Climate Change AI

IA para los sistemas eléctricos y energéticos

Dr José Córdova García
Profesor asociado
Líder de Analítica e Inteligencia Artificial para la Sostenibilidad
Universidad ESPOL, Ecuador

AIAS
Analytics and Artificial Intelligence for Sustainability

espol Centro de Tecnologías de Información

Lecturas previas

Panorama de sistemas energéticos + IA
Donti & Kolter (2021), *Machine Learning for Sustainable Energy Systems*
https://doi.org/10.1146/annurev-environ-020220-061831
Panorama de la IA para la acción climática, sección sobre sistemas energéticos y eléctricos
Rolnick et al. (2019), *Tackling Climate Change with Machine Learning*
https://arxiv.org/abs/1906.05433
IA responsable / supervisión humana
NIST AI RMF 1.0, *Appendix C: AI Risk Management and Human-AI Interaction*
https://airc.nist.gov/airmf-resources/airmf/appendices/app-c-ai-risk-management-and-human-ai-interaction/
Los LLM y su despliegue en el sector eléctrico
EPRI Journal (2026), *Benchmarking Large Language Models for the Electric Power Sector*
https://eprijournal.com/benchmarking-large-language-models-for-the-electric-power-sector/

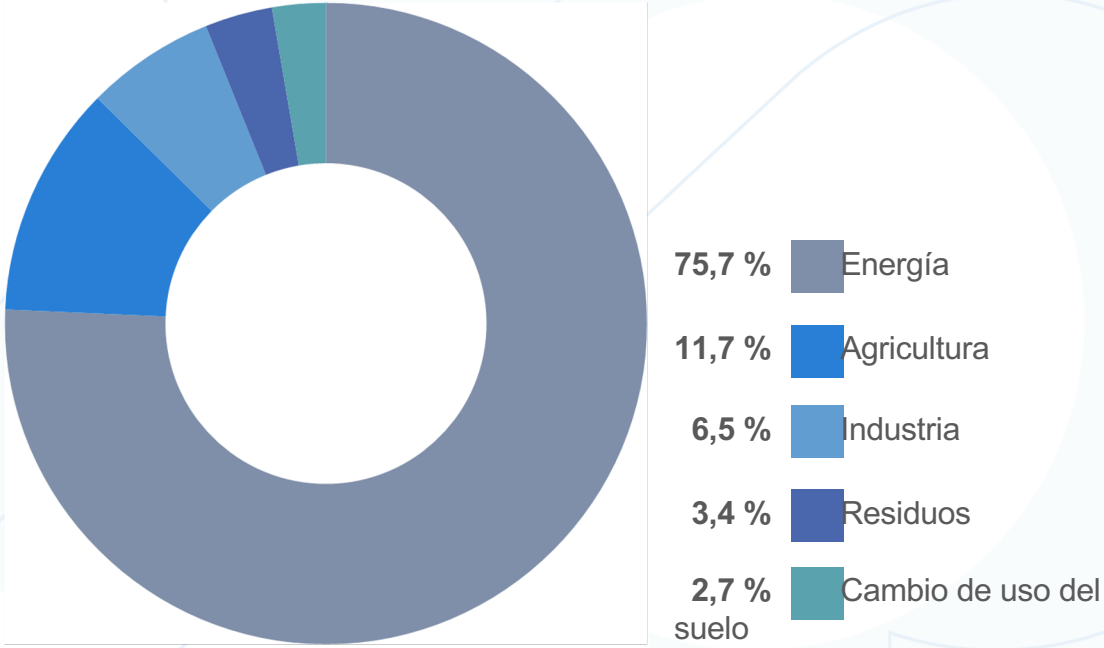
Agenda

1. Introducción a los sistemas eléctricos y energéticos
2. IA para los sistemas energéticos
3. Previsión de la oferta renovable y de la demanda
4. IA con restricciones físicas y optimización
5. Retos de despliegue de modelos y escasez de datos
6. Conclusiones

Introducción a los sistemas eléctricos y energéticos

Energía y clima: emisiones de gases

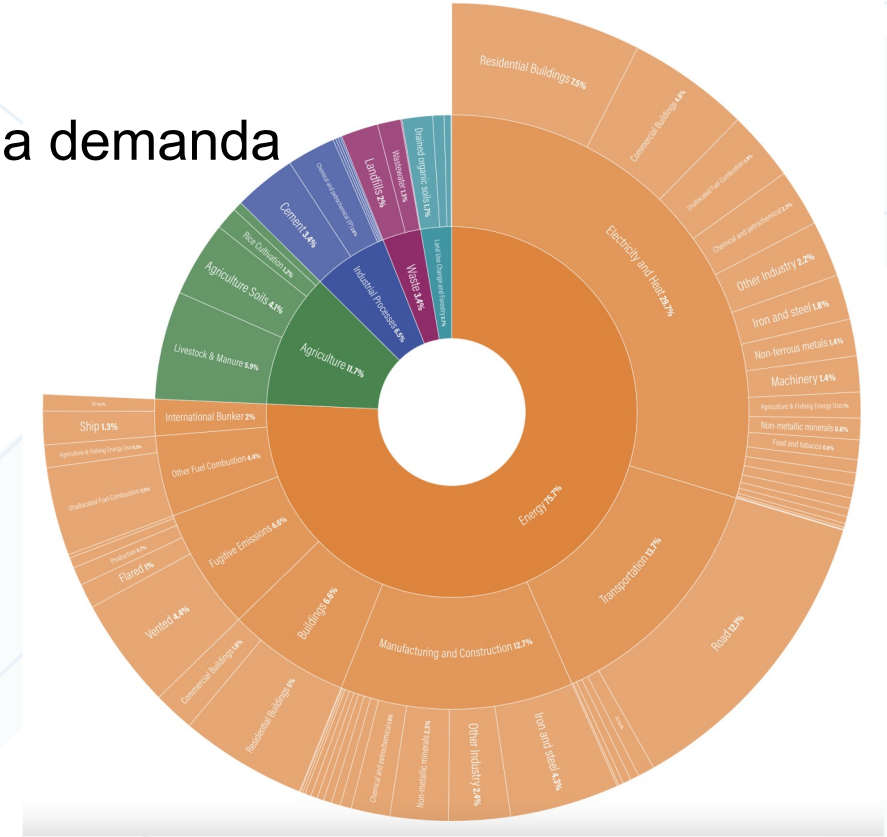
El **sector energético** es, con diferencia, el que más gases de efecto **invernadero emite**: nada menos que el **75,7 %** a escala mundial.



Emisiones mundiales de gases de efecto invernadero por sector y uso final, 2021. Fuente: (World Resources Institute 2024)

Cuota de la electricidad en la demanda de energía

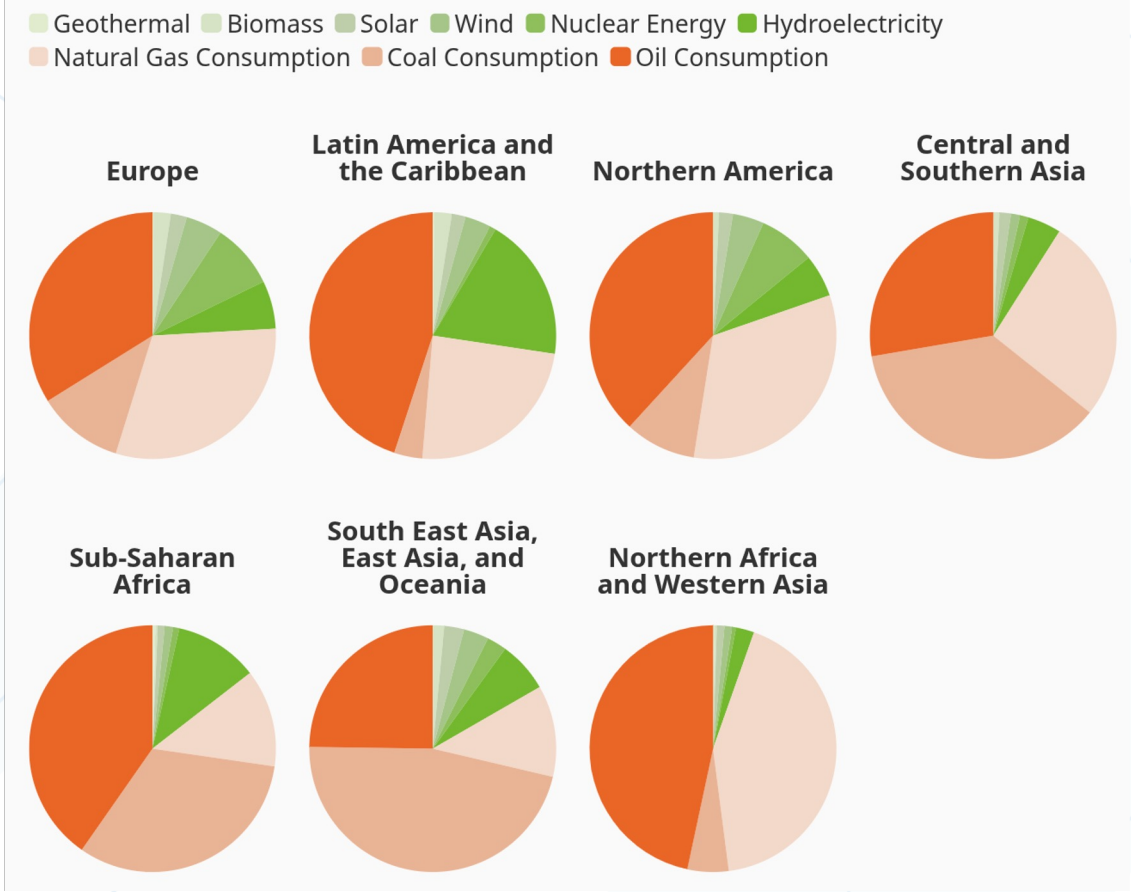
El **sector energético** es, con diferencia, el que más gases de efecto **invernadero emite**: nada menos que el **75,7 %** a escala mundial.



