

Copiloto Multiagente Basado en LLMs para la Gestión Inteligente del Sistema Argentino de Interconexión (SADI) bajo Alta Penetración Renovable

LLM-Based Multi-Agent Copilot for Intelligent Management of Argentina's Interconnection System (SADI) under High Renewable Penetration

Presentación: 07/05/2026

Matias Gerard

Research Institute for Signals, Systems and Computational Intelligence sinc(i), FICH-UNL, CONICET, Santa Fe, Argentina
mgerard@sinc.unl.edu.ar

Guillermo A. Magallán

Facultad de Ingeniería - Universidad Nacional de Río Cuarto, FI-UNRC, Río Cuarto, Argentina
gmagallan@ing.unrc.edu.ar

Iván Peralta

Facultad de Ingeniería - Universidad Nacional de Entre Ríos, FI-UNER, Paraná, Argentina
ivan.peralta@uner.edu.ar

Hugo Leonardo Rufiner

Research Institute for Signals, Systems and Computational Intelligence sinc(i), FICH-UNL, CONICET, Santa Fe, Argentina
lrufiner@sinc.unl.edu.ar

Resumen

La creciente penetración de energías renovables en el Sistema Argentino de Interconexión (SADI) introduce desafíos operativos que exceden las capacidades de los enfoques tradicionales de gestión. En este trabajo se propone un sistema multiagente inteligente denominado *Copiloto CAMMESA*, basado en Large Language Models (LLMs), para asistir a los operadores en la gestión del SADI. La arquitectura multiagente combina agentes especializados en detección de violaciones, planificación de acciones correctivas, validación física en entorno *sandbox*, así como generación de explicaciones en lenguaje natural. El modelado de la red física está basado en el framework Grid2Op como front-end y Panda Power como back-end. El sistema fue validado experimentalmente en *l2rpn_case14_sandbox*, red estándar IEEE de 14 buses que permite comparaciones con la literatura. Los resultados experimentales demuestran capacidad efectiva de gestión de contingencias $N - 1$, con reducción del factor de carga crítico desde 0,9565 hasta 0,9207 (mejora de 3,74 %) y aumento del margen de seguridad operativo desde 4,35 % hasta 7,93 %. El mecanismo de validación mediante *sandbox* previene acciones riesgosas, mientras que la generación de explicaciones en lenguaje natural facilita la supervisión humana. Los resultados obtenidos muestran el potencial del enfoque propuesto para la asistencia explicable a operadores en sistemas eléctricos con alta penetración renovable.

Palabras Clave: gestión energética inteligente, large language models, sistemas eléctricos de potencia, sistemas multiagente

Abstract

The increasing penetration of renewable energy in Argentina's Interconnection System (SADI) introduces operational challenges that exceed the capabilities of traditional management approaches. In this work, we propose an intelligent multi-agent system called *CAMMESA Copilot*, based on Large Language Models (LLMs) integrated with Reinforcement Learning (RL), to assist operators in managing SADI. The multi-agent architecture combines specialized agents for violation detection, corrective action planning, physical validation in *sandbox* environment, and natural language explanation generation. The physical network modeling is based on the Grid2Op framework as the front-end and Panda Power as the back-end. The system was experimentally validated on *l2rpn_case14_sandbox*, a standard IEEE 14-bus network enabling benchmarking with prior literature. Experimental results demonstrate an effective $N - 1$ contingency management capability, with a reduction in the critical loading factor from 0,9565 to 0,9207 (3,74 % improvement) and an increase in the operational safety margin from 4,35 % to 7,93 %. The *sandbox* validation mechanism prevents risky actions, while natural language explanation generation facilitates human supervision. Results show the potential of the proposed approach for explainable assistance to operators in electrical systems with high renewable penetration.

Keywords: intelligent energy management, large language models, multi-agent systems, power systems

Introducción

El Sistema Argentino de Interconexión (SADI) experimenta una transformación acelerada, impulsada por la integración masiva de energías renovables. Esta red de transmisión interconecta aproximadamente 3000 nodos mediante líneas de 500, 220 y 132 kV, operada por la Compañía Administradora del Mercado Mayorista Eléctrico (CAMMESA) como administrador y coordinador técnico del sistema. La participación renovable ha crecido exponencialmente desde menos del 2 % en 2015 hasta proyecciones que superan el 30 % para 2030 (CAMMESA, 2024), impulsada principalmente por la generación eólica patagónica y solar del Noroeste argentino. Este crecimiento, aunque ambientalmente deseable y económicamente estratégico, introduce desafíos operativos que exceden las capacidades del despacho económico tradicional optimizado para generación térmica e hidráulica (Wood et al., 2013). La naturaleza intermitente y variable de las fuentes renovables en escalas temporales de minutos a horas, combinada con las restricciones físicas de la infraestructura de transmisión existente, genera problemas complejos de gestión que requieren nuevos paradigmas de control y operación.

Los desafíos que enfrenta el SADI no son únicos en el contexto global. El 28 de abril de 2025, la Península Ibérica experimentó uno de los apagones más severos en la historia moderna de Europa, cuando falló el interconector crítico Francia-España, dejando sin electricidad a España y Portugal durante aproximadamente 10 horas y afectando brevemente el sur de Francia (ENTSO-E Expert Panel, 2025). El incidente, que desconectó 31 GW de carga y provocó al menos ocho víctimas, expuso vulnerabilidades sistémicas en la gestión de redes con alta penetración renovable. Investigaciones preliminares de la Red Europea de Gestores de Redes de Transporte de Electricidad (ENTSO-E) revelaron que la falla fue precipitada por una compleja secuencia de eventos que incluyó una insuficiente capacidad sincrónica en el sistema español, una inadecuada respuesta de los planes de defensa del sistema y limitaciones estructurales en la interconexión transfronteriza (solo 6 % de capacidad, muy por debajo del objetivo europeo del 15 %) (ENTSO-E Expert Panel, 2025; Bajo-Buenestado, 2025). Los reportes técnicos identificaron que, al momento de la falla, la generación de energía renovable era de más del 75 %, lo cual no es tan inusual en esa región; sin embargo, en ese momento, salieron de servicio muy rápidamente grandes generadores solares y el sistema contaba con muy poca generación convencional formadora de red (gas, nucleares) alrededor del 15 %. Esta generación convencional constituye los amortiguadores naturales que mantienen la estabilidad de la red ante estos cambios abruptos. La baja inercia en ese momento particular, combinada con la insuficiente capacidad de respuesta rápida de frecuencia y recursos de flexibilidad limitados (España tenía solo 25 MW de almacenamiento en baterías frente a un objetivo de 500 MW para 2025), creó condiciones en las que perturbaciones que habrían sido absorbibles en sistemas con mayor inercia desencadenaron colapsos catastróficos en cuestión de segundos (Bajo-Buenestado, 2025). Este evento subraya la urgencia de desarrollar sistemas inteligentes de gestión que puedan anticipar, prevenir y responder efectivamente a contingencias en entornos de alta variabilidad renovable.

