy escapan a la intuición.

Este es el horizonte: una red masivamente controlada, auditable y resiliente, capaz de integrar nuevas fuentes y electrificar más usos sin renunciar a la calidad. La inteligencia artificial no es un fin; es la coreografía que alinea física, datos y experiencia para que la electricidad llegue —segura, eficiente y a tiempo— a un futuro que ya comenzó.

7 - Referencias.

- CAMMESA. (s.f.). Los Procedimientos Versión XXXIV. Procedimientos para la programación de la operación, el despacho de cargas y el cálculo de precios. Recuperado el 1 de noviembre de 2023 de <https://microfe.cammesa.com/static-content/CammesaWeb/download-manager-files/Los%20Procedimientos/Los%20Procedimientos%20XXXIV.pdf>
- Chen, K. (2015). Deep and Modular Neural Networks. In: Kacprzyk, J., Pedrycz, W. (eds) Springer Handbook of Computational Intelligence. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-662-43505-2_28
- Glavić, M. (2019). (Deep) reinforcement learning for electric power system control and related problems: A short review and perspectives. *Annual Reviews in Control*, 48, 22–35. <https://doi.org/10.1016/j.arcontrol.2019.09.008>
- Google. (s.f.). Google Colaboratory (Colab): Servicio gratuito de nube para aprendizaje automático e inteligencia artificial. Recuperado el 1 de noviembre de 2023 de <https://colab.google/>
- Phadke, A. G., & Thorp, J. S. (2008). Synchronized phasor measurements and their applications. Springer, New York. <https://doi.org/10.1007/978-0-387-76537-2>
- PowerWorld Corporation. (s.f.). PowerWorld Simulator: Software de simulación de sistemas de energía eléctrica. Recuperado el 1 de noviembre de 2023 de <https://www.powerworld.com/>
- Python Software Foundation. (s.f.). Python Software. Recuperado el 1 de noviembre de 2023 de <https://www.python.org/>
- Radvanovsky, R., & Brodsky, J. (2016). Handbook of SCADA/control systems security (2nd ed.). CRC Press. Recuperado el 3 de diciembre de 2023.
- Raschka, S. (2015). Python machine learning. Packt Publishing Ltd., Birmingham, UK. Recuperado el 3 de diciembre de 2023 de https://www.academia.edu/29079919/Python_Machine_Learning
- Stevenson, W. D. Jr. (1979). Análisis de sistemas eléctricos de potencia (2.^a ed.). Libros McGraw-Hill de México. Recuperado el 1 de noviembre de 2023 de <https://jvasconcellos.com.br/wp-content/uploads/2020/06/Analisis-de-sistemas-electricos-de-potencia.pdf>
- Sutton, R. S., & Barto, A. G. (2018). Reinforcement learning: An introduction (2nd ed.). MIT Press. Recuperado el 1 de noviembre de 2023 de <https://incompleteideas.net/book/the-book-2nd.html>

Nombres y Apellidos del autor	Colaboración Académica													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
Romero Beneitez Facundo Cruz	x	x	x	x	x	x	x	x	x	x	x	x	x	x

1-Administración del proyecto, 2-Adquisición de fondos, 3-Análisis formal, 4-Conceptualización, 5-Curaduría de datos, 6-Escritura - revisión y edición, 7-Investigación, 8-Metodología, 9-Recursos, 10-Redacción - borrador original, 11-Software, 12-Supervisión, 13-Validación, 14-Visualización.+