Emisiones mundiales de gases de efecto invernadero por sector y uso final, 2021. Fuente: (World Resources Institute 2024)

Consumo de energía por fuente

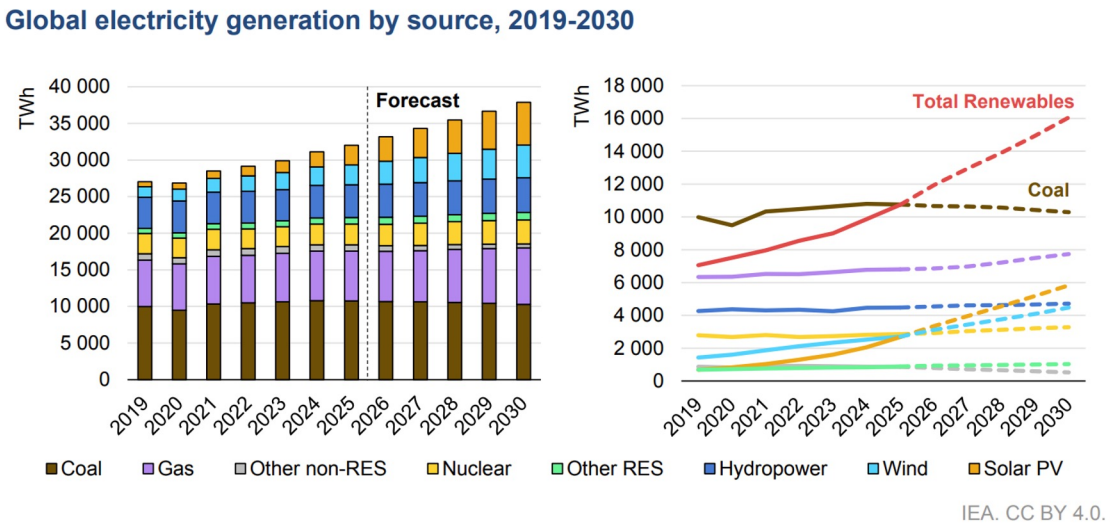
Cerca de dos tercios del carbón que se usa en el mundo se destinan a la **generación** en sistemas **eléctricos** (IEA 2025), junto con la hidráulica, la nuclear, la eólica y la solar como fuentes principales



Fuente: estimaciones de la OMPI a partir de la base de datos del GII y del EI Statistical Review of World Energy.

La matriz energética es cada vez más limpia

En 2025, la generación eólica de la UE cayó cerca de un 2,6 % por vientos más débiles, mientras que la hidroeléctrica bajó cerca de un 13 % por la menor lluvia, lo que aumentó el uso de gas en torno a un 8 % (IEA 2026).



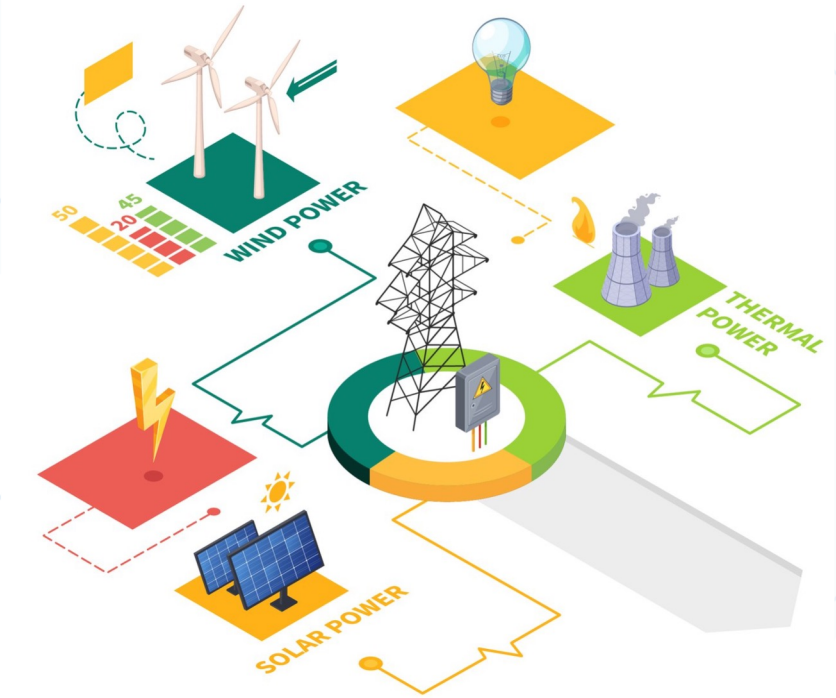
Notes: RES = renewable energy sources. 'Other non-RES' includes oil, waste and other non-renewable sources. 'Other RES' includes geothermal, bioenergy, concentrated solar power (CSP), and ocean energy. Data for 2026-2030 are forecast values.

Fuente: estimaciones de la OMPI a partir de la base de datos del GII y del EI Statistical Review of World Energy.

Las redes hacen disponible la energía eléctrica

Integrar distintas fuentes de energía convierte la gestión energética en un problema complejo.

Tareas como la planificación, la operación y el mantenimiento dependen ahora de factores variables.

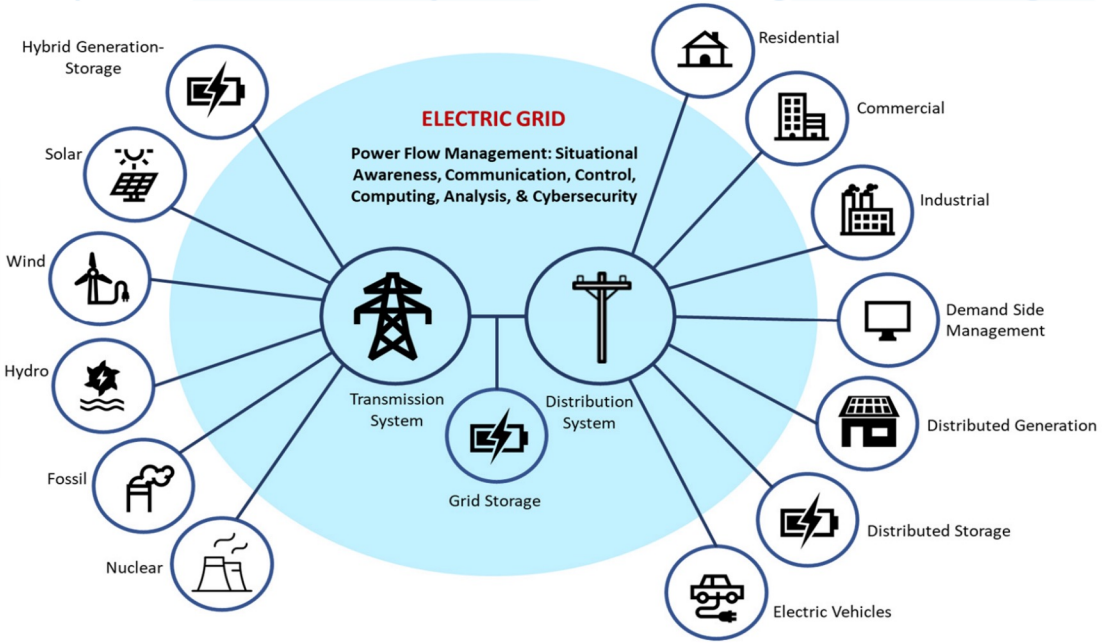


Integración en la red. Fuente: Nigeria Energy Transition Plan (ETP 2025)

Suministrar energía eléctrica es un problema complejo

De la generación al consumo: probablemente el sistema de ingeniería más complejo

Más complejidad aún: los cambios en los patrones de demanda

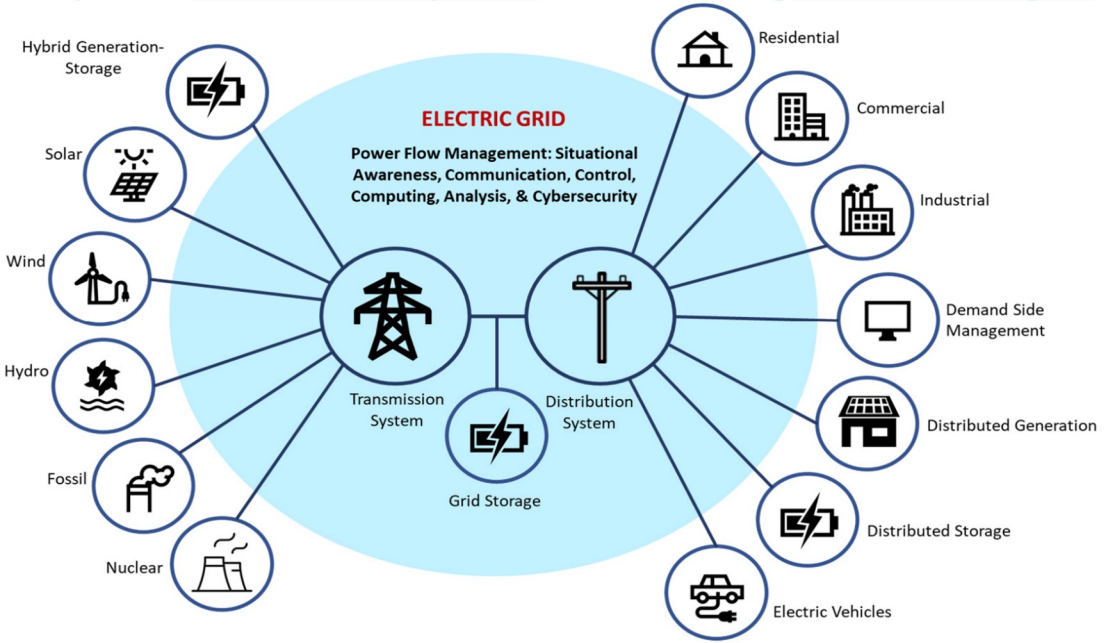


Fuente: U.S. Department of Energy, Office of Electricity, Next-Generation Grid Technologies, figura 2, 2021

Suministrar energía eléctrica es un problema complejo

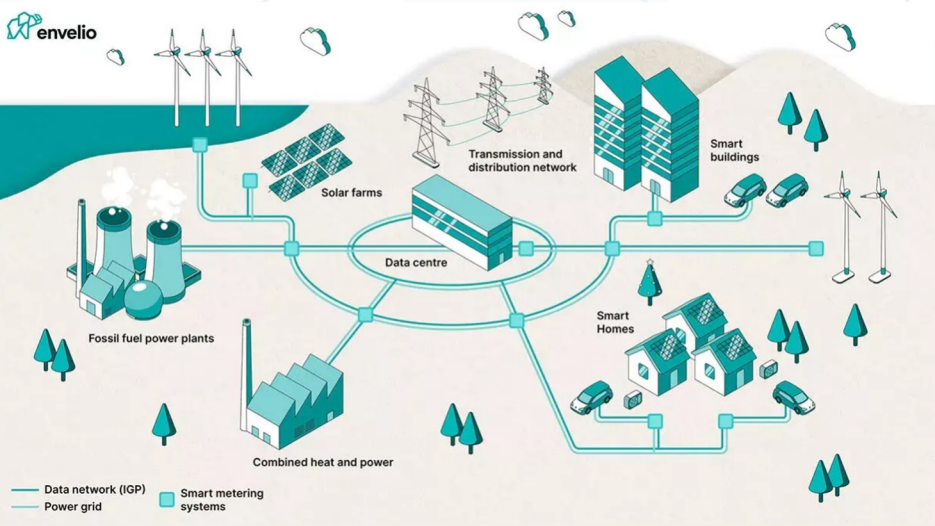
Muchas tareas de ingeniería:

asignación de unidades y despacho económico, previsión de la demanda, planificación de la expansión de generación y transmisión, estimación de estado, análisis de flujos de potencia, casación del mercado, control de tensión y frecuencia, protecciones, detección de fallas, mantenimiento, balance de carga…



Fuente: U.S. Department of Energy, Office of Electricity, Next-Generation Grid Technologies, figura 2, 2021

¿Por qué IA para la energía?