La variabilidad impredecible de las fuentes renovables en el SADI, particularmente en la generación eólica patagónica que aporta aproximadamente 1.656 GW y la solar del NOA que aporta 119 MW, se combinan con congestiones frecuentes en la red de transmisión que resultan en una reducción de la generación energética significativa (*curtailment*), con el consecuente desperdicio de recursos limpios y pérdidas económicas (Secretaría de Energía de Argentina, 2023). Las herramientas tradicionales de Flujo de Potencia Óptimo (OPF, del inglés) enfrentan limitaciones computacionales fundamentales cuando deben considerar

múltiples escenarios de incertidumbre estocástica, típicamente requiriendo 10-30 minutos para redes de 500+ nodos, tiempos incompatibles con la gestión en tiempo cuasi-real que exigen las dinámicas aceleradas introducidas por las renovables (?). Esta brecha entre los requerimientos operativos emergentes y las capacidades de las herramientas existentes se amplifica en contextos donde las decisiones deben tomarse en ventanas temporales de segundos a pocos minutos para mantener la estabilidad del sistema ante variaciones rápidas de generación y demanda. Adicionalmente, la creciente complejidad de las redes modernas, con múltiples actores, mercados de energía dinámicos, y requisitos regulatorios estrictos, demanda soluciones que no solo sean computacionalmente eficientes sino también explicables y confiables para facilitar la supervisión humana y el cumplimiento normativo.

En este contexto, dos líneas tecnológicas han emergido como prometedoras pero con limitaciones complementarias. Por un lado, los enfoques basados en Reinforcement Learning (RL) han demostrado capacidad notable para aprender políticas complejas de control mediante interacción directa con simuladores de redes eléctricas (?Donnot et al., 2020), alcanzando tiempos de inferencia sub-segundo que los hacen viables para operación en tiempo real. Sin embargo, su naturaleza de caja negra dificulta la confianza y aceptación regulatoria en infraestructura crítica, donde la explicabilidad de las decisiones es fundamental para supervisión humana efectiva y cumplimiento de normativas de seguridad. Por otro lado, los avances recientes en Large Language Models (LLMs) han revelado capacidades extraordinarias de razonamiento simbólico, comprensión contextual profunda, y generación de explicaciones coherentes en lenguaje natural (OpenAI, 2023). La convergencia de LLMs con sistemas multiagente especializados ha emergido como un paradigma prometedor para abordar problemas complejos que requieren coordinación distribuida, adaptabilidad continua, y toma de decisiones explicable en dominios de alta complejidad (Gao et al., 2024).

Trabajos recientes han comenzado a explorar la integración de LLMs en tareas específicas de gestión de redes eléctricas con resultados iniciales alentadores. Zhang *et al.* (Zhang et al., 2025) introdujeron Grid-Agent, un framework que combina LLMs con solucionadores numéricos de flujo de potencia dentro de una arquitectura multiagente modular, demostrando la viabilidad técnica de integrar razonamiento semántico de alto nivel con precisión numérica rigurosa para detección y remediación de violaciones operativas en redes de distribución. Ji *et al.* (?) propusieron LEMAD, un sistema multiagente basado en LLMs para detección de anomalías en servicios de infraestructura crítica eléctrica, evidenciando las ventajas significativas de la colaboración distribuida entre agentes especializados con diferente expertise. En el contexto específico de sistemas de transmisión de alta tensión, GridMind (?) demostró que la integración cuidadosa de LLMs con solucionadores determinísticos permite computación científica conversacional, coordinando análisis complejos de AC OPF (*Alternating Current Optimal Power Flow*) y evaluación de contingencias $N-1$ a través de interfaces de lenguaje natural manteniendo precisión numérica comparable a herramientas tradicionales. Estos trabajos, aunque prometedores, han explorado estas tecnologías de manera relativamente aislada, sin integrar completamente las fortalezas complementarias de RL (eficiencia computacional y adaptabilidad) y LLMs (razonamiento simbólico y explicabilidad).

La técnica de Reinforcement Learning from Human Feedback (RLHF) ha emergido como una metodología transformadora para alinear modelos de lenguaje con preferencias y valores humanos mediante un proceso iterativo de entrenamiento que incorpora feedback explícito de evaluadores expertos (Ouyang et al., 2022; Christiano et al., 2017). RLHF permite incorporar sistemáticamente conocimiento experto y restricciones operativas que son difíciles o imposibles de codificar mediante funciones de recompensa numéricas tradicionales, facilitando la alineación del comportamiento del sistema con los criterios sofisticados, matizados y a menudo implícitos de operadores especializados. Estudios recientes demuestran que RLHF no solo mejora la calidad y relevancia de las respuestas generadas por LLMs, sino que además incrementa significativamente la robustez ante perturbaciones, mejora la capacidad de exploración en espacios de acción complejos, y permite transferencia de conocimiento más efectiva entre dominios relacionados (Lambert et al., 2024; Christiano et al., 2023). La integración de RLHF en el contexto específico de operación de sistemas eléctricos representa una oportunidad única para incorporar de manera sistemática y escalable el conocimiento acumulado durante décadas de experiencia operativa en Argentina, permitiendo que el sistema aprenda no solo de simulaciones numéricas sino también de las preferencias validadas, heurísticas prácticas y criterios de seguridad refinados por ingenieros especializados de CAMMESA que operan el SADI diariamente.

Este trabajo propone el *Copiloto CAMMESA*, un sistema multiagente que integra LLMs para asistencia operativa avanzada a los operadores del SADI bajo condiciones de alta penetración renovable. A diferencia de enfoques previos que utilizan estas tecnologías de forma aislada o superficialmente combinada, la arquitectura propuesta logra una integración profunda que

aprovecha las fortalezas complementarias de cada componente. El sistema comprende una arquitectura modular que incluye cinco agentes especializados con responsabilidades claramente definidas: **DetectorAgent** para identificación proactiva de violaciones operativas, **PlannerAgent** para generación de estrategias de acción correctiva basadas en razonamiento LLM, **ExecutorAgent** para simulación segura en entorno *sandbox*, **ValidatorAgent** para verificación rigurosa de factibilidad y seguridad, y **SummarizerAgent** para generación de explicaciones comprensibles en lenguaje natural que documentan exhaustivamente las decisiones tomadas y sus justificaciones técnicas. Las contribuciones principales incluyen: (i) desarrollo de una arquitectura que integra profundamente LLMs para gestión de sistemas eléctricos, (ii) demostración experimental del funcionamiento para un caso de estudio reducido, proporcionando una solución viable manteniendo explicabilidad. Este recurso puede servir así como base para investigación futura en gestión inteligente de sistemas eléctricos, particularmente en el contexto latinoamericano donde las características específicas de los sistemas nacionales requieren aproximaciones adaptadas.

Modelado y Simulación de la Red Eléctrica

Ecuaciones Fundamentales de Sistemas Eléctricos

El modelado matemático riguroso de sistemas de transmisión y distribución eléctrica se fundamenta en un conjunto bien establecido de ecuaciones algebraicas no lineales que describen el comportamiento físico de la red bajo condiciones de estado estacionario (Glover et al., 2017; Chow and Sanchez-Gasca, 2020). Sea $\mathcal{N} = \{1, 2, \dots, N\}$ el conjunto de buses o barras del sistema y $\mathcal{E} \subseteq \mathcal{N} \times \mathcal{N}$ el conjunto de líneas de transmisión que interconectan físicamente las barras, formando una topología de red típicamente mallada en sistemas de transmisión de alta tensión. Las variables de estado fundamentales en cada bus $i \in \mathcal{N}$ son la magnitud de tensión $|V_i|$ expresada en valores por unidad (p.u.) respecto a la tensión nominal del bus, y el ángulo de fase δ_i medido en radianes respecto a un bus de referencia arbitrario pero fijo, que conjuntamente definen de manera completa el fasor complejo de tensión mediante $V_i = |V_i|e^{j\delta_i}$ donde j representa la unidad imaginaria. Estas $2N$ variables de estado (magnitud y ángulo para cada bus) determinan completamente el estado operativo del sistema eléctrico bajo condiciones de régimen permanente balanceado.

Las ecuaciones de flujo de potencia (*PF*), también conocidas como ecuaciones de carga o *load flow equations*, constituyen el núcleo fundamental del modelado eléctrico y establecen el balance preciso entre generación, consumo y pérdidas en cada nodo de la red (Glover et al., 2017). Para un bus i arbitrario, las inyecciones netas de potencia activa P_i (en MW o p.u.) y reactiva Q_i (en MVar o p.u.) se expresan mediante las ecuaciones algebraicas no lineales:

$$P_i = \sum_{j=1}^N |V_i||V_j| [G_{ij} \cos(\delta_i - \delta_j) + B_{ij} \sin(\delta_i - \delta_j)] \quad (1)$$

$$Q_i = \sum_{j=1}^N |V_i||V_j| [G_{ij} \sin(\delta_i - \delta_j) - B_{ij} \cos(\delta_i - \delta_j)] \quad (2)$$

donde G_{ij} y B_{ij} representan respectivamente la conductancia (parte real) y susceptancia (parte imaginaria) del elemento ij de la matriz de admitancias nodales $\mathbf{Y}_{\text{bus}} \in \mathbb{C}^{N \times N}$, que encapsula las características topológicas y eléctricas completas del sistema. Estas ecuaciones vinculan de manera implícita las variables de estado con los flujos de potencia en la red a través de las características físicas de líneas y transformadores, manifestando la naturaleza fuertemente acoplada del problema de análisis de redes eléctricas donde cambios en un nodo pueden propagarse e influir en el estado de toda la red.

El principio físico de conservación de potencia exige que en cada bus se cumpla estrictamente el balance entre potencia generada, potencia demandada y potencia que fluye hacia o desde otros buses a través de las líneas de transmisión:

$$P_{g,i} - P_{d,i} = P_i, \quad Q_{g,i} - Q_{d,i} = Q_i \quad (3)$$

donde $P_{g,i}$ y $Q_{g,i}$ denotan las potencias activa y reactiva generadas en el bus i por máquinas sincrónicas, inversores de generación renovable, o compensadores reactivos, mientras que $P_{d,i}$ y $Q_{d,i}$ representan las demandas de potencia activa y reactiva en dicho bus, típicamente modeladas como cargas pasivas aunque sistemas modernos pueden incluir cargas activas

con capacidad de respuesta a la demanda. El término P_i calculado mediante (1) incluye implícitamente las pérdidas resistivas por transmisión en todas las líneas conectadas al nodo i , que aunque individualmente pequeñas (típicamente 1-3 % por línea) pueden acumularse significativamente en sistemas extensos.

Los límites operativos del sistema imponen restricciones adicionales fundamentales que deben satisfacerse rigurosamente para garantizar operación segura y prevenir daños a equipamiento o degradación de calidad de servicio. Las restricciones térmicas en líneas de transmisión limita la corriente máxima que puede circular, y por lo tanto, también la potencia aparente que puede fluir a través de cada conductor sin exceder temperaturas de operación segura (Chow and Sanchez-Gasca, 2020):

$$|S_{ij}| = \sqrt{P_{ij}^2 + Q_{ij}^2} \leq S_{ij}^{\text{máx}} \quad \forall (i, j) \in \mathcal{E} \quad (4)$$

donde P_{ij} y Q_{ij} representan los flujos de potencia activa y reactiva en la línea que conecta los buses i y j , calculados a partir de las tensiones y parámetros de línea, y $S_{ij}^{\text{máx}}$ denota la capacidad máxima de transmisión de potencia aparente determinada por límites térmicos del conductor, típicamente especificada por fabricantes y operadores. Adicionalmente, se imponen restricciones estrictas en las magnitudes de tensión nodales para mantener calidad de suministro aceptable y proteger equipamiento conectado contra sobre-tensiones y sub-tensiones que podrían inducir mal funcionamiento o daño permanente:

$$V_i^{\text{mín}} \leq |V_i| \leq V_i^{\text{máx}} \quad \forall i \in \mathcal{N} \quad (5)$$

donde los límites típicos en sistemas de transmisión son $V_i^{\text{mín}} = 0,95$ p.u. y $V_i^{\text{máx}} = 1,05$ p.u., aunque pueden variar según regulaciones nacionales y características específicas del sistema. Finalmente, las capacidades físicas de generadores imponen restricciones de límites de operación:

$$P_{g,i}^{\text{mín}} \leq P_{g,i} \leq P_{g,i}^{\text{máx}}, \quad Q_{g,i}^{\text{mín}} \leq Q_{g,i} \leq Q_{g,i}^{\text{máx}} \quad \forall i \in \mathcal{G} \quad (6)$$

donde $\mathcal{G} \subseteq \mathcal{N}$ denota el conjunto de buses con generación instalada, y los límites dependen de características específicas de cada tecnología de generación, incluyendo restricciones de curva de capacidad para máquinas sincrónicas y límites de inversores para generación renovable.

