

Memoria de Prácticas en Empresa

Nombre del alumno: Rita Jiménez Campos

Empresa: Cátedra ENIA-UPV en IA Desarrollo Sostenible

Tutor de empresa: Vicente Pelechano Ferragud

Tutor académico: Ángel Ortiz Bas

Período de prácticas: 07/01/2026 - 30/06/2026



Proyecto financiado por Secretaría de Estado de Digitalización e Inteligencia Artificial (TSI-100930-2023-9)

Índice

1. Introducción	3
1.1. Información general de la entidad	3
1.2. Organigrama de la entidad y situación del alumno	3
1.3. Descripción general de los proyectos de la entidad	4
2. Relación con el plan de estudios	4
2.1. Tecnologías, herramientas y conocimientos empleados	5
2.2. Relación con las asignaturas cursadas y por cursar	5
3. Diario de trabajo	6
4. Aprendizaje	7
4.1. Aportaciones técnicas y metodológicas	8
4.2. Aportaciones transversales y desarrollo profesional	8
4.3. Reflexión y proyección futura	8
5. Evaluación de las prácticas y sugerencias de mejora	9

1. Introducción

La presente sección contextualiza el entorno institucional de la Cátedra ENIA-UPV en Inteligencia Artificial y Desarrollo Sostenible, entidad de acogida de las prácticas. A continuación, se expone una visión global de la organización, detallando su sector de actividad, su organigrama y las líneas generales de los proyectos de investigación, optimización tecnológica y análisis predictivo que desarrolla.

1.1. Información general de la entidad

La Cátedra ENIA-UPV en Inteligencia Artificial y Desarrollo Sostenible es una estructura de investigación, docencia y transferencia de conocimiento adscrita a la Universitat Politècnica de València (UPV). Su actividad principal se enmarca en el sector de la Investigación, Desarrollo e Innovación (I+D+i) y la educación superior, operando en la intersección entre la tecnología avanzada y la sostenibilidad.

A diferencia de una empresa corporativa tradicional, los “servicios y productos” de la Cátedra se materializan en:

- **Investigación académica:** Publicación de artículos científicos, ponencias en congresos internacionales y estudios técnicos de vanguardia.
- **Transferencia tecnológica:** Desarrollo de soluciones de software, algoritmos y modelos matemáticos aplicables al sector público y privado para resolver retos medioambientales, sociales y económicos.
- **Formación y divulgación:** Organización de seminarios, talleres y jornadas para promover la adopción de la Inteligencia Artificial de manera ética y sostenible.

El trabajo de la entidad se estructura en torno a áreas de especialización técnica orientadas a la sostenibilidad, destacando departamentos o grupos de trabajo enfocados en la economía, la programación de modelos predictivos, la optimización algorítmica y el estudio de arquitecturas avanzadas como las redes neuronales de grafos y sus derivados.

1.2. Organigrama de la entidad y situación del alumno

La estructura organizativa de la Cátedra sigue un modelo académico y de investigación jerarquizado. A nivel estratégico, cuenta con una Comisión de Seguimiento formada por representantes de la UPV y de la empresa Nunsys, tal y como se refleja en su web oficial:

- **Comisión de Seguimiento:**
 - Maria Belén Picó Sirvent (Vicerrectorado de Investigación).
 - Vicent Botti Navarro (Director del Instituto Valenciano de Investigación en Inteligencia Artificial).
 - M^a Dolores Salvador Moya (Vicerrectorado de Empleo y Formación Permanente).
 - Jorge Reverte Sevillano (Gerente de Negocio de Transformación Digital, Nunsys).
 - Jorge Capel Planells (CTO Área Innovación de Producto, Nunsys).
 - Patricia Tamarit Tomas (Directora de Innovación en Producto, Nunsys).
- **Investigadores Principales (IPs) y Coordinadores de Área:** Lideran las líneas técnicas (modelado predictivo, optimización, etc.) y dirigen los proyectos en curso.
- **Investigadores Predoctorales y Postdoctorales:** Personal que ejecuta el núcleo del trabajo científico y técnico.

- **Personal Técnico y Estudiantes en Prácticas (Situación del becario):** Eslabón de apoyo a la investigación. Los alumnos en prácticas se sitúan en este nivel, colaborando transversalmente con los investigadores en tareas de soporte técnico, desarrollo de soluciones y ejecución experimental.

1.3. Descripción general de los proyectos de la entidad

La Cátedra impulsa proyectos de alta complejidad tecnológica cuyo denominador común es el uso de la Inteligencia Artificial para alcanzar los Objetivos de Desarrollo Sostenible (ODS). Las iniciativas generales se agrupan en las siguientes tipologías:

- **Proyectos de Modelado Predictivo y Análisis Económico:** Investigaciones centradas en la recopilación y tratamiento de grandes volúmenes de datos para predecir escenarios futuros. Esto incluye la evaluación del impacto económico de políticas medioambientales, la predicción de consumo energético y el diseño de modelos que ayudan a la toma de decisiones estratégicas.
- **Proyectos de Optimización Sostenible:** Desarrollo de algoritmos destinados a minimizar el consumo de recursos (energía, agua, materiales) en procesos industriales, logísticos o urbanos, mejorando la eficiencia general de los sistemas evaluados.
- **Investigación Aplicada en Deep Learning y Redes Estructuradas:** Proyectos de investigación fundamental y aplicada que exploran el uso de arquitecturas avanzadas, con especial énfasis en las redes neuronales de grafos (GNNs) y sus derivados. Estos proyectos buscan modelar relaciones complejas en entornos reales, como la topología de las redes eléctricas, las redes de transporte o las interacciones en ecosistemas naturales.

En concreto, el proyecto desarrollado a lo largo del periodo de prácticas consiste en el desarrollo de un modelo predictivo basado en Redes Neuronales Recurrentes Convolucionales de Difusión (DCRNN) para optimizar una red de suministro agroalimentaria. Su finalidad es sustituir los sistemas matemáticos tradicionales por una Inteligencia Artificial capaz de gestionar el inventario, predecir flujos y reconfigurar rutas logísticas en tiempo real ante cualquier imprevisto. Para lograrlo, el algoritmo se entrena evaluando el equilibrio entre los costes operativos, las capacidades físicas de las instalaciones (granjas, plantas, almacenes, centros de distribución y mercados) y la reducción del desperdicio alimentario.

2. Relación con el plan de estudios

La realización de las prácticas externas ha supuesto una oportunidad para trasladar al entorno profesional los conocimientos, metodologías y competencias adquiridos a lo largo del Grado en Ciencia de Datos de la Universitat Politècnica de València. Esta experiencia ha permitido comprobar cómo los contenidos impartidos en las diferentes asignaturas del plan de estudios convergen en proyectos reales, donde es necesario combinar conocimientos de programación, estadística, aprendizaje automático, optimización y gestión de datos para dar respuesta a problemas complejos.

El trabajo desarrollado durante las prácticas se ha centrado en la construcción y evaluación de un modelo predictivo basado en Redes Neuronales Recurrentes Convolucionales de Difusión (DCRNN) aplicado a la optimización de una red de suministro agroalimentaria. Este tipo de problema presenta una elevada complejidad debido a la existencia de dependencias espaciales y temporales entre los distintos elementos de la red logística, así como a la necesidad de generar predicciones precisas que permitan mejorar la planificación y la toma de decisiones. Por ello, el proyecto ha requerido la aplicación integrada de numerosas competencias propias de la ciencia de

datos, desde la adquisición y preparación de los datos hasta el diseño, entrenamiento, validación e interpretación de modelos avanzados de inteligencia artificial.

Además, las prácticas han permitido comprender mejor el ciclo de vida completo de un proyecto de ciencia de datos en un contexto empresarial y de investigación aplicada. Más allá del desarrollo técnico del modelo, ha sido necesario analizar los requisitos del problema, estudiar la calidad y disponibilidad de los datos, diseñar experimentos, comparar distintas configuraciones de modelos, interpretar los resultados obtenidos y comunicar las conclusiones de manera clara y rigurosa. Todo ello ha contribuido a desarrollar una visión más global del papel que desempeña la ciencia de datos en la resolución de problemas reales y en la generación de valor para las organizaciones.

2.1. Tecnologías, herramientas y conocimientos empleados

Durante el desarrollo del proyecto se han empleado diversas tecnologías y herramientas estrechamente relacionadas con los contenidos impartidos en el grado. La programación ha constituido uno de los pilares fundamentales del trabajo realizado, utilizándose lenguajes y entornos orientados al análisis de datos y al desarrollo de modelos de aprendizaje automático. Asimismo, se han utilizado bibliotecas especializadas para el tratamiento de datos, la construcción de redes neuronales profundas, el análisis de series temporales y la evaluación de modelos predictivos.

Dado que el proyecto se desarrolló sobre datos sintéticos, una parte fundamental del trabajo consistió en la definición y generación de un conjunto de datos capaz de representar de forma realista el comportamiento de una red de suministro agroalimentaria. Para ello, se diseñaron las características, restricciones y patrones temporales necesarios para simular el funcionamiento de la red y generar escenarios de demanda, producción y distribución sobre los que entrenar y evaluar los modelos predictivos.

Asimismo, fue necesario estructurar la información generada en formatos compatibles con la arquitectura DCRNN, definiendo tanto las series temporales asociadas a cada nodo como las relaciones espaciales existentes entre ellos mediante una representación basada en grafos. Este proceso permitió disponer de un entorno controlado para analizar el comportamiento del modelo y estudiar su capacidad predictiva ante diferentes configuraciones y escenarios simulados.

Por otro lado, el proyecto ha implicado el estudio de relaciones espaciales y temporales dentro de la red agroalimentaria, así como la construcción de grafos que representan las conexiones existentes entre los diferentes nodos del sistema. Este aspecto ha permitido profundizar en conceptos relacionados con la representación de datos complejos y la modelización de sistemas interconectados, competencias cada vez más relevantes dentro del ámbito de la ciencia de datos.

Asimismo, se han aplicado metodologías propias del aprendizaje automático y del aprendizaje profundo, incluyendo la definición de arquitecturas neuronales, la selección de hiperparámetros, la ejecución de procesos de entrenamiento y validación, y la comparación de métricas de rendimiento para evaluar la capacidad predictiva de los modelos desarrollados. Todo ello ha requerido una combinación de conocimientos teóricos y habilidades prácticas que reflejan el carácter multidisciplinar de la titulación.

2.2. Relación con las asignaturas cursadas y por cursar

Las actividades realizadas durante las prácticas guardan una relación directa con numerosas asignaturas del plan de estudios. En primer lugar, las competencias adquiridas en asignaturas como *Fundamentos de Programación*, *Programación* y *Estructuras de Datos* han resultado esenciales para desarrollar código eficiente, gestionar adecuadamente la información y diseñar soluciones escalables para el procesamiento de grandes volúmenes de datos.

Del mismo modo, los conocimientos obtenidos en *Bases de Datos* y *Gestión de Datos* han sido fundamentales para comprender la organización de la información, realizar procesos de extracción y transformación de datos, y garantizar la calidad de los conjuntos de datos empleados en el

proyecto. La importancia de una correcta gestión de los datos ha quedado especialmente patente durante las fases iniciales del trabajo, donde la preparación de la información constituye un paso imprescindible para obtener resultados fiables.

Por otra parte, la experiencia desarrollada se encuentra estrechamente vinculada con las asignaturas *Proyecto I*, *Proyecto II*, *Proyecto III* y *Gestión de proyectos*, ya que estas materias proporcionan una visión integral del desarrollo de proyectos de ciencia de datos. Durante las prácticas ha sido necesario aplicar metodologías similares a las trabajadas en estas asignaturas, abordando todas las etapas del proceso analítico, desde la definición del problema hasta la evaluación final de la solución propuesta.

En relación con el ámbito de la modelización y el aprendizaje automático, el proyecto presenta una conexión especialmente significativa con las asignaturas *Modelos Descriptivos y Predictivos I y II*, donde se estudian técnicas de análisis y construcción de modelos para la extracción de conocimiento a partir de los datos. La implementación de una arquitectura DCRNN ha permitido aplicar y ampliar muchos de los conceptos abordados en estas materias, especialmente aquellos relacionados con la predicción de fenómenos complejos y el uso de modelos avanzados basados en redes neuronales.

Asimismo, los contenidos de *Modelos Estadísticos para la Toma de Decisiones I y II* han proporcionado las bases necesarias para comprender los principios estadísticos que sustentan la construcción y evaluación de modelos predictivos. Del mismo modo, la asignatura *Técnicas de Previsión* guarda una relación directa con el objetivo principal del proyecto, ya que gran parte del trabajo realizado ha consistido en generar predicciones temporales precisas para mejorar la planificación dentro de la red de suministro agroalimentaria.

La experiencia también se encuentra alineada con los contenidos de *Técnicas Escalables en Aprendizaje Automático*, debido al uso de modelos de aprendizaje profundo y a la necesidad de gestionar procesos de entrenamiento computacionalmente exigentes. De forma complementaria, los conocimientos asociados a *Evaluación, Despliegue y Monitorización de Modelos* han resultado relevantes para analizar el comportamiento del sistema predictivo, comparar alternativas y valorar la robustez de las soluciones desarrolladas.

Finalmente, la asignatura *Optimización* mantiene una relación especialmente estrecha con el proyecto, ya que el objetivo último del modelo predictivo es contribuir a una mejor planificación y gestión de la red logística. Las predicciones obtenidas constituyen una herramienta de apoyo para la toma de decisiones y para la optimización de recursos dentro de la cadena de suministro, permitiendo mejorar la eficiencia operativa y reducir posibles costes asociados a una planificación inadecuada.

En conjunto, las prácticas han permitido consolidar y ampliar los conocimientos adquiridos durante la formación académica, demostrando cómo las diferentes áreas que integran la ciencia de datos se complementan para resolver problemas reales de elevada complejidad. Esta experiencia ha reforzado la conexión entre la formación universitaria y el entorno profesional, proporcionando una visión aplicada de los contenidos estudiados y evidenciando la utilidad de las técnicas de análisis de datos, aprendizaje automático e inteligencia artificial en sectores estratégicos como el agroalimentario y el logístico. Además, ha contribuido al desarrollo de competencias transversales relacionadas con la capacidad de análisis, la resolución de problemas, el trabajo autónomo, la gestión de proyectos y la comunicación de resultados, aspectos fundamentales para el futuro desempeño profesional como científico de datos.

3. Diario de trabajo

A continuación, se detalla el desarrollo temporal de las actividades llevadas a cabo durante las 26 semanas de duración del periodo de prácticas en la Cátedra ENIA-UPV. El plan de trabajo se estructuró de forma progresiva, abarcando desde el estudio del problema logístico hasta la implementación, entrenamiento y documentación de la arquitectura de aprendizaje profundo.

Semanas 1–4: Familiarización, contextualización y revisión bibliográfica

El periodo inicial se centró en comprender las líneas de investigación de la entidad y el funcionamiento de la cadena de suministro agroalimentaria. Se realizó una revisión teórica sobre modelos predictivos basados en grafos y se analizó el problema matemático original para entender las restricciones logísticas de cada fase operativa.

Semanas 5–7: Diseño de la propuesta inicial del modelo

Durante estas semanas se conceptualizó la adaptación del problema logístico a una estructura de red neuronal. Se definieron las variables clave para representar las instalaciones y las rutas, y se diseñó la lógica básica para que el modelo pudiera procesar tanto la distribución espacial como la evolución temporal del inventario.

Semanas 8–10: Refinamiento de la propuesta y especificación final

En esta fase se consolidó la arquitectura del modelo predictivo y se definió una función de pérdida multiobjetivo. Esta función se diseñó para equilibrar la viabilidad física, el rendimiento económico y la reducción del desperdicio, integrando además variables clave como la degradación del producto a lo largo del tiempo.

Semanas 10–15: Generación de datos sintéticos e implementación base

Con la metodología definida, se implementó el modelo de optimización clásico mediante programación en Python. Ante la falta de datos históricos masivos, se desarrolló un entorno de simulación para generar escenarios sintéticos que contemplaran fluctuaciones en la demanda, precios y otros factores operativos.

Semanas 16–19: Resolución masiva de escenarios (Ground Truth)

Esta etapa se dedicó a la computación intensiva de los escenarios generados previamente. Se resolvieron miles de simulaciones para obtener las decisiones logísticas óptimas en cada caso. Estos resultados se estructuraron y procesaron para conformar el conjunto de datos de entrenamiento (*ground truth*) de la Inteligencia Artificial.

Semanas 20–22: Implementación computacional de la arquitectura de red

Se procedió a la programación del modelo predictivo definitivo. Se codificaron las capas encargadas de asimilar la estructura de la red logística, la memoria temporal y la función de coste personalizada, asegurando que la IA penalizara cualquier violación de las reglas físicas del problema.

Semanas 22–24: Entrenamiento, validación y estrategias de robustez

Se llevó a cabo el entrenamiento formal del modelo utilizando el conjunto de datos generado. Se aplicaron técnicas para estabilizar el aprendizaje a largo plazo, se monitorizó el rendimiento de la red y se validó su capacidad para reconfigurar la cadena logística de forma eficiente ante imprevistos.

Semanas 24–26: Documentación, organización de entregables y cierre

Las últimas semanas se destinaron a comparar el rendimiento del modelo neuronal frente a los métodos tradicionales, destacando la mejora en los tiempos de computación. Finalmente, se procedió a la limpieza del código, la organización de los repositorios y la redacción de la memoria de prácticas y la documentación técnica.

4. Aprendizaje

La estancia realizada en la Cátedra ENIA-UPV ha supuesto una experiencia especialmente enriquecedora para mi desarrollo académico y profesional, permitiéndome dar el paso de un entorno principalmente teórico a un contexto real de investigación e innovación tecnológica.

Durante el desarrollo del proyecto he adquirido conocimientos y competencias de gran valor, tanto en el ámbito técnico como en el personal y profesional.

4.1. Aportaciones técnicas y metodológicas

- **Modelado predictivo avanzado:** He adquirido experiencia práctica en el diseño, implementación y entrenamiento de arquitecturas espaciotemporales avanzadas, en particular Redes Neuronales Recurrentes Convolucionales de Difusión (DCRNN), aplicadas a problemas complejos de predicción.
- **Integración entre optimización e inteligencia artificial:** He aprendido a trasladar modelos matemáticos de optimización, como los basados en Programación Lineal Entera Mixta (MILP), a entornos de aprendizaje profundo. Para ello, he trabajado con herramientas como Pyomo y técnicas de simulación Monte Carlo para la generación de grandes volúmenes de datos sintéticos destinados al entrenamiento de modelos.
- **Diseño y formulación de funciones objetivo:** He desarrollado la capacidad de diseñar funciones de coste multiobjetivo que permiten incorporar restricciones físicas, operativas y económicas dentro del proceso de aprendizaje, favoreciendo la obtención de soluciones más realistas y aplicables.

4.2. Aportaciones transversales y desarrollo profesional

- **Conocimiento sectorial y sostenibilidad:** He profundizado en la comprensión de la cadena de suministro agroalimentaria y de los desafíos asociados a su gestión. Esta experiencia me ha permitido valorar la importancia de equilibrar la eficiencia logística con objetivos de sostenibilidad, especialmente en lo relativo a la reducción del desperdicio alimentario.
- **Capacidad de aprendizaje autónomo:** He reforzado mi habilidad para analizar literatura científica reciente, identificar metodologías relevantes y aplicarlas de forma autónoma a problemas reales, abiertos y con un elevado grado de complejidad.
- **Pensamiento crítico y resolución de problemas:** El proyecto me ha permitido enfrentarme a retos técnicos que requerían evaluar diferentes enfoques, identificar limitaciones y proponer soluciones fundamentadas, fortaleciendo así mi capacidad de análisis y toma de decisiones.

4.3. Reflexión y proyección futura

Además de los conocimientos adquiridos, esta experiencia me ha permitido realizar una evaluación más precisa de mis fortalezas y áreas de mejora. El trabajo con redes logísticas complejas ha despertado mi interés por profundizar en el estudio de las redes neuronales de grafos y otras arquitecturas relacionadas, fundamentales para modelar de forma más eficiente este tipo de sistemas. Asimismo, la necesidad de incorporar restricciones físicas y operativas dentro del proceso de aprendizaje ha puesto de manifiesto la importancia de seguir ampliando mis conocimientos en optimización matemática, con el objetivo de desarrollar en el futuro modelos más robustos, eficientes y alineados con las necesidades del mundo real.

En conjunto, estas prácticas han contribuido significativamente a mi formación como científica de datos, proporcionándome una visión más completa de la investigación aplicada y reforzando mi interés por continuar desarrollando soluciones basadas en inteligencia artificial para abordar problemas complejos con impacto social y económico.

5. Evaluación de las prácticas y sugerencias de mejora

La valoración global de las prácticas es muy positiva, ya que me han permitido participar en un proyecto de investigación aplicado a un problema real y adquirir conocimientos avanzados tanto en inteligencia artificial como en optimización. No obstante, el desarrollo del trabajo también ha planteado diversos retos que han supuesto una importante oportunidad de aprendizaje y han contribuido a identificar áreas en las que debo seguir profundizando.

Uno de los aspectos más satisfactorios de la experiencia ha sido la capacidad de comprender e implementar una solución basada en técnicas avanzadas de aprendizaje profundo para un problema de optimización logística de gran complejidad. A medida que avanzaba el proyecto, fui capaz de relacionar conceptos procedentes de distintas disciplinas, como la optimización matemática, la comprensión de un modelo de logística y las redes neuronales, integrándolos en una misma metodología de trabajo.

Sin embargo, la principal dificultad encontrada durante las prácticas no estuvo relacionada con las herramientas de programación utilizadas, sino con la comprensión del modelo matemático que describía el problema. La cadena de suministro agroalimentaria analizada estaba representada mediante un modelo con un elevado número de variables, parámetros y restricciones, todos ellos estrechamente interrelacionados. Entender el significado de cada variable, cómo influía sobre las demás y de qué manera las decisiones tomadas en una parte del sistema afectaban al comportamiento global del modelo requirió un esfuerzo considerable durante las primeras etapas del proyecto.

Además, la transición desde un modelo de optimización clásico basado en Programación Lineal Entera Mixta (MILP) hacia un enfoque de aprendizaje profundo exigió comprender en profundidad la lógica subyacente del problema. No bastaba con conocer las ecuaciones matemáticas; era necesario interpretar qué representaba cada elemento dentro del contexto logístico real y cómo trasladar esa información al diseño de los datos de entrenamiento, la arquitectura neuronal y las funciones de coste utilizadas. Este proceso de abstracción y conexión entre distintos niveles de modelado constituyó uno de los mayores desafíos de la estancia.

A medida que fui profundizando en el proyecto, comprendí que muchas de las dificultades iniciales se debían a la necesidad de desarrollar una visión global del sistema antes de poder analizar correctamente cada una de sus partes. Una vez alcanzada esa comprensión, resultó mucho más sencillo interpretar los resultados obtenidos, detectar posibles inconsistencias y proponer mejoras en el modelo.

De cara al futuro, identifiqué dos líneas principales de mejora. En primer lugar, considero necesario fortalecer mis conocimientos en optimización matemática y modelado de sistemas complejos, ya que una comprensión más profunda de estas disciplinas permitiría abordar con mayor rapidez problemas similares. En segundo lugar, me gustaría profundizar en el estudio de las redes neuronales de grafos y otras arquitecturas especializadas para datos estructurados, dado que constituyen una herramienta especialmente adecuada para representar y modelar redes logísticas complejas como las analizadas durante estas prácticas.

En definitiva, las dificultades encontradas no solo no han supuesto un obstáculo para el aprovechamiento de la estancia, sino que han contribuido de forma significativa a mi aprendizaje. La experiencia me ha permitido desarrollar una comprensión más profunda de la relación entre optimización e inteligencia artificial y me ha ayudado a identificar los conocimientos que deseo seguir ampliando en mi futura trayectoria académica y profesional.