Smart Grid – How intelligent power grids enable the energy transition.(Envelio 2025)

- Las redes modernas afrontan **una complejidad creciente**: más renovables, balance en tiempo real, datos incompletos, demanda cambiante.
- **La IA aporta inteligencia adaptativa basada en datos**: mejores previsiones, decisiones conscientes del riesgo, respuestas en tiempo real.
- Reto: replantear la operación de los sistemas eléctricos



Encuesta

¿Qué hace difícil operar una red eléctrica?

IA para los sistemas energéticos

La IA surge como habilitador clave para modernizar las aplicaciones energéticas



Planificación
Optimización de la capacidad a largo plazo y desarrollo de infraestructuras

Operación
Gestión de la red en tiempo real, programación y supervisión de recursos

Mantenimiento
Analítica predictiva de la fiabilidad de los equipos

Mercados
Precios dinámicos y optimización del comercio de energía

Usuarios finales
Respuesta a la demanda y optimización del consumo

Métodos de IA y problemas energéticos

Métodos de IA/AA utilizados

Análisis de series temporales
Previsión de carga, renovables y generación

Aprendizaje profundo y redes neuronales (NN)
Previsión, detección de anomalías, modelización.

Visión por computador
Mapeo y supervisión de activos, planificación FV

Aprendizaje por refuerzo
Respuesta a la demanda, almacenamiento, control de red

Métodos con restricciones/PINN
Decisiones óptimas, despacho, flujos de potencia

Principales problemas energéticos

Previsión
De patrones de demanda estables a renovables inciertas

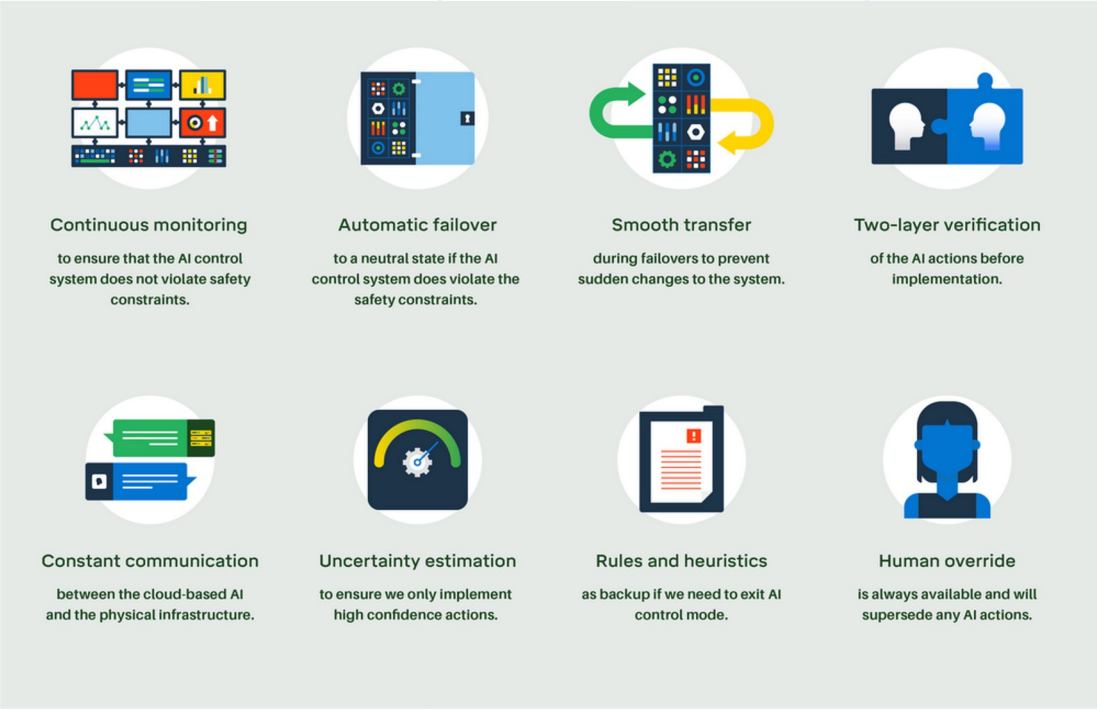
Despacho óptimo
De modelos estáticos a decisiones con sensores

Salud de los activos
Del mantenimiento reactivo al predictivo

Expansión de la red
De una planificación lenta a la ubicación basada en datos

Mercados y flexibilidad
De una operación fija a respuestas dinámicas

De los datos de red a decisiones seguras asistidas por IA



«Safety-first AI for autonomous data center cooling and industrial control», (Google 2018)

De los datos de red a decisiones seguras asistidas por IA

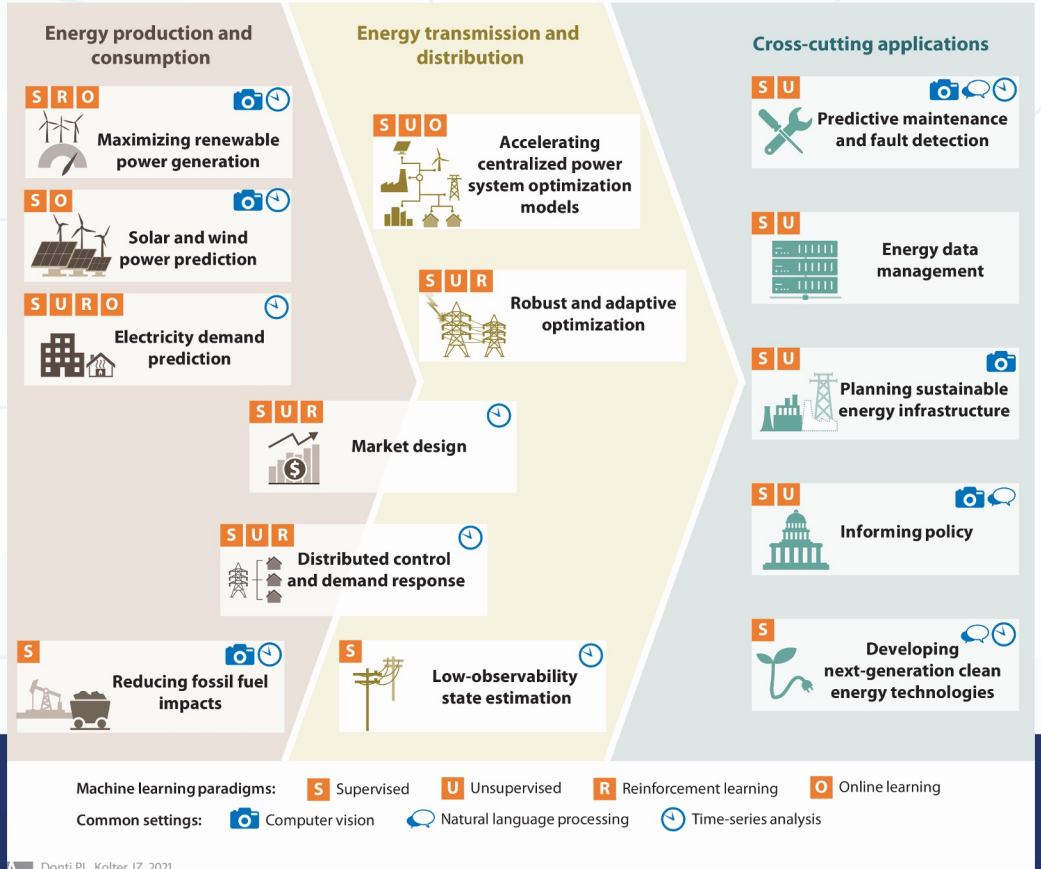
Datos:

- **PMU**: tensión, corriente, ángulo de fase, frecuencia, ~ms
- **SCADA / EMS**: datos de generadores, subestaciones, interruptores, tensión y flujos de potencia, supervisión al segundo
- **Contadores inteligentes / AMI**: demanda, tensión, cortes, a menudo en intervalos de 5 a 60 min
- **DER y dispositivos**: inversores FV, baterías, cargadores de VE, sensores de edificios, datos meteorológicos/NWP

Decisiones:

- Prever la generación renovable y la demanda
- Detectar fallas, cortes, anomalías y errores de sensores
- Estimar el estado de la red y los riesgos de congestión
- Apoyar el despacho, el OPF, el almacenamiento, la carga de VE y la respuesta a la demanda
- Enviar recomendaciones a operadores, mercados o controladores locales

Aplicaciones en sistemas energéticos sostenibles

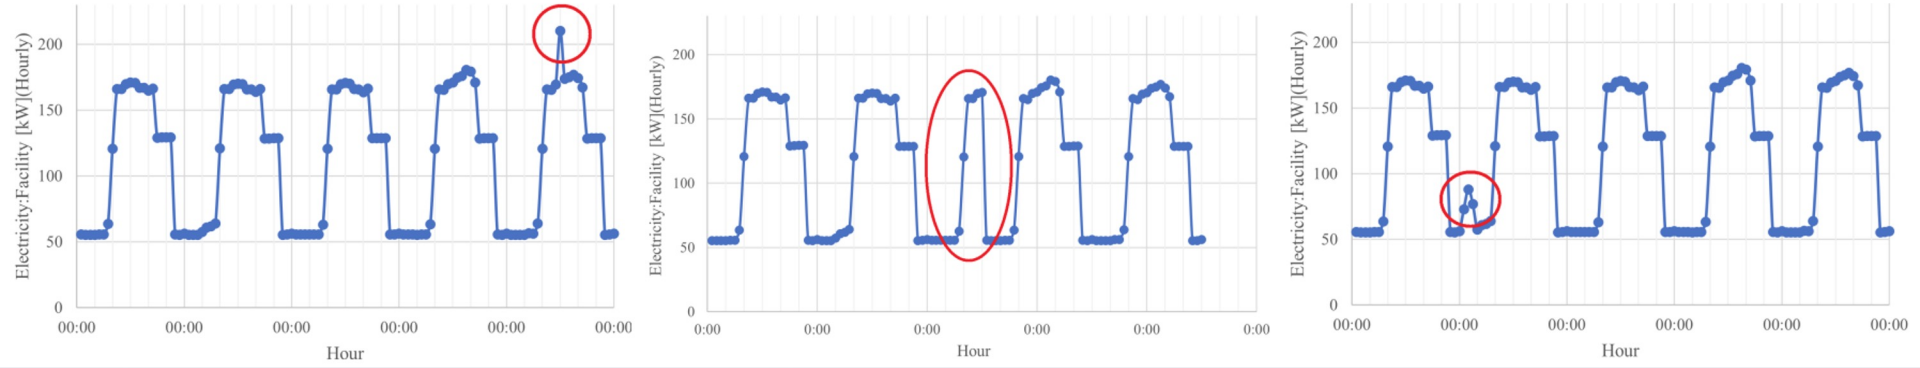


Detección, identificación y localización de fallas

Los patrones de funcionamiento normal pueden aprenderse del SCADA, de sensores de alta resolución, inspecciones y registros para generar alertas tempranas:

- Detección de anomalías
- Autocodificadores
- Clasificadores de fallas

Ilustración de tres tipos de valores atípicos en datos de carga horarios de un restaurante. Datos de Open EI (Zhang et al. 2021)

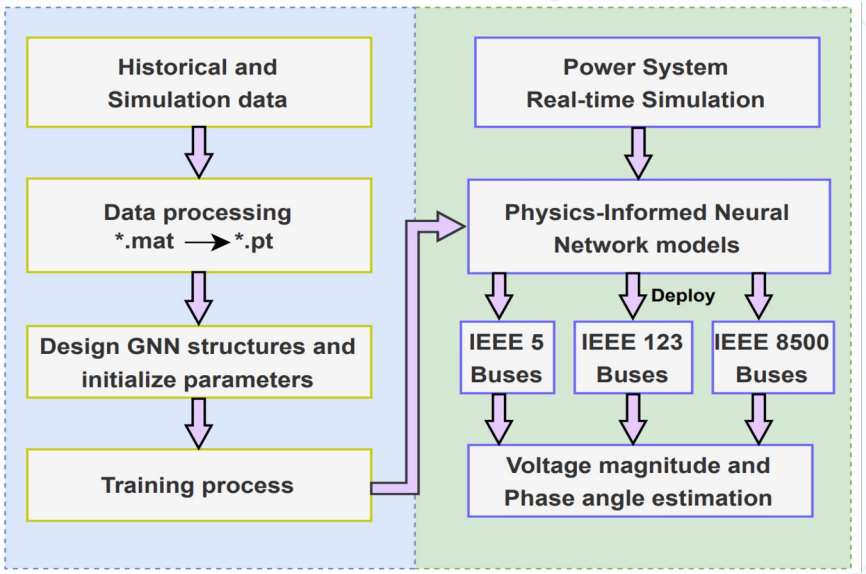


¿Datos incompletos? Estimación de estado con baja observabilidad

Las redes de distribución carecen de datos de topología actualizados y de sensores:

- Las **GNN** informadas por la física combinan topología de red, datos dispersos de sensores y ecuaciones del sistema eléctrico para estimar tensiones y estados no medidos.

Resultados del orden de **10e-6** en sistemas de prueba estándar (Ngo et al. 2023)



Marco PINN (Ngo et al. 2023)

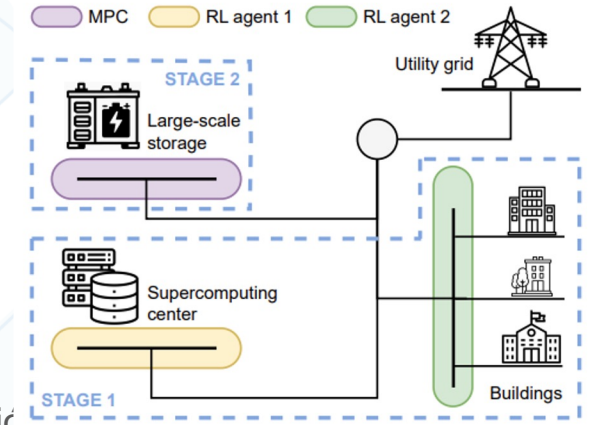
Respuesta a la demanda y control distribuido

El AR puede aprender políticas de control para:

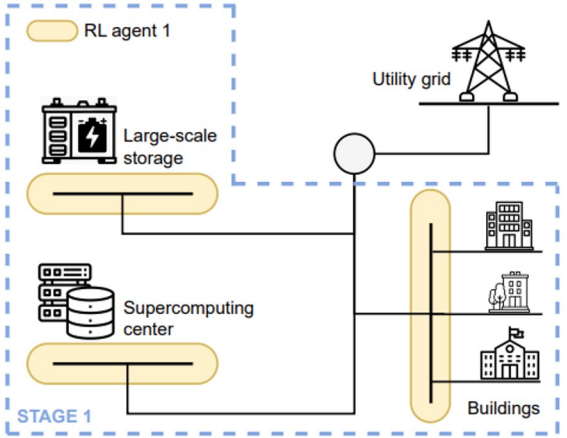
- Cargas flexibles
- DER
- Almacenamiento
- Carga de VE
- Respuesta a la demanda

El reto es multiobjetivo: reducci
físicas y, **como novedad para el**
para los operadores y ciberresiliencia.

Flujo de control durante el entrenamiento y el despliegue en CommonPower. (Eichelbeck 2024)



(a) Two-stage control with balancing assets operated by an MPC and two different coalitions controlled by multi-agent RL.



(b) Centralized control using RL.

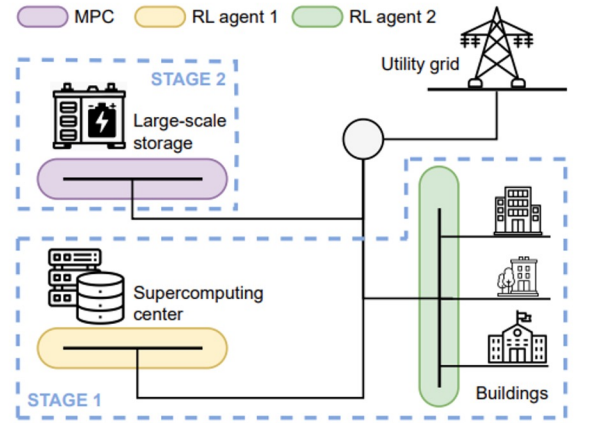
Respuesta a la demanda y control distribuido

PPO/SAC (Eichelbeck 2024) con filtros de seguridad que imponen restricciones:

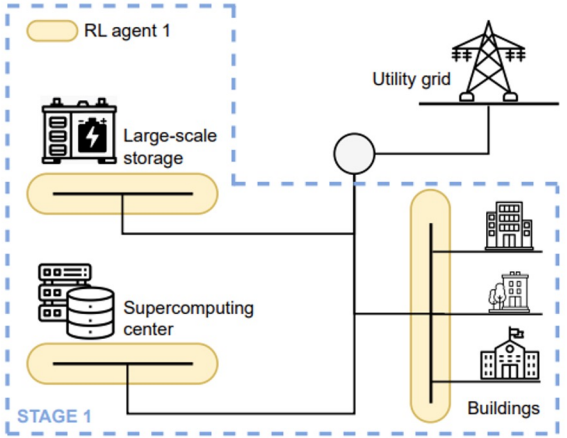
- >90 % de cumplimiento
- Bancos de prueba seguros para el AR

El reto es multiobjetivo: reducci
físicas y, **como novedad para el**
para los operadores y ciberresiliencia.

Flujo de control durante el entrenamiento y el despliegue en CommonPower. (Eichelbeck 2024)



(a) Two-stage control with balancing assets operated by an MPC and two different coalitions controlled by multi-agent RL.

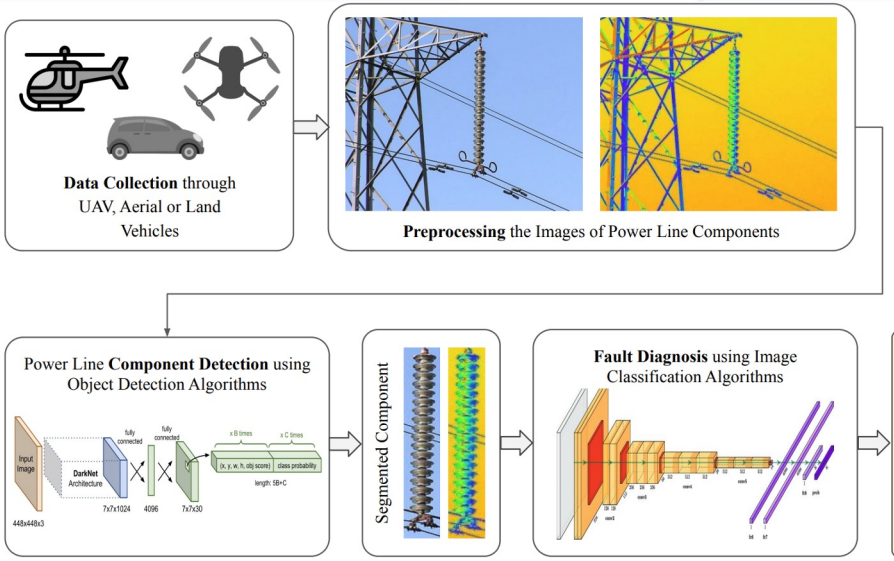


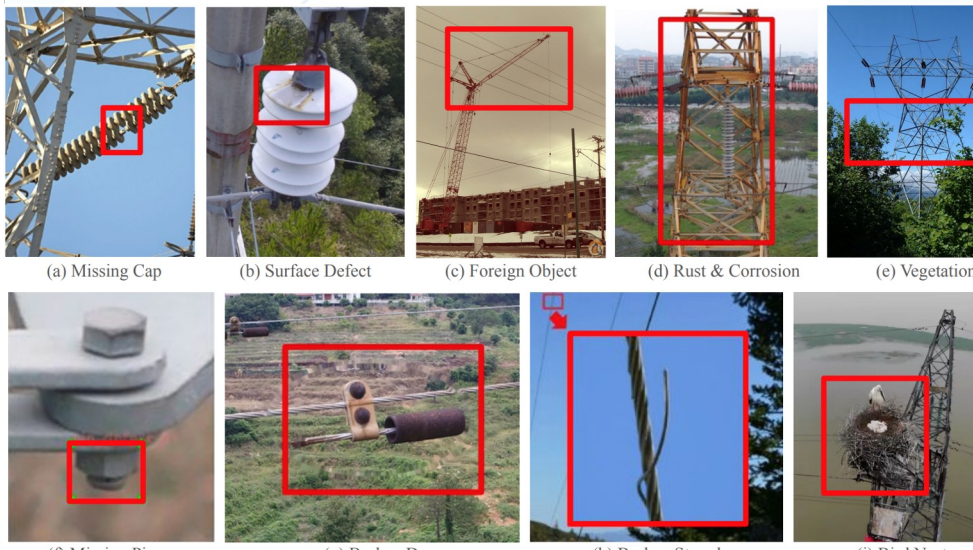
(b) Centralized control using RL.

Detección y supervisión del estado de las infraestructuras

Llevar la **visión por computador** a la planificación de redes para ampliar el acceso a la electricidad, con datos heterogéneos:

- Mapas, edificios, datos abiertos de infraestructuras, usos, imágenes aéreas
- Automatizar la inspección de infraestructuras eléctricas (Faisal et al. 2025)

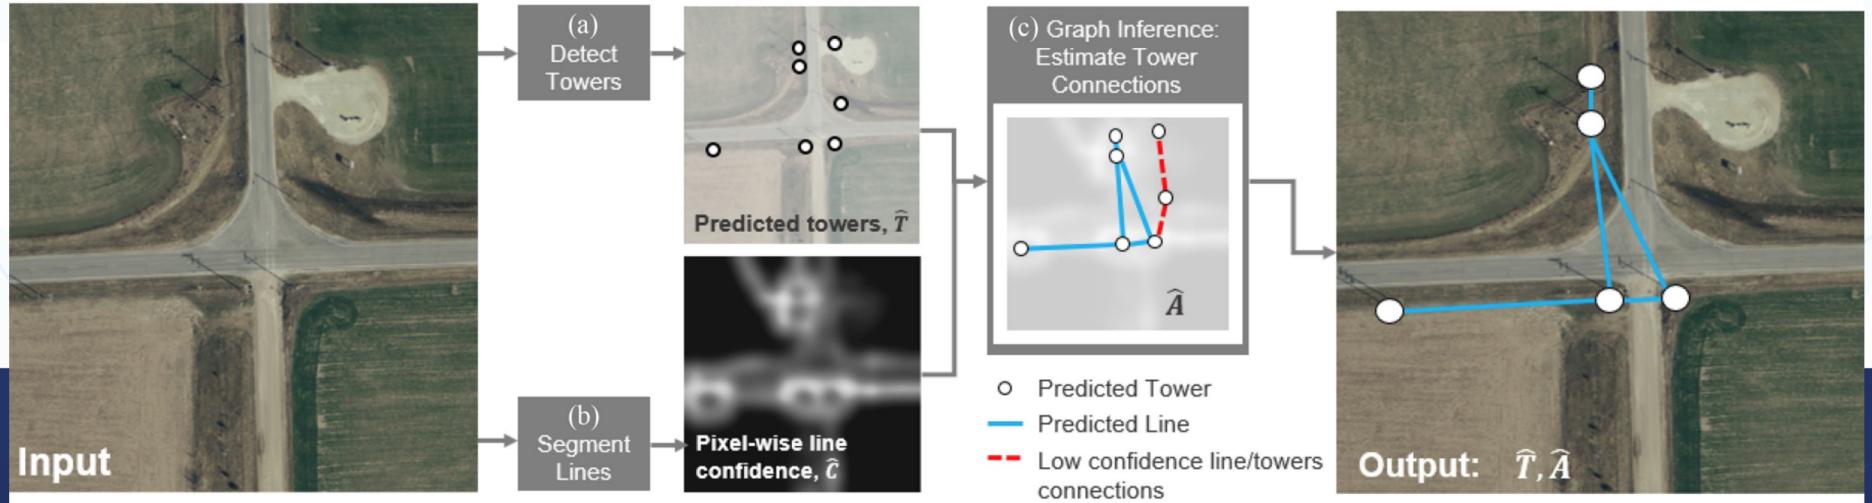




Detección y supervisión del estado de las infraestructuras

Llevar la **visión por computador** a la planificación de redes para ampliar el acceso a la electricidad, con datos heterogéneos:

- Mapas, edificios, datos abiertos de infraestructuras, usos, imágenes aéreas
- Detectar la topología y las interconexiones de líneas es necesario para ampliar la capacidad (Huang et al. 2021)





Encuesta

¿Qué tarea de los sistemas eléctricos está más lista para el despliegue hoy?

Previsión para sistemas energéticos

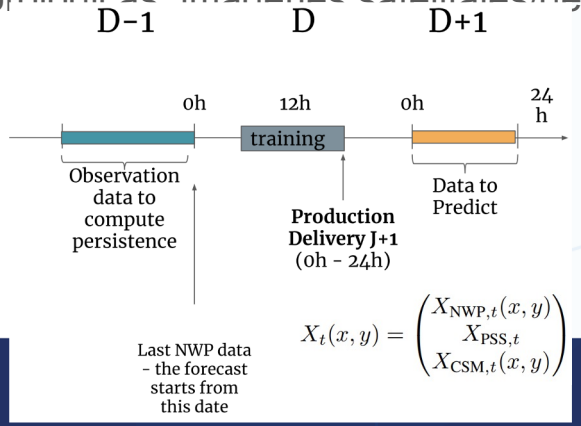
¿Qué estamos previendo?

Apoya el despacho, el almacenamiento, los mercados, la respuesta a la demanda y la integración de renovables:

- Demanda/carga, solar, eólica, hidráulica, precios, intensidad de carbono de la red, flexibilidad.

De la previsión estadística al AA: el gran cambio es pasar de una oferta estable a una dependiente del tiempo meteorológico

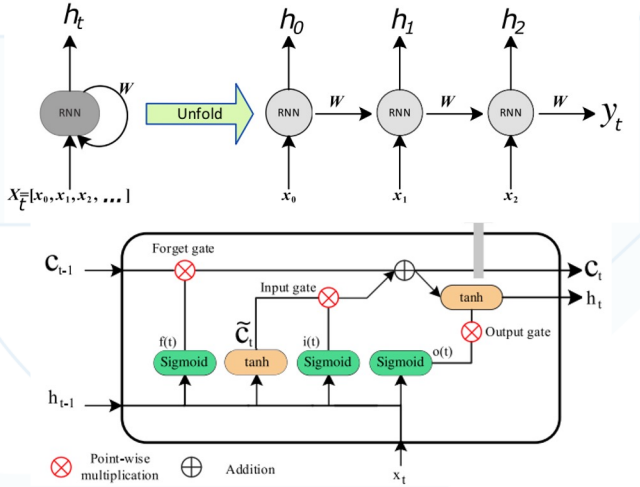
- **Entradas**: historial de generación, SCADA, estaciones meteorológicas, imágenes satelitales/de nubes, NWP, metadatos del terreno y del emplazamiento.
- **Salidas**: previsiones puntuales + probabilísticas.



Cronología de la predicción para el día siguiente con agregación de variables de modelos estándar y meteorología (Mathe et al. 2019)

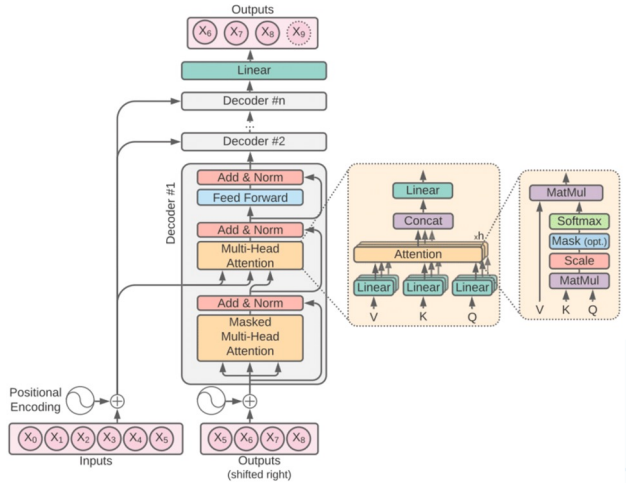
Aprendizaje profundo para la previsión solar y eólica

RNN / GRU / LSTM / Bi-LSTM: muy usadas para series temporales (previsión a corto plazo) (Guanoluisa-Pineda 2022, Díaz-Bedoya 2023)



«Forecasting Univariate Solar Irradiance using Machine learning models: A case study of two Andean Cities» (Diaz-Bedoya 2023)

Arquitecturas Transformer: para modelizar varios emplazamientos y horizontes. (Nascimento 2023)

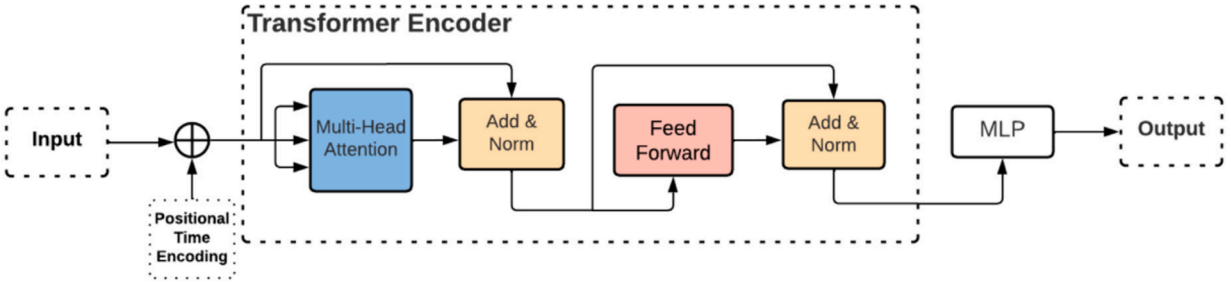


«Evaluation of the Transformer Architecture for Univariate Time Series Forecasting», (Lara-Benitez 2021)

¿Y en escenarios de pequeña escala?

Los emplazamientos pequeños suelen carecer de muchos datos de sensores: las referencias simples pueden superar a los modelos profundos cuando escasean los datos.

Aprovechar los sesgos inductivos: (Nascimento et al. 2023) Transformer integrado con transformada wavelet para prever la velocidad del viento y la potencia eólica en varias torres anemométricas de ciudades brasileñas y a distintas alturas (100-150 m).

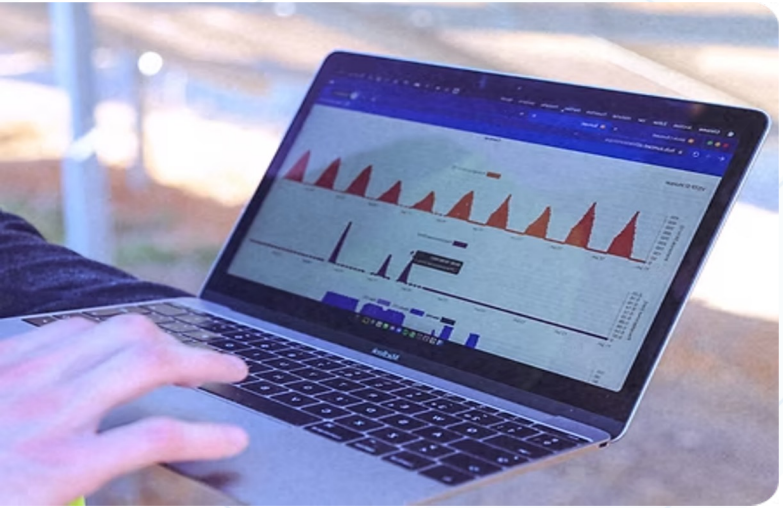


«A transformer-based deep neural network with wavelet transform for forecasting wind speed and wind energy», (Nascimento et al 2023)

El Transformer con wavelets logró errores de previsión menores que el LSTM en la mayoría de los emplazamientos y alturas, con mayor coherencia en las estimaciones de velocidad del viento y potencia.

Previsión operativa a gran escala

A escala nacional, el AA suele mejorar o posprocesar los datos meteorológicos, de demanda y de los operadores



Servicios de previsión meteorológica de SunCast, Chile. Fuente: (SunCast 2025)

País	Métodos	Principales resultados
Chile: velocidad del viento para la operación	TiDE híbrido + GraphCast	Mejoras del 4-21 % a corto plazo y del 5-23 % a medio plazo (Suri et al. 2024)
Francia: solar y eólica a escala nacional	AA con meteorología ERA5	Las redes neuronales alcanzaron un nRMSE del 4-10 % (Lindas et al. 2025)
Grecia: carga del día siguiente	RNN + aprendizaje activo + gemelo digital	Los modelos específicos siguen superando a los generalistas (Mylonas et al. 2024)
Europa: variables meteorológicas	Modelo meteorológico GNN + Transformer	Rendimiento comparable a la NWP y a las observaciones de superficie (Lang et al. 2024)

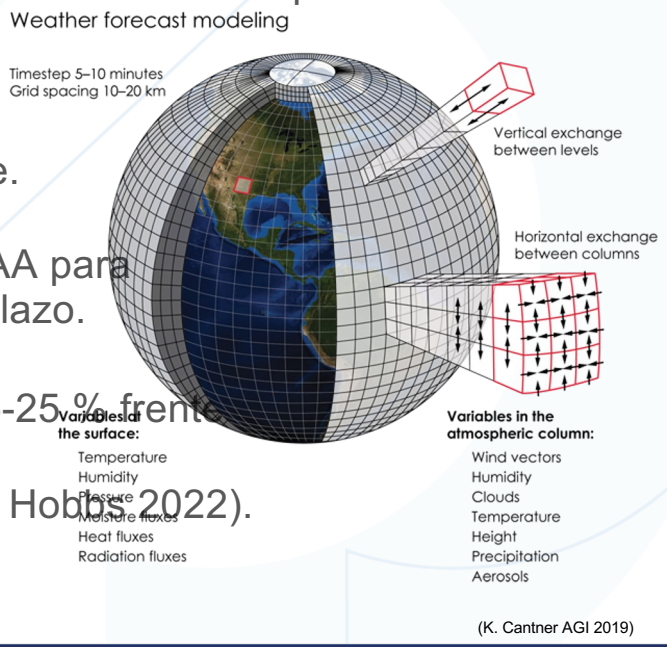
Reducción de escala y previsión espacial

El AA puede convertir previsiones meteorológicas gruesas o datos satelitales en previsiones renovables de alta resolución a nivel de emplazamiento.

Eólica: atención temporal sobre NWP + SCADA de las turbinas, codificadores de grafos espaciales para la disposición del parque.

Hidráulica: modelo lluvia-escorrentía + corrección residual con AA para los caudales de entrada y las consignas de las turbinas a corto plazo.

Potencial: las revisiones señalan reducciones del RMSE de ~15-25 % frente a la persistencia y ahorros de reservas de ~10-15 % cuando se usan previsiones probabilísticas en el despacho (Haupt 2018, Hobbs 2022).

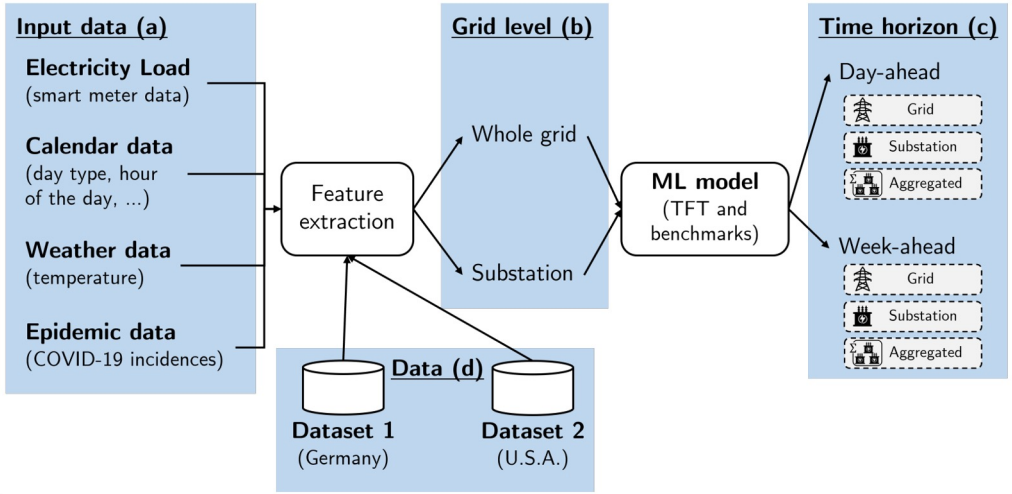


(K. Cantner AGI 2019)

Previsión de la demanda en la transición energética

La demanda es menos predecible con los VE, las bombas de calor, los prosumidores, la FV detrás del contador y los cambios de comportamiento.

El AA ayuda a nivel de alimentador, subestación y comunidad (Giacomazzi et al. 2023).

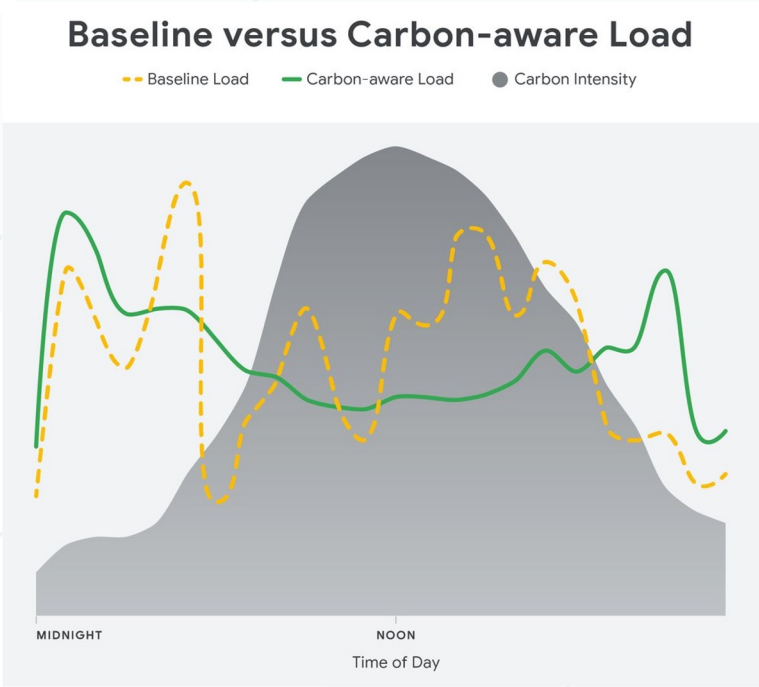


Las previsiones se convierten en acciones

Las previsiones alimentan:

- El despacho
- Las reservas
- Las ofertas en el mercado
- La programación del almacenamiento
- El desplazamiento de cargas según el carbono
- Las recomendaciones a los operadores.

(Todavía) un reto abierto:
las previsiones que integran la incertidumbre son más útiles que las predicciones puntuales.



«Our data centers now work harder when the sun shines and wind blows», (Radovanovic 2020)

Pregunta abierta

¿Qué debería optimizar una previsión?

Pausa

5 minutos



Encuesta

¿Qué es peor?

IA con restricciones físicas y optimización

Por qué las redes neuronales de caja negra no bastan

La IA para la operación de la red no es solo predicción:

- debe respetar la física, la seguridad y las restricciones operativas.

OPF: el flujo óptimo de potencia está en el centro de la operación de los sistemas eléctricos

- Minimizar el coste de operación de la red sujeto al balance de potencia, los límites de tensión, los límites térmicos y los límites de los generadores

$$\min_{y} \quad f(y;x)$$

$$\text{s.t.} \quad g(y;x) \leq 0, \qquad h(y;x) = 0$$

Aprender la factibilidad solo a partir de datos es un desperdicio cuando conocemos parte de la física.

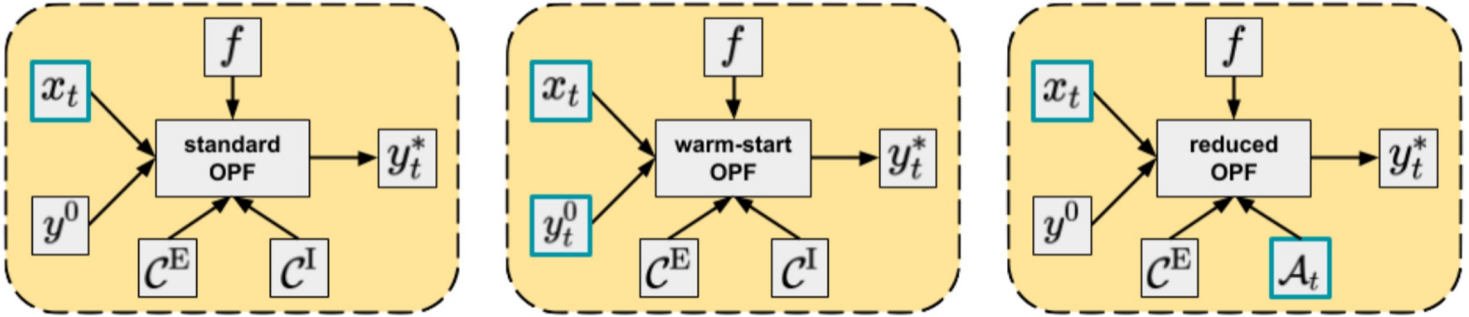
Estrategias de aprendizaje

Aprender las soluciones directamente

- Usar las NN como regresores: asocian parámetros con OPF.
- Sin garantía inmediata de factibilidad.
- Otra opción: predecir un número reducido de variables

Aprender modelos indirectos

- Arranque en caliente: usar la salida predicha y resolver el problema de optimización
- Usar las NN como clasificadores: aprender solo el conjunto activo.

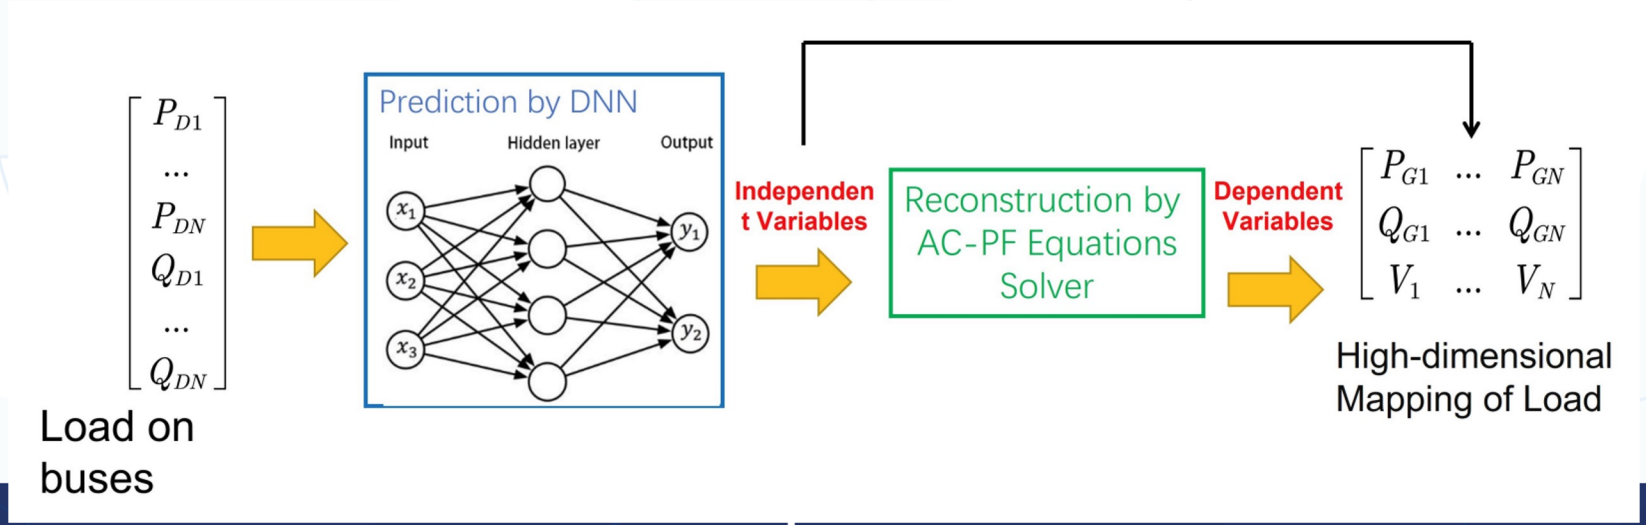


Principales enfoques para resolver el OPF. Se destacan los argumentos variables; los demás pueden ser fijos. (Mones 2021)

Por qué ahora hay que resolver el OPF con más frecuencia

Renovables, DER, VE, almacenamiento e incertidumbre generan muchos escenarios:

- Un enfoque (Pan et al. 2020), **valor**: soluciones más rápidas, una nueva forma de operar la red



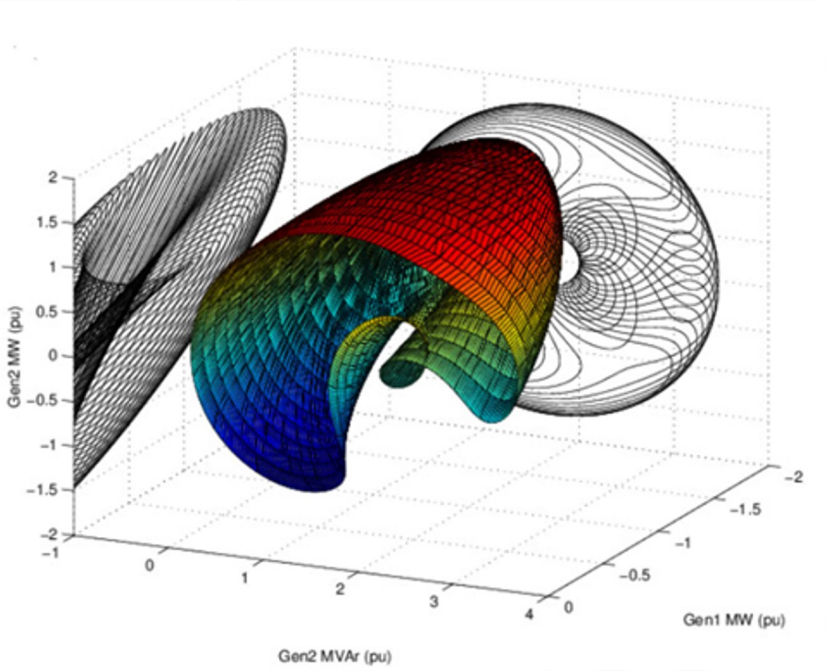
¿Cómo integran las NN el conocimiento físico?

Retos:

- Naturaleza no convexa de los sistemas eléctricos.
- Redes grandes y complejas.
- Garantizar una operación segura y fiable.

Enfoques:

- Penalizaciones en la función de pérdida
- Arquitecturas con restricciones
- Capas de flujo de potencia diferenciables e implícitas.

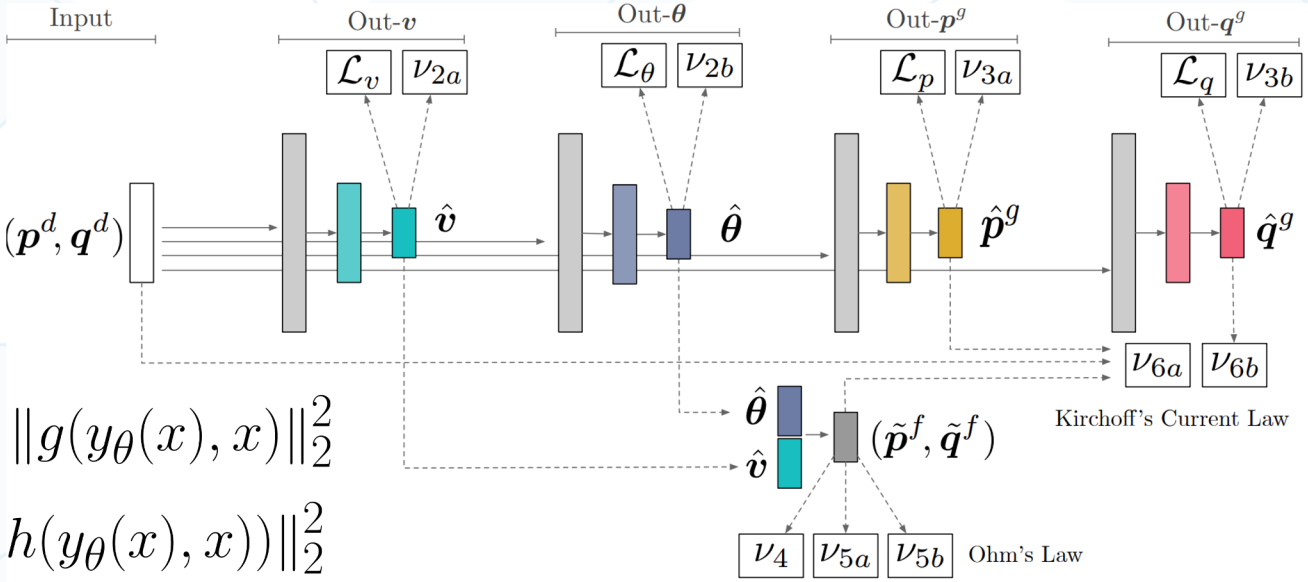


Espacio factible del flujo de potencia. Fuente: (Babiker 2025)

PINN y penalizaciones

Usar las restricciones conocidas como penalizaciones lagrangianas (Chatzos et al. 2020):

$$\mathcal{L}(\theta) = \mathcal{L}_{\text{data}}(\theta) + \lambda_g \left\| g(y_\theta(x), x) \right\|_2^2 + \lambda_h \left\| \max(0,\ h(y_\theta(x), x)) \right\|_2^2$$



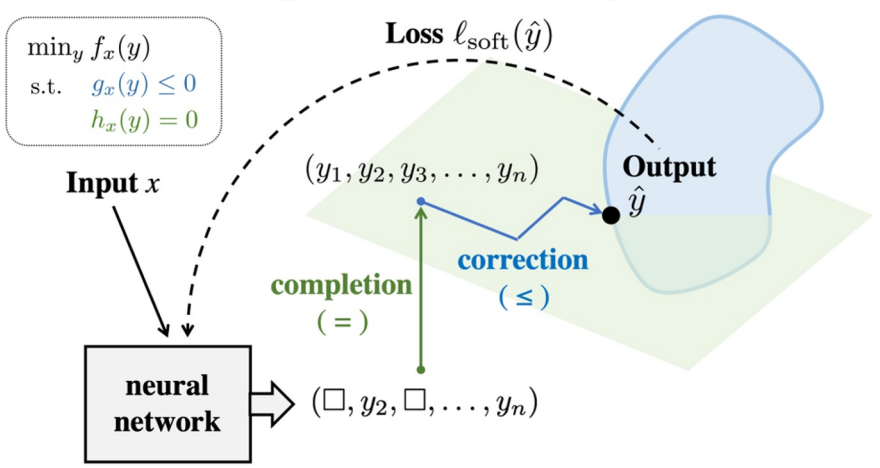
Modelo OPF-DNN (Chatzos et al. 2020)

Integrar las restricciones del sistema en las NN

Podríamos aprender a predecir una solución parcial:

- Completar las igualdades
- Corregir las desigualdades

Después, optimizar el objetivo (Donti et al. 2021)



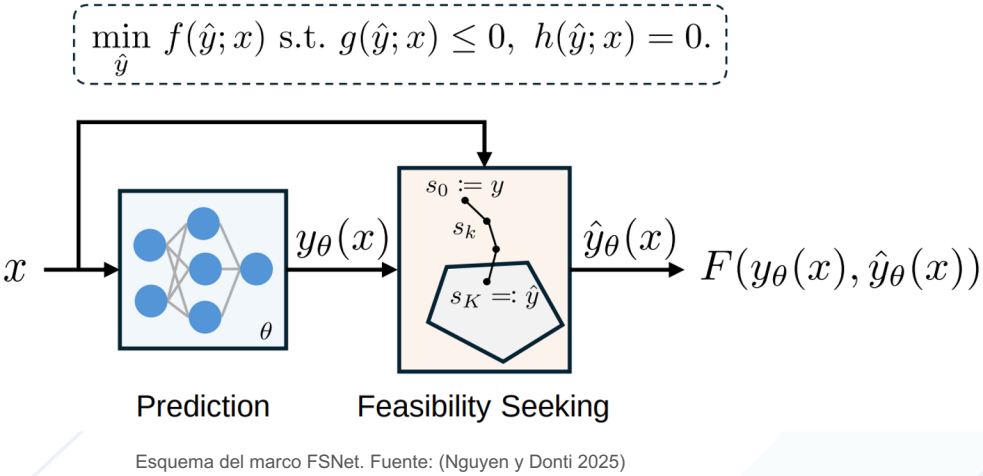
Esquema del marco DC3. Fuente: (Donti 2021)

Integrar las restricciones del sistema en las NN

Un segundo paso de optimización puede ayudar a buscar la factibilidad antes de la corrección, optimizando (Nguyen y Donti 2025):

$$\phi(s;x) = \|h(s;x)\|_2^2 + \left\|g^+(s;x)\right|$$

$$s_{k+1} = s_k - \eta_\phi \nabla_s \phi(s_k;x)$$



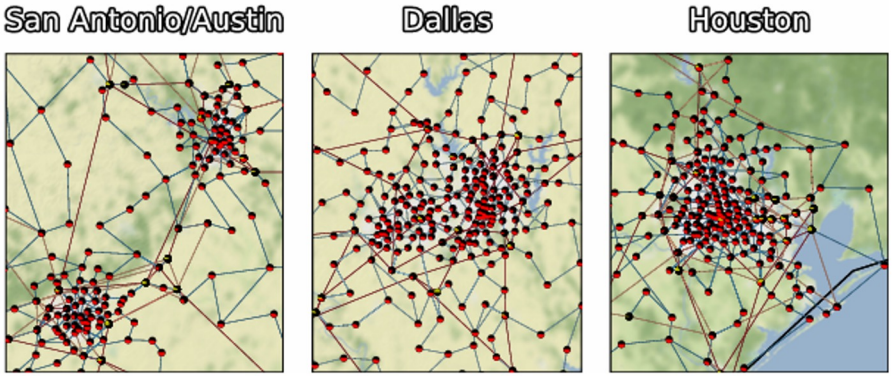
Esquema del marco FSNet. Fuente: (Nguyen y Donti 2025)

Después, entrenar con la pérdida:

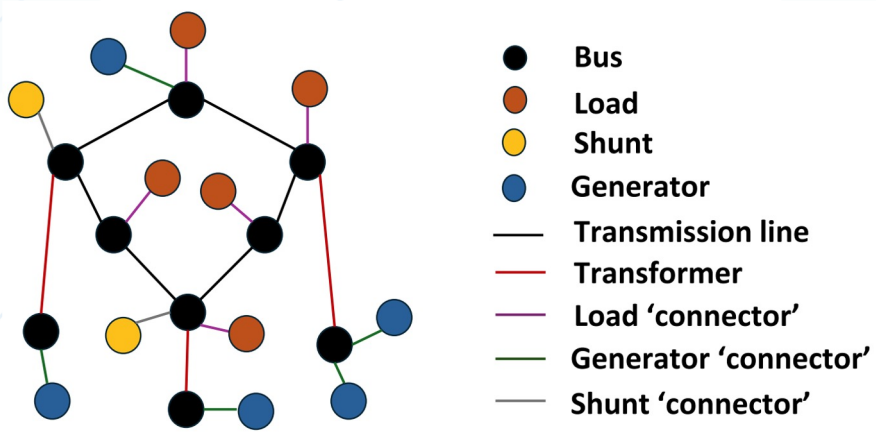
$$\mathcal{L}(\theta) = f(\hat{y}_\theta(x);x) + \frac{\rho}{2}\|y_\theta(x) - \hat{y}_\theta(x)\|_2^2$$

Aprendizaje de representaciones de la estructura del sistema

Las redes eléctricas son grafos: usar la red como estructura del modelo, desde soluciones iniciales de OPF que mejoran la eficiencia de la optimización (Diehl 2019) hasta una brecha de optimalidad <1 % y una **brecha zero-shot en contingencias N-1 <3 %** (Arowolo & Cremer 2025)



Mapa del conjunto de datos sintético TEXAS. Fuente: (Diehl 2019)



Grafos heterogéneos con distintos tipos de nodos y aristas (Arowolo & Cremer 2025)

Retos de despliegue de modelos y escasez de datos

IA responsable en los sistemas eléctricos: ¿qué puede salir mal?

En los sistemas eléctricos, un fallo de la IA no es solo un error de predicción

- Puede convertirse en un problema de fiabilidad, seguridad, equidad o ciberseguridad.

Seguridad física
Controles inviables o inseguros, más retrasos

Equidad
Los modelos pueden rendir peor en redes con pocos datos

Automatización y pérdida de control
Los operadores pueden confiar en exceso en la IA, sobre todo bajo presión

Rendición de cuentas
Registros robustos, fichas de modelo, fichas de datos y responsabilidades claras

Control humano: de la IA consultiva a la autonomía

Consultiva	**IA:** prevé, detecta anomalías, recomienda. **Persona:** decide y ejecuta la acción.	**Sí, habitual en la red**
Aprobar para actuar	**IA:** sugiere la acción de despacho/control. **Persona:** aprueba antes de ejecutar.	**Posible para decisiones más lentas**
Totalmente autónoma	**IA:** planifica, llama a herramientas, actúa en varios sistemas. **Persona:** casi siempre ausente.	**No está lista para operar la red**

NIST AI RMF, App. C (2023), EPRI Journal (2026)



Encuesta final

¿Debería un agente de IA controlar la red?

¿Por qué aún no IA agéntica para el control crítico de la red?

Cadenas impredecibles

Pequeños errores pueden propagarse dinámicamente a través de varias llamadas a herramientas.

Accesos con demasiados privilegios

Agentes con permisos amplios pueden actuar más rápido de lo que las personas pueden revisar.

Rendición de cuentas difícil

No está claro qué prompt, herramienta, memoria o estado del sistema causó una acción.

Riesgos de seguridad

Conectores, herramientas y contexto compartido amplían la superficie de ataque potencial.

Retos del despliegue de modelos en el Sur Global



(Filho 2024)

3500 millones de personas afectadas por problemas de calidad/fiabilidad eléctrica en los PIBM (Flashpohler et al. 2024)

La escasez de datos de red frena el despliegue

Los datos abiertos impulsan la innovación, pero pueden ampliar la desigualdad:

- Ampliar la representatividad de los datos con anonimización, agregación o privacidad diferencial.
- Codiseñar las iniciativas de datos con instituciones locales y comunidades afectadas.
- Combinar los datos abiertos con formación local y marcos de gobernanza (p. ej., ISO 50001, ética de la IA de la UNESCO).



«The Difference Between Data Governance vs. Data Management», (Semer 2019)

De las limitaciones de despliegue a bancos de pruebas de IA reutilizables

GridWatch: sensor enchufable de bajo coste con batería + enlace celular.

- ~1300 sensores desplegados en Acra durante 4 años, registrando tensión y frecuencia cada 2 minutos.

Accra Power: primer conjunto de datos de red a largo plazo en un PIBM (SAIDI, SAIFI, subtensión), motor de la investigación en IA para la energía.



«Helping global grids work smarter, not harder», (Flashpohler et al. 2024)

Conclusiones

Conclusiones

La IA como acelerador: integrar pilotos de previsión, control y automatización que muestren mejoras medibles de **fiabilidad**.

Diseño de pilotos: de la investigación al despliegue con **indicadores clave** claros: precisión, resiliencia (SAIDI/SAIFI) y tCO_2 evitadas.

Seguridad: establecer reglas básicas de intercambio de datos y capas de seguridad (aprendizaje **con restricciones**, **persona en el bucle**).

… ¡y **modelos y datos abiertos**!

Climate Change AI

Gracias

jecordov@espol.edu.ec

AIAS
Analytics and Artificial Intelligence for Sustainability

espol Centro de Tecnologías de Información