Framework para Simulación y Control

Grid2Op (Donnot et al., 2020) constituye un framework open-source desarrollado por RTE (Réseau de Transport d'Électricité), el operador de transmisión francés, específicamente diseñado para facilitar investigación en toma de decisiones secuencial aplicada a sistemas de potencia mediante paradigmas de aprendizaje por refuerzo. El framework adopta una perspectiva arquitectónica de alto nivel que separa mediante interfaces bien definidas la representación lógica de la red (topología, equipamiento, restricciones) de la resolución numérica computacionalmente intensiva de las ecuaciones físicas que gobiernan el sistema. Esto permite experimentar con algoritmos de control sin requerir expertise profunda en análisis de sistemas de potencia, facilita la sustitución de backends numéricos según requerimientos, y posibilita la definición de interfaces estandarizadas que promueven reproducibilidad y comparabilidad de resultados.

La arquitectura de Grid2Op se estructura en tres componentes fundamentales que interactúan mediante APIs claramente especificadas: el *Environment* que encapsula el estado completo del sistema eléctrico y gestiona su evolución temporal incluyendo cambios en demanda, generación renovable variable, y ocurrencia de contingencias; el *Backend* que asume la responsabilidad de resolver las ecuaciones no lineales de flujo de potencia mediante métodos numéricos iterativos apropiados; y el *Agent* que implementa la lógica de control y toma decisiones sobre acciones a ejecutar basándose en observaciones del estado actual y objetivos operativos definidos.

Grid2Op representa el sistema eléctrico como un grafo dirigido $G = (\mathcal{N}, \mathcal{E})$ donde los nodos corresponden a buses o barras eléctricas y las aristas representan líneas de transmisión o transformadores que posibilitan flujo bidireccional de potencia entre nodos. Crucialmente, Grid2Op no implementa directamente la resolución de las ecuaciones (1)-(6), sino que proporciona una interfaz estandarizada de alto nivel que permite al agente especificar modificaciones en la topología de la red (apertura o cierre

de líneas, reconfiguración de conexiones en subestaciones) y ajustes en set-points de generación dentro de rangos operativos permitidos, delegando completamente al backend la responsabilidad crítica de verificar factibilidad física mediante resolución del problema completo de flujo de potencia. A su vez, implementa mecanismos automatizados de detección de violaciones que identifican y clasifican sobrecargas térmicas en líneas específicas, desviaciones de tensión respecto a límites normativos en buses individuales, y violaciones de límites de capacidad de generación, proporcionando al agente señales de retroalimentación detalladas y estructuradas mediante recompensas numéricas y observaciones ricas del estado que incluyen no solo variables de estado fundamentales sino también indicadores derivados (*i.e.* factores de carga de líneas, márgenes disponibles respecto a límites, y métricas agregadas de desempeño operativo del sistema).

Arquitectura del Sistema Multiagente Propuesto

El sistema propuesto en este trabajo está basado en el modelo desarrollado por Zhang *et al.* (Zhang et al., 2025), y comprende cinco agentes especializados que operan coordinadamente según el flujo ilustrado en la Figura 1. La arquitectura implementa un ciclo completo de detección-planificación-validación-ejecución-documentación que garantiza gestión segura y explicable de operaciones en redes eléctricas.

Detección y Planificación. El `DetectorAgent` opera como vigilante continuo procesando observaciones periódicas del estado operativo (magnitudes de tensión, flujos de potencia, factores de carga, estados de equipamiento) e implementando algoritmos para identificar violaciones críticas: sobrecargas térmicas ($\rho > 0,95$), desviaciones de tensión ($0,95 \leq V \leq 1,05$ p.u.), y violaciones de restricciones de generación según las ecuaciones (4)-(6), priorizando anomalías según severidad e impacto sistémico. Al detectar violaciones, transmite un reporte estructurado al `PlannerAgent`, que constituye el núcleo cognitivo del sistema. Este agente sintetiza estrategias correctivas mediante un LLM con capacidades agénticas operando en fases secuenciales: analiza violaciones determinando relaciones causales y prioridades; explora acciones disponibles (conmutación topológica, redespacho de generación respetando restricciones de rampa y capacidad); y construye secuencias ordenadas de acciones que remedian violaciones minimizando efectos adversos. El plan incluye justificaciones textuales detalladas vinculando explícitamente acciones con objetivos operativos y restricciones físicas.

Validación y Ejecución. El `ExecutorAgent` valida planes mediante simulación *sandbox*, ejecutándolos completamente en un entorno aislado que replica fielmente la red real. Aplica secuencialmente cada acción y ejecuta análisis de flujo de potencia (AC OPF) para determinar el nuevo estado resultante, capturando efectos de acoplamiento entre acciones e identificando combinaciones que producen estados no deseados mientras monitorea convergencia y detecta configuraciones inestables. El `ValidatorAgent` determina entonces si el plan simulado debe aplicarse al sistema real mediante verificación multi-capa combinando lógica determinística con evaluación heurística. Los criterios incluyen: (i) reducción cuantificable de violaciones; (ii) preservación de restricciones físicas fundamentales; (iii) ausencia de efectos adversos no anticipados (pérdidas excesivas, degradación de márgenes, reducción de reservas). Si se acepta, las acciones se aplican al entorno real con monitoreo continuo; si se rechaza, se solicita plan alternativo con feedback implementando refinamiento iterativo.

Documentación y Propiedades del Sistema. El `SummarizerAgent` genera documentación explicativa para trazabilidad y auditoría, incluyendo: (i) caracterización del estado inicial y violaciones; (ii) descripción de cada acción con justificación técnica; (iii) cuantificación de resultados en métricas operativas; (iv) evaluación del grado de éxito en resolver violaciones. Esta documentación facilita auditorías posteriores, análisis de desempeño histórico y aprendizaje continuo. El diseño integrado garantiza tres propiedades esenciales: primero, **seguridad por diseño** mediante simulación *sandbox* y validación cuantitativa que previenen ejecución de acciones que violen restricciones o induzcan inestabilidad; segundo, **explicabilidad integral** donde cada decisión incluye justificación comprensible vinculando acciones con objetivos operativos; tercero, **compatibilidad human-in-the-loop** admitiendo supervisión humana en cualquier punto, permitiendo que operadores revisen planes, modifiquen parámetros o anulen decisiones, preservando control humano final mientras se benefician de asistencia automatizada inteligente.

Caso de Estudio: Red de 14 Nodos

La validación experimental del sistema Copiloto CAMMESA se realizó utilizando el entorno `12rpn_case14_sandbox` (Donnot et al., 2020), una adaptación de la red estándar IEEE de 14 buses específicamente configurada para el framework `Grid2Op`. Esta red constituye un benchmark ampliamente reconocido y extensamente utilizado en la literatura de control de

sinc(r) Research Institute for Signals, Systems and Computational Intelligence (sinc.unl.edu.ar)
 M. Gerard, G. Magallán, I. R. Peralta & H. L. Rufiner; "Copiloto Multiagente Basado en LLMs para la Gestión Inteligente del Sistema Argentino de Interconexión (SADI) bajo Alta Penetración Renovable"
 Actas del V Congreso de Investigación y Transferencia Tecnológica en Ingeniería Eléctrica (CITIE 2026), 2026.

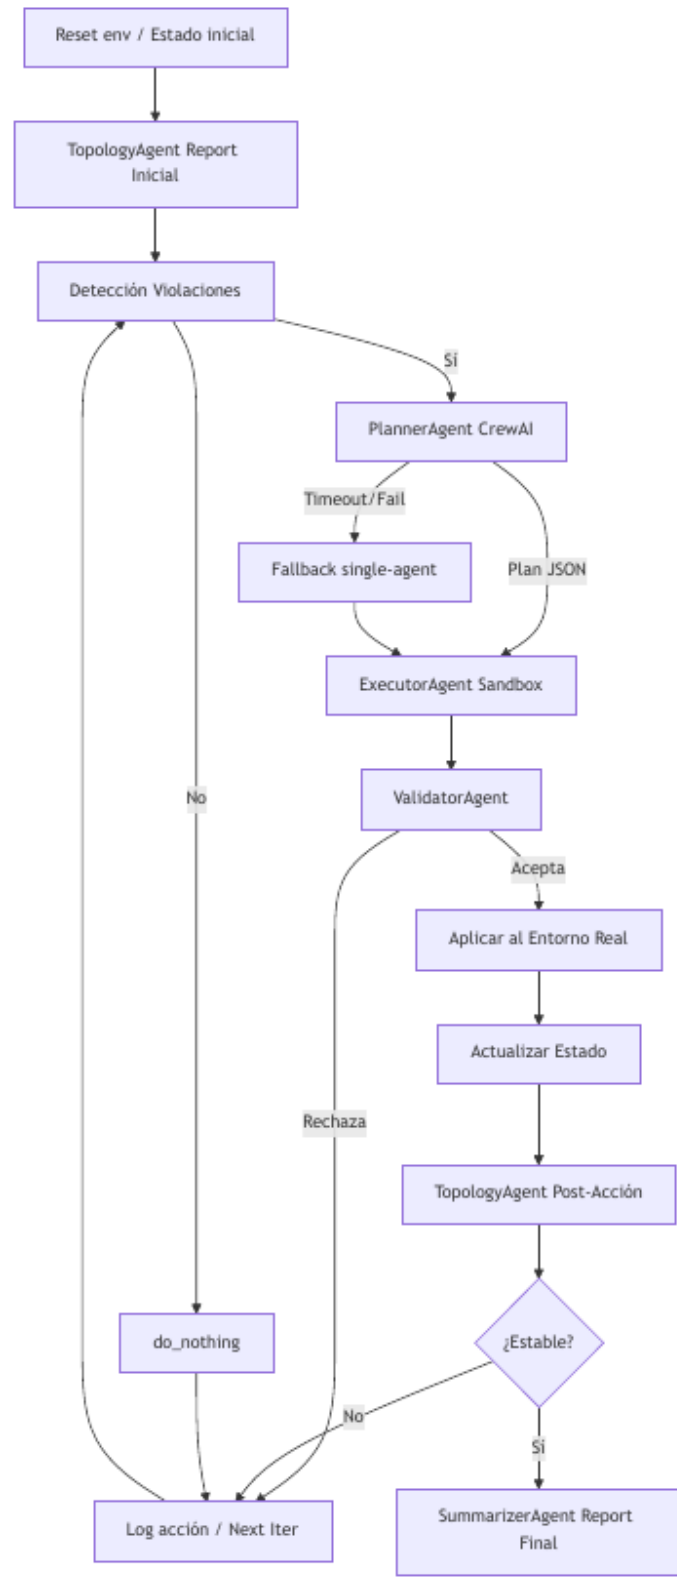


Figura 1. Arquitectura del sistema multiagente Copiloto CAMMESA: El flujo operativo inicia con detección de violaciones por el DetectorAgent, continúa con planificación de acciones correctivas mediante el PlannerAgent (coordinado por CrewAI), validación física en entorno *sandbox* por el ExecutorAgent, verificación de seguridad por el ValidatorAgent, aplicación al entorno real, y finaliza con generación de reportes explicativos por el SummarizerAgent.




Figura 2. Topología de la red de 14 nodos utilizada en la validación experimental, mostrando la estructura mallada de interconexión de buses mediante 20 líneas de transmisión, ubicaciones de 5 generadores (4 convencionales despachables y 1 renovable variable), y distribución de 11 centros de carga en el sistema. La redundancia topológica proporciona múltiples caminos para flujo de potencia entre generadores y cargas, característica esencial para análisis de contingencias N-1.

sistemas eléctricos mediante técnicas de aprendizaje por refuerzo, permitiendo comparación directa y cuantitativa de resultados con trabajos previos publicados y facilitando reproducibilidad completa de experimentos mediante acceso público a los datos de configuración. Aunque simplificada respecto a sistemas operativos reales como el SADI, la red de 14 buses captura características esenciales de sistemas de transmisión reales incluyendo topología mallada con caminos redundantes, generación con diferentes tecnologías, demanda variable temporal, restricciones operativas realistas, y dinámicas de contingencia tipo N-1, proporcionando un entorno de prueba suficientemente complejo para evaluación rigurosa de capacidades de gestión inteligente mientras mantiene tractabilidad computacional que permite experimentación extensiva. La Figura 2 presenta la topología completa de la red utilizada en los experimentos, mostrando claramente la interconexión de buses, líneas de transmisión, ubicaciones de generadores con sus capacidades respectivas, y distribución espacial de cargas, elementos fundamentales para comprender el comportamiento del sistema bajo diferentes condiciones operativas y contingencias.

Características Operativas de la Red

La red de 14 nodos comprende un sistema eléctrico simplificado pero suficientemente complejo para evaluación rigurosa de capacidades de gestión inteligente. La topología incluye 14 buses interconectados mediante 20 líneas de transmisión en estructura mallada con múltiples caminos alternativos para el flujo de potencia, proporcionando redundancia operativa. El sistema opera a 110 kV con 5 generadores que suman capacidad instalada de 615 MW: cuatro unidades convencionales (térmica e hidráulica) controlables entre 10 MW y 200 MW, y una fuente renovable eólica de 20 MW con perfil estocástico que exhibe variabilidad temporal (con alcance temporal de minutos a días) e introduce complejidad en la gestión operativa. Las cargas se distribuyen en 11 nodos con demanda total entre 180 MW y 290 MW según perfiles horarios: pico vespertino de 260 MW (19:00-22:00h) y valle nocturno de 190 MW (03:00-06:00h). Esta variabilidad temporal combinada con intermitencia renovable crea condiciones operativas dinámicas desafiantes.

El espacio de acciones refleja opciones de control típicas de sistemas de transmisión reales en tres categorías: Primero, 20 acciones discretas de conmutación topológica para abrir/cerrar líneas mediante interruptores, modificando caminos de flujo y redistribuyendo cargas térmicas. Segundo, acciones continuas de redespacho de los 5 generadores dentro de rangos

sinc(r) Research Institute for Signals, Systems and Computational Intelligence (sinc.unl.edu.ar)
 M. Gerard, G. Magallán, I. R. Peralta & H. L. Rufiner; "Copiloto Multiagente Basado en LLMs para la Gestión Inteligente del Sistema Argentino de Interconexión (SADI) bajo Alta Penetración Renovable"
 Actas del V Congreso de Investigación y Transferencia Tecnológica en Ingeniería Eléctrica (CITTIE 2026), 2026.

operativos específicos, respetando restricciones de rampa $\pm 30\%$ de potencia nominal por hora que protegen equipamiento contra estrés operativo excesivo y reflejan limitaciones físicas reales. Tercero, acciones de *curtailment* selectivo aplicables a la generación renovable para reducir potencia eólica cuando la alta disponibilidad renovable con demanda baja satura la capacidad de evacuación de la red. Esta combinación de acciones proporciona un espacio de decisión para evaluar capacidades de optimización multiobjetivo que balancean: minimización de costos operativos, maximización de integración renovable, cumplimiento de restricciones físicas y mantenimiento de márgenes para contingencias.

Las restricciones operativas reflejan criterios típicos de sistemas reales. Las tensiones nodales deben mantenerse en 0,95 a 1,05 p.u. para asegurar calidad de suministro y protección de equipamiento. Los factores de carga de líneas deben permanecer por debajo de 1,0 en condiciones normales, representando el límite térmico seguro de conductores, aunque algunos operadores toleran brevemente hasta 1,05 en contingencias severas. La reserva girante (capacidad de generación inmediatamente disponible sin estar actualmente despachada) debe ser $\geq 5\%$ de la demanda instantánea, criterio típico del SADI que asegura capacidad de respuesta ante variaciones inesperadas de generación o demanda. Finalmente, el sistema satisface el criterio $N - 1$, donde la red permanece estable tras desconexión súbita de cualquier elemento único sin propagación hacia cascadas de fallas, reflejando la filosofía de operación defensiva donde el sistema absorbe fallas individuales probables sin un colapso sistémico.

Resultados Experimentales

El sistema propuesto fue implementado usando el framework CrewAI (CrewAI Team, 2024) y el modelo gpt-oss:20b (Agarwal and et al., 2025), con capacidades de razonamiento y agénticas y que se puede correr en forma local utilizando *ollama*¹. Se utilizó una computadora con CPU i7 con 32 GB de RAM y una GPU NVIDIA RTX A5000 con 24 GB de VRAM que permitió correr el modelo a una velocidad de 86,33 tokens/segundo², lo que resulta razonable para un funcionamiento cercano al tiempo real. En esta versión el modelo se utilizó con los pesos originales, pero en el futuro se espera realizar un ajuste fino mediante técnicas de parámetros eficientes (ej. QLoRA (Dettmers and et al., 2023)). Los prompts proporcionados a los agentes se diseñaron a partir de conocimiento experto del dominio, pero serán optimizados con técnicas de evolución de prompts en versiones futuras (ej. EvoPrompt (Guo et al., 2023)).

La validación experimental del sistema multiagente propuesto se realizó mediante análisis detallado y exhaustivo de un caso de estudio representativo ejecutado sobre el entorno Grid2Op utilizando la configuración `l2rpn_case14_sandbox`. Este caso fue específicamente seleccionado por representar una evaluación rigurosa de las capacidades del agente en escenarios operativamente desafiantes de contingencia tipo $N - 1$, que son eventos frecuentes en operación real de sistemas eléctricos y constituyen pruebas estándar de robustez operativa, permitiendo examinar simultáneamente tanto la efectividad técnica de las decisiones implementadas por el sistema inteligente como las limitaciones arquitectónicas inherentes al diseño actual que restringen el espacio de problemas abordables con el repertorio de acciones disponible.

Configuración Experimental y Estado Inicial

Tabla 1. Parámetros operativos característicos del estado inicial del sistema eléctrico analizado antes de la contingencia programada

Parámetro Operativo	Valor Medido	Observaciones Técnicas
Factor de carga máximo (ρ_{max})	0,9245	Próximo al umbral crítico
Factor de carga promedio ($\bar{\rho}$)	0,4573	Utilización media del sistema
Generación total despachada	248,25 MW	4 de 6 generadores activos
Demanda total agregada	244,00 MW	11 centros de carga activos
Pérdidas de transmisión	4,25 MW	1,74 % de la demanda
Líneas en servicio	20/20	Conectividad topológica completa
Violaciones de tensión detectadas	10 nodos	Fuera del alcance actual del agente

¹<https://ollama.com/>

²Velocidad estimada usando: <https://github.com/MinhNguyen/llm-benchmark>

El experimento opera sobre la red de 14 nodos de 110 kV descrita en la Sección *Caso de Estudio: Red de 14 Nodos*, compuesta por 20 líneas activas, 5 unidades generadoras, y 11 centros de carga distribuidos espacialmente. La configuración inicial presentaba características operativas estables: las 20 líneas activas proporcionaban máxima redundancia topológica, el factor de carga máximo era $\rho_{\text{máx}} = 0,9245$ (92,45 % de capacidad nominal) dejando margen de seguridad del 7,55 % respecto al límite crítico $\rho_{\text{crit}} = 0,95$. El balance energético mostraba generación total de 248,25 MW atendiendo demanda de 244 MW, resultando en pérdidas de 4,25 MW (1,74 % de la demanda), consistente con valores típicos en sistemas de transmisión. La configuración de generación empleaba cuatro de seis unidades disponibles (nodos 0, 1, 2 y 5 aportando 82,5 MW, 80,7 MW, 5,3 MW y 81,3 MW respectivamente), mientras que las unidades en nodos 3 y 4 permanecían inactivas constituyendo reserva fría. El factor de carga promedio alcanzaba $\bar{\rho} = 0,4573$, indicando utilización moderada de la infraestructura compatible con períodos valle o intermedios, significativamente inferior al factor máximo evidenciando distribución no uniforme de cargas.

Un aspecto crítico identificado corresponde a diez violaciones simultáneas de tensión distribuidas en distintos nodos, donde magnitudes excedían límites normativos (típicamente $0,95 \leq V \leq 1,05$ p.u.). Estas desviaciones constituyen anomalías que comprometen calidad de suministro experimentada por consumidores, pueden inducir desconexiones automáticas mediante protecciones de sobre-tensión o sub-tensión, y en casos severos prolongados reducen vida útil de transformadores y motores. La persistencia de estas violaciones a lo largo de todo el episodio experimental, tanto precontingencia como postreconexión, constituye un aspecto de particular relevancia para el análisis crítico del desempeño del sistema, revelando limitaciones fundamentales en el repertorio de acciones actualmente disponibles que serán discutidas en la subsección dedicada a evaluación crítica. La Tabla 1 resume cuantitativamente los parámetros operativos del estado inicial, proporcionando la referencia contra la cual se compararán los efectos de la contingencia y acciones correctivas subsecuentes. El protocolo experimental implementó una contingencia programada consistente en la desconexión intencional de la línea 0 durante la iteración inicial ($\text{iter} = 0$), constituyendo una perturbación tipo $N - 1$ representativa de escenarios que operadores enfrentan rutinariamente: mantenimientos programados, fallas impredecibles por envejecimiento o defectos, activaciones de protecciones automáticas ante condiciones anormales, o eventos externos como condiciones meteorológicas adversas. Esta metodología controlada permite evaluar rigurosamente la capacidad del agente para identificar rápidamente condiciones anómalas emergentes, planificar proactivamente acciones correctivas considerando restricciones operativas, y ejecutarlas de manera segura dentro de ventanas temporales operativamente relevantes.

Respuesta del Agente ante Contingencia $N - 1$

La desconexión súbita de la línea 0 produjo una redistribución significativa de flujos de potencia, incrementando el factor de carga máximo desde $\rho_{\text{máx}} = 0,9245$ hasta $\rho_{\text{máx}} = 0,9565$ en la línea 17, que asumió carga adicional debido a la reconfiguración forzada. Este valor representa 95,65 % de la capacidad térmica, situándose peligrosamente próximo al límite crítico $\rho_{\text{crit}} = 0,95$, por encima del cual la operación sostenida puede inducir sobrecalentamiento con riesgo de daño permanente. El margen de seguridad térmica se redujo críticamente desde 7,55 % pre-contingencia hasta apenas 4,35 % post-contingencia, evidenciando la criticidad emergente de la línea 17 como cuello de botella del sistema. La reconfiguración topológica incrementó la generación requerida desde 248,25 MW hasta 249,80 MW (0,62 % de aumento) para mantener el balance con una demanda que aumentó de 244 MW a 244,40 MW, reflejando el impacto de pérdidas adicionales por rutas de transmisión subóptimas.

Ante esta condición crítica, el agente ejecutó proactivamente la reconexión de la línea 0 mediante activación de su interruptor (`update_switch_status`), intervención orientada a restaurar la configuración original y redistribuir flujos desde la línea sobrecargada hacia patrones equilibrados. Esta decisión fue precedida por simulación predictiva en entorno *sandbox* mediante `obs.simulate()`, evaluando anticipadamente efectos completos sin comprometer la estabilidad del sistema real. El módulo `ValidatorAgent` verificó exhaustivamente que el factor de carga máximo proyectado no excediera el umbral crítico y que ninguna restricción operativa fuera violada, certificando la seguridad operativa antes de autorizar la implementación. Este protocolo multi-capa demuestra la robustez arquitectónica del sistema, implementando defensas en profundidad contra errores de planificación o efectos colaterales no anticipados.

La reconexión efectiva produjo modificaciones operativas favorables: el factor de carga máximo se redujo de $\rho_{\text{máx}} = 0,9565$ a $\rho_{\text{máx}} = 0,9207$ (3,74 % de disminución respecto al valor crítico), quedando incluso 0,38 % inferior al valor inicial pre-contingencia. Esta reducción incrementó el margen de seguridad térmica de 4,35 % a 7,93 %, alejando al sistema de condiciones peligrosas de sobrecarga inminente. El balance energético post-reconexión indicó generación de 248,99 MW atendiendo demanda de 244,80 MW, con pérdidas de 4,19 MW (1,71 % de la demanda). Comparando con las pérdidas iniciales de 4,25 MW, la configuración post-reconexión demostró reducción del 1,41 % en pérdidas absolutas, confirmando que la reconexión optimizó los patrones de flujo y minimizó pérdidas resistivas Joule. El factor de carga promedio se mantuvo prácticamente invariante ($\bar{\rho} = 0,4576$ versus $\bar{\rho} = 0,4573$), confirmando que la acción tuvo efectos predominantemente localizados sin alterar la utilización agregada de la infraestructura. La tasa de éxito del 100 %, combinada con la mejora del 0,38 % en carga máxima y la resolución efectiva de la sobrecarga, evidencian la efectividad técnica del enfoque implementado.

Evaluación Crítica y Limitaciones del Repertorio

El desempeño del agente inteligente en el escenario de contingencia $N - 1$ resulta altamente satisfactorio dentro de sus capacidades operativas actuales. La reconexión inmediata de la línea 0 constituye la respuesta óptima factible para abordar la sobrecarga crítica en la línea 17, demostrando capacidad integral al identificar rápidamente el problema, planificar una solución mediante reconfiguración topológica, validarla preventivamente con simulación *sandbox*, y ejecutarla exitosamente sin efectos adversos. La arquitectura multi-capa de validación previene sistemáticamente intervenciones que podrían degradar el sistema, aspecto fundamental para infraestructura crítica. Sin embargo, las violaciones de tensión (10 nodos con desviaciones respecto a límites normativos) permanecieron sin corrección tanto en condición inicial como en estado final post-reconexión.

