



Campus de la UNA
SAN LORENZO-PARAGUAY

UNIVERSIDAD NACIONAL DE ASUNCIÓN
FACULTAD POLITÉCNICA
CONSEJO DIRECTIVO

RESOLUCIÓN 25/18/159-00
ACTA 1226/25/08/2025

“POR LA CUAL SE APRUEBA EL PROGRAMA DE ESTUDIO DE LA ASIGNATURA TÉCNICAS AVANZADAS DE APRENDIZAJE AUTOMÁTICO, DE CARRERAS DE GRADO, SEDE SAN LORENZO, FILIAL VILLARRICA Y FILIAL CORONEL OVIEDO”

VISTO: El Memorando DA/1707/2025 del Director Académico de la FP-UNA, Prof. MSc. Felipe Santiago Uzabal Ecurra, con el cual remite el Memorando CCPTCC/030/2025 de la Comisión Coordinadora del Proyecto de Transformación Curricular de Carreras de Grado de la FP-UNA, en el que presenta la propuesta de Programa de Estudio de Asignatura de las Carreras de Grado.

CONSIDERANDO: La Ley 4995/2013 de Educación Superior, el Estatuto de la Universidad Nacional de Asunción y las deliberaciones sobre el tema.

Que la Comisión Coordinadora del Proyecto de Transformación Curricular de Carreras de Grado, solicita la aprobación del Programa de Estudio de la asignatura **“Técnicas Avanzadas de Aprendizaje Automático”**, la cual es común entre Carreras de Grado.

Que los programas fueron elaborados conforme a las disposiciones establecidas por el Consejo Nacional de Educación Superior (CONES) en materia de **créditos académicos**, según lo dispuesto en la Resolución CONES N.º 221/2024, que regula el *Sistema de Créditos Académicos – Paraguay* y los criterios para su publicación en las carreras de grado.

**EL CONSEJO DIRECTIVO DE LA FACULTAD POLITÉCNICA
RESUELVE:**

25/18/159-01 APROBAR el Programa de Estudio de la Asignatura **“Técnicas Avanzadas de Aprendizaje Automático”**, de carreras de Grado, Sede San Lorenzo, Filial Villarrica y Filial Coronel Oviedo, detallado en el ANEXO 121 de la presente Acta.

25/18/159-02 COMUNICAR, copiar y archivar.

Prof. Abg. Joel Arsenio Benítez Santacruz
Secretario



Prof. Ing. Silvia Teresa Leiva León, MSc.
Presidenta



Campus de la UNA
SAN LORENZO-PARAGUAY

UNIVERSIDAD NACIONAL DE ASUNCIÓN
FACULTAD POLITÉCNICA
CONSEJO DIRECTIVO

Resolución 25/18/159-00 Acta 1226/25/08/2025
ANEXO 121

DEPARTAMENTO DE ENSEÑANZA DE INFORMÁTICA
PROGRAMA DE ESTUDIO

I. IDENTIFICACIÓN

Nivel				Grado									
Asignatura				Técnicas Avanzadas de Aprendizaje Automático									
Carrera				Plan		Sede/Filial		Carácter		Semestre		Prerrequisitos	
Ingeniería en Informática				2026		Sede San Lorenzo		Electiva 1		Séptimo		Seguridad Informática, Programación de Aplicaciones 2, Bases de Datos 2, Ingeniería de Software 1.	
Licenciatura en Ciencias Informáticas				2026		Sede San Lorenzo/Filial Villarrica/Filial Coronel Oviedo		Electiva		***		Ingeniería de Software I, Base de Datos II, Seguridad Informática, Programación Frontend.	
Semanal					Periodo								
HT		HP		HTD	HTI	HS	PA	THTD		THTI		THA	CA-PY
2		2		4	4	8	18	72		72		144	5

- *HT: Horas Teóricas semanales.
- *HP: Horas Prácticas semanales.
- *HTD: Horas semanales de Trabajo académico con acompañamiento Docente.
- *HTI: Horas semanales de Trabajo académico Independiente del estudiante.
- *HS: Horas Semanales (HTD+HTI).
- *PA: Periodo Académico en semanas.
- * THTD: Total de Horas de Trabajo académico con acompañamiento Docente (HTD*PA).
- * THTI: Total de Horas de Trabajo académico Independiente del estudiante (HTI*PA).
- * THA: Total de Horas de trabajo Académico (THTD+THTI).
- * CA-PY: Créditos académicos de la asignatura.

II. FUNDAMENTACIÓN

El aprendizaje automático (del inglés, "Machine Learning") es un subcampo de la Inteligencia Artificial que intercepta la matemática, la estadística y las ciencias de la computación. En el aprendizaje automático se tiene como objetivo desarrollar técnicas/modelos que permitan a las computadoras aprender a partir de datos observados e interacción con el ambiente de simulación. Es decir, diseñar programas que puedan generalizar comportamientos a partir de ejemplos suministrados.

El impacto del aprendizaje de máquinas es vasto en la clasificación, predicción, búsqueda de patrones que pueden ser aplicados en el sector de la educación, medicina, biología, física, ámbitos financieros, planificación e industria, interacción hombre máquina, robótica, visión artificial, gestión de datos, toma de decisión, pronósticos y predicción por mencionar algunas.

En general el aprendizaje de máquinas se puede dividir en: supervisado, no supervisado, semi supervisado y por refuerzo. Siendo el aprendizaje supervisado y no supervisado las áreas centrales del presente trabajo en donde se busca responder algunas preguntas: ¿cómo el desempeño de aprendizaje varía con el número

varía con el número de ejemplos de entrenamiento presentados? y ¿qué algoritmos de aprendizaje son más apropiados para varias tareas de aprendizaje?

Las técnicas avanzadas de aprendizaje de máquinas se caracterizan por enfoques combinados y modelos de mayor complejidad. En el primer caso, nos encontramos con enfoque ensamblados, diseño de kernel de alto grado para SVM, y reducción de la dimensionalidad. En el segundo caso, se construyen modelos complejos con las redes neuronales profundas.

En relación a la naturaleza de la asignatura, se aborda de manera teórico-práctica, se combinarán conceptos teóricos con ejercicios prácticos. La organización de la asignatura se basa en los ejes temáticos, se incluyen conceptos fundamentales como: Análisis de técnicas. Ensamblados, métodos de kernel, técnicas de reducción de dimensionalidad.

III. COMPETENCIAS DEL PERFIL DE EGRESO ASOCIADAS

- 1. Aplicar en la práctica profesional los valores humanos, la ética y los mecanismos de seguridad laboral.
- 2. Evaluar el comportamiento de diversos fenómenos disciplinares e interdisciplinares relacionados con la informática con una visión de sistema, mediante modelos teóricos validados y actualizados, capaces de abarcarlos integralmente en un contexto de incertidumbre.
- 3. Aplicar, producir y difundir conocimientos técnicos y científicos en el área de la informática.

IV. ORGANIZACIÓN DE LA ASIGNATURA

Unidades	Contenidos	Resultados de aprendizaje
1. Introducción al Aprendizaje de Máquinas.	1.1. El Problema del Aprendizaje. 1.2. Tipos de aprendizajes. 1.3. Ejemplo de una simple máquina de aprendizaje. 1.4. Problemas de Clasificación. 1.5. Conceptos de conjuntos de entrenamiento, de validación y de verificación.	1. Describe el problema del aprendizaje 2. Reconoce las características de los tipos de aprendizaje 3. Aplica una máquina simple de aprendizaje de máquina a un problema básico 4. Describe apropiadamente conjunto de entrenamiento, validación y verificación
2. Sistemas ensamblados.	2.1. Introducción al Ensamble de Algoritmos 2.2. Métodos Básicos de Ensamble 2.3. Métodos Avanzados de Ensamble. 2.4. Evaluación y Afinación de Modelos Ensamblados. 2.5. Aplicaciones Prácticas. 2.6. Desafíos y Consideraciones. 2.7. Herramientas y Bibliotecas. 2.8. Proyectos Reales.	1. Explica los principios fundamentales y la lógica detrás de los métodos de ensamble en aprendizaje automático. 2. Diferencia entre los diversos métodos de ensamble, destacando sus ventajas, desventajas, y los contextos en los que cada uno es más efectivo. 3. Implementa y ajusta modelos de ensamble básicos y avanzados utilizando bibliotecas populares de Python, como scikit-learn, XGBoost, LightGBM, y CatBoost. 4. Desarrolla y evalúa modelos de ensamble en escenarios de clasificación y regresión, aplicando

Unidades	Contenidos	Resultados de aprendizaje
		técnicas de validación cruzada y optimización de hiperparámetros.
3. Métodos Kernel.	3.1. Introducción a los Métodos Kernel. 3.2. Fundamentos Matemáticos de los Métodos Kernel. 3.3. SVM con Kernel (Support Vector Machines). 3.4. Métodos Kernel para Análisis de Componentes Principales (KPCA). 3.5. Métodos Kernel en Regresión. 3.6. Métodos Kernel para Clustering. 3.7. Selección y Combinación de Kernels. 3.8. Implementación Práctica de Métodos Kernel. 3.9. Aplicaciones Avanzadas de Métodos Kernel. 3.10. Desafíos y Consideraciones Prácticas	1. Evalúa y compara la eficacia de los métodos kernel en comparación con métodos tradicionales de aprendizaje automático. 2. Selecciona y combina kernels adecuados para diferentes tareas utilizando criterios específicos y técnicas como MultipleKernelLearning (MKL). 3. Implementa métodos kernel en proyectos prácticos que aborden problemas reales, demostrando un entendimiento profundo tanto teórico como práctico.
4. Reducción de la dimensionalidad.	4.1. Introducción a la Reducción de Dimensionalidad 4.2. Técnicas Basadas en la Selección de Características. 4.3. Técnicas Basadas en la Extracción de Características. 4.4. Técnicas No Lineales y ManifoldLearning. 4.5. Técnicas Basadas en Modelos Probabilísticos. 4.6. Evaluación de Técnicas de Reducción de Dimensionalidad. 4.7. Aplicaciones Prácticas.	1. Explica los principios fundamentales de la reducción de dimensionalidad y su importancia en el aprendizaje automático. 2. Describe y diferencia entre técnicas de selección de características y técnicas de extracción de características. 3. Compara y evalúa la eficacia de métodos no lineales frente a métodos lineales en la reducción de dimensionalidad. 4. Utiliza herramientas y bibliotecas de Python para implementar y evaluar diferentes técnicas de reducción de dimensionalidad, optimizando su aplicación en grandes volúmenes de datos.

IV. ESTRATEGIAS DIDÁCTICAS

En el desarrollo del programa se aplicarán estrategias didácticas conducentes a la apropiación teórica y la ejecución práctica de procesos y procedimientos, a saber:

- **Clases Magistrales:** se presentará una introducción teórica con los conceptos fundamentales de la asignatura utilizando ejemplos claros y aplicaciones en el mundo real.
- **Aprendizaje basado en problemas:** exposición por parte del docente de los conceptos básicos por unidad, con materiales de lectura y ejemplos orientados a la enseñanza de las competencias específicas de la asignatura. El estudiante buscará resolver un problema a través del conocimiento que adquirió en el aula.



- **Aprendizaje basado en proyectos:** el docente propondrá la realización de un proyecto que involucre todos los resultados de aprendizaje de la materia. De esta forma el estudiante participa activamente en su aprendizaje, desarrollando diferentes habilidades para solucionar un problema a través de este proyecto.
- **Aula Invertida:** se proporcionará a los estudiantes acceso a materiales de aprendizaje, como videos, lecturas y ejercicios a ser accedidos mediante una planificación. Estos recursos cubrirán los conceptos teóricos fundamentales de la asignatura.

La elección particular de la estrategia didáctica aplicada será explícita en el Planeamiento de la Asignatura, de acuerdo con el perfil de los estudiantes, los recursos disponibles y el contexto educativo.

VI. ESTRATEGIAS EVALUATIVAS

Procesos de producción grupales e individuales, pruebas individuales orales y/o escritas durante el desarrollo de las unidades con diálogos e interpