

## Cátedra ENIA-UPV en IA para el Desarrollo Sostenible

*Pablo García López — Memoria de prácticas extracurriculares*

*5 de febrero al 19 de julio de 2026 (471 horas)*

### 1. Introducción

Entre el 5 de febrero y el 19 de julio de 2026 realicé prácticas extracurriculares para la Cátedra ENIA-UPV en Inteligencia Artificial para el Desarrollo Sostenible, con una dedicación total de 471 horas repartidas en tres convenios consecutivos: 156 horas del 5 de febrero al 31 de marzo, 260 horas del 1 de abril al 30 de junio y 55 horas del 1 al 19 de julio.

El trabajo se desarrolló alrededor de un mismo caso real, una sala de maternidad porcina en una granja de Pedregales, y siguió una línea continua vinculada a mi TFM del Máster en Inteligencia Artificial, Reconocimiento de Formas e Imagen Digital. El objetivo fue construir, de extremo a extremo, un sistema para tratar datos energéticos y ambientales y predecir el consumo eléctrico agregado, dejando además preparada la base para la desagregación por tipo de dispositivo y para la transferencia científica.

El proyecto combina tres piezas: una API en FastAPI que orquesta la ingestión y el procesado, una aplicación en Streamlit para operar el flujo sin necesidad de código y una librería de experimentación para series temporales. A lo largo de estos meses el foco se desplazó de la infraestructura de datos a los modelos predictivos y, finalmente, a la redacción del artículo científico derivado del TFM.

### 2. Descripción de las tareas realizadas

#### 2.1. Periodo 1: infraestructura de datos y pipeline base (5 de febrero al 31 de marzo, 156 horas)

El primer periodo se centró en dejar un flujo de datos reproducible, desde los CSV en bruto hasta un dataset de entrenamiento en Parquet. Se adoptó una arquitectura por capas tipo *lakehouse*:

- **Raw:** ficheros originales tal cual se reciben, almacenados en un bucket compatible con S3.
- **Silver:** limpieza y normalización por proveedor con Polars.
- **Gold:** unificación temporal y construcción de variables para modelado.

En la práctica esto supuso automatizar la carga de históricos identificando proveedor, periodo y sensor; normalizar columnas heterogéneas, tipar valores numéricos y armonizar marcas temporales de señales eléctricas y ambientales; consolidar todo a una resolución común de 10 minutos reorganizando por sensor en una matriz multivariante; y calcular potencia y energía por circuito.

Paralelamente preparé la capa de operación. Diseñé en FastAPI los endpoints para listar datos brutos, subir ficheros, lanzar el procesado por capas y regenerar el dataset Gold, y dejé el pipeline preparado para ejecutarse por lotes con control de estado, tiempos y un resumen de incidencias. Probé la interfaz en Streamlit para que la carga de CSV y el disparo del procesado,

total o parcial, pudieran hacerse sin tocar código. Este conjunto hizo que repetir el pipeline fuera rápido y trazable.

Con la capa Gold ya estable empecé la experimentación inicial. Preparé un análisis exploratorio reproducible sobre calidad, correlaciones y relevancia de variables, con gráficas para documentación, y monté un marco común de carga, entrenamiento y evaluación. Como referencia inicial comparé dos modelos base, XGBoost y Prophet, con validación cruzada temporal y búsqueda en rejilla de hiperparámetros, reservando un conjunto de test que no intervino en el ajuste. Seguí métricas de error absolutas y relativas y generé informes comparativos. Todo ello quedó como *benchmark* interno para los periodos siguientes y como base estable para la redacción metodológica del TFM.

## 2.2. Periodo 2: modelado con Transformers y desagregación contextual (1 de abril al 30 de junio, 260 horas)

El segundo periodo continuó el mismo TFM y se dedicó al modelado avanzado. Implementé tres arquitecturas Transformer para series temporales para predecir la potencia agregada de la sala de maternidad: Informer, FEDformer y TimeXer.

La elección responde a que cada una aporta algo distinto. Informer, una de las primeras adaptaciones del Transformer a series temporales, funciona bien como referencia sólida. FEDformer trabaja en el dominio de la frecuencia, lo que encaja con la naturaleza cíclica de una sala de maternidad donde los patrones diarios y de climatización se repiten. TimeXer, más reciente, trata las variables exógenas sin mezclarlas de entrada y utiliza atención por parches, lo que en nuestras pruebas dio muy buen rendimiento con señales ambientales.

Para medir el valor real de los sensores ambientales planteé tres estrategias de entrada: (a) usar tanto variables ambientales (temperatura de sala, concentración de gases, presión y otras) como corrientes, (b) entrenar con sensores pero evaluar sin ellos, y (c) usar solo corrientes. De ese modo se puede cuantificar cuánto aportan los sensores y cómo se degrada la predicción si no están disponibles. Evalué cada configuración en dos horizontes, 1 hora y 24 horas, y validé los modelos previamente en el *benchmark* público ETTh1 antes de pasar a los datos de la granja.

Además de la predicción agregada, abordé la desagregación contextual de cargas. El problema consiste en estimar, a partir de las variables ambientales, la potencia demandada por cada tipo de dispositivo de la sala: ventiladores, fuentes de calor, iluminación y dispensadores de alimento. Para esta tarea utilicé TimeXer, que se mostró especialmente adecuado al separar la señal propia de consumo de la información exógena.

## 2.3. Periodo 3: redacción del artículo científico (1 al 19 de julio, 55 horas)

El último periodo se dedicó a convertir el trabajo del TFM en un artículo científico. El manuscrito, titulado *Multi-Horizon Transformer-Based Forecasting of Electrical Current Consumption in Pig Housing Indoor Environmental Data*, recoge las tres arquitecturas, las estrategias de entrada con y sin sensores, los dos horizontes de predicción y la validación en ETTh1, además del experimento de desagregación por dispositivo con TimeXer.

Durante estas semanas revisé resultados, unifiqué métricas y gráficas generadas en los periodos anteriores y organicé los artefactos (traces de ejecución, tablas y figuras) para que la metodología

quedara descrita de forma reproducible. El texto sistematiza el pipeline Raw-Silver-Gold, el protocolo de validación temporal sin fuga de información y los resultados comparativos entre Informer, FEDformer y TimeXer.

### 3. Conclusiones y perspectivas futuras

#### 3.1. Balance general

A lo largo de los cinco meses y medio se pasó de un conjunto de CSV heterogéneos a un pipeline completo y repetible, y de unos baselines con XGBoost y Prophet a una comparativa consistente entre Transformers. El flujo Raw-Silver-Gold, la API y la aplicación Streamlit dejaron una base de datos limpia y trazable, y el marco de experimentación permitió comparar modelos con el mismo protocolo y las mismas métricas. En conjunto, el trabajo cubre ingestión, transformación, modelado y difusión científica dentro de un mismo repositorio.

#### 3.2. Limitaciones y trabajo pendiente

El proyecto sigue en una etapa intermedia. Los datos reales aún presentan huecos, cambios de formato según proveedor y eventos anómalos que exigen más controles de calidad. El *benchmark* puede ampliarse a otras familias de modelos y la desagregación contextual necesita validación operativa más allá de los experimentos actuales. También queda trabajo para integrar el módulo NILM de forma estable en el pipeline y para automatizar por completo la generación de informes.

Para los próximos pasos conviene reforzar la validación de calidad a nivel de Silver, ampliar el comparador con alternativas recientes, consolidar la evaluación de la desagregación por dispositivo en condiciones reales y cerrar la documentación necesaria para el TFM y su difusión.

#### 3.3. Reflexión final

Estas prácticas me permitieron aplicar lo aprendido en el máster a un problema con impacto energético y ambiental directo. Pasar del dato crudo al modelo y del modelo al artículo obligó a cuidar tanto la ingeniería como el rigor experimental, y dejó una base clara sobre la que seguir construyendo.