Esta persistencia de violaciones de tensión no refleja deficiencias técnicas del agente sino limitaciones estructurales en el repertorio de acciones disponibles. El sistema dispone exclusivamente de: (i) reconfiguración topológica (`update_switch_status`), (ii) redespacho de potencia activa (`redispatch`), (iii) *curtailment* renovable (`curtail_load`), y (iv) gestión de almacenamiento (`place_battery`). Ninguna proporciona control directo sobre tensiones nodales. La corrección efectiva de violaciones de tensión requiere herramientas especializadas de control de potencia reactiva actualmente no disponibles: ajuste de set-points de tensión en generadores síncronos, activación de bancos de capacitores/reactores shunt, modificación de taps en transformadores reguladores, y despacho coordinado de dispositivos FACTS. El redespacho de potencia activa, aunque capaz de efectos secundarios sobre tensiones por acoplamiento P-V, resulta insuficiente para abordar sistemáticamente múltiples violaciones distribuidas geográficamente. El agente implementó la estrategia óptima dentro de sus capacidades limitadas, priorizando correctamente el riesgo más inmediato de sobrecarga térmica.

Para incrementar la efectividad operativa y posibilitar control integral de todas las anomalías operativas, se recomienda incorporar capacidades de control activo de tensión mediante gestión de potencia reactiva: ajuste dinámico de set-points en generadores, gestión coordinada de dispositivos de compensación reactiva, y control automatizado de transformadores reguladores. Esta ampliación debe acompañarse de refinamiento en la jerarquización de objetivos operativos, asignando a las violaciones de tensión prioridad superior a optimizaciones de eficiencia energética cuando no existe riesgo inmediato de sobrecarga térmica, dado su potencial de desencadenar desconexiones automáticas con impactos económicos significativos. Adicionalmente, la implementación de mecanismos explícitos de coordinación entre control de potencia activa y reactiva, junto con análisis de sensibilidades V-P y V-Q mediante factorizaciones LU de la matriz Jacobiana, permitiría anticipar efectos cruzados y diseñar estrategias multi-objetivo que aborden simultáneamente seguridad térmica y calidad de tensión.

Conclusiones y Trabajo Futuro

Este trabajo presenta el desarrollo y validación experimental del sistema multiagente Copiloto CAMMESA para asistencia inteligente en gestión del SADI bajo alta penetración renovable. Los resultados experimentales en una red de 14 buses mostraron la capacidad de gestión de contingencias N-1, con mejora en el factor de carga crítico post-contingencia y aumento del margen de seguridad operativo. A su vez, el sistema exhibió una capacidad integral de explicabilidad mediante generación de justificaciones en lenguaje natural que vinculan acciones con objetivos operativos.

Como trabajo futuro se planifica: (i) validación con datos operativos reales del SADI (posible colaboración con CAMESA), (ii) expansión del modelo SADItoy hacia 200-300 nodos con mayor detalle topológico, (iii) despliegue en modo observador paralelo donde el Copiloto genera recomendaciones monitoreadas pero no aplicadas automáticamente, y (iv) adaptación de metodología a otros sistemas eléctricos latinoamericanos.

Referencias bibliográficas

- Agarwal, S. and et al. (2025). gpt-oss-120b & gpt-oss-20b model card. *arXiv preprint arXiv:2508.10925*.
- Bajo-Buenestado, R. (2025). The iberian peninsula blackout: Causes, consequences, and challenges ahead. *Baker Institute Policy Report*.
- CAMESA (2024). Informe anual del mercado eléctrico mayorista 2024.
- Chow, J. H. and Sanchez-Gasca, J. J. (2020). *Power System Modeling, Computation, and Control*. Wiley-IEEE Press, Hoboken, NJ.
- Christiano, P., Leike, J., and Ganguli, D. (2023). Iterated online rlhf: Reward model evolution in alignment. *arXiv preprint arXiv:2304.07327*.
- Christiano, P. F., Leike, J., Brown, T., Martic, M., Legg, S., and Amodei, D. (2017). Deep reinforcement learning from human preferences. *Advances in Neural Information Processing Systems*, 30.
- CrewAI Team (2024). Crewai: Framework for orchestrating role-playing autonomous ai agents. Software Framework.
- Dettmers, T. and et al. (2023). Qlora: Efficient finetuning of quantized llms. *arXiv preprint arXiv:2305.14314*.
- Donnot, B., Guyon, I., Schoenauer, M., Panciatici, P., and Marot, A. (2020). Grid2op: A testbed platform to model sequential decision making in power systems. In *Proceedings of the 34th Conference on Neural Information Processing Systems (NeurIPS 2020)*, Vancouver, Canada.
- ENTSO-E Expert Panel (2025). Factual report on the grid incident in spain and portugal on 28 april 2025. Scale 3 (Major) Incident Classification.
- Gao, C., Lan, X., Li, N., Yuan, Y., Ding, J., Zhou, Z., Xu, F., and Li, Y. (2024). Large language models empowered agent-based modeling and simulation: A survey and perspectives. *Humanities & Social Sciences Communications*, 11(1):1–25.
- Glover, J. D., Overbye, T., and Sarma, M. S. (2017). *Power System Analysis and Design*. Cengage Learning, Boston, MA, 6th edition.
- Guo, Q., Wang, R., Guo, J., Li, B., Song, K., Tan, X., Liu, G., Bian, J., and Yang, Y. (2023). Evoprompt: Connecting llms with evolutionary algorithms yields powerful prompt optimizers. *arXiv preprint arXiv:2309.08532*.
- Lambert, N. et al. (2024). The rlhf book: A comprehensive guide to reinforcement learning from human feedback. *Online Technical Book*.
- OpenAI (2023). Gpt-4 technical report. *arXiv preprint arXiv:2303.08774*.
- Ouyang, L., Wu, J., Jiang, X., Almeida, D., Wainwright, C., Mishkin, P., Zhang, C., Agarwal, S., Slama, K., Ray, A., et al. (2022). Training language models to follow instructions with human feedback. *Advances in Neural Information Processing Systems*, 35:27730–27744.
- Secretaría de Energía de Argentina (2023). Programa renovar: Balance de generación renovable en argentina. Reporte de Gestión.
- Wood, A. J., Wollenberg, B. F., and Sheblé, G. B. (2013). *Power Generation, Operation, and Control*. Wiley-IEEE Press, Hoboken, NJ, 3rd edition.
- Zhang, Y., Chen, X., and Wang, J. (2025). Grid-agent: An llm-powered multi-agent system for power grid control. *arXiv preprint arXiv:2508.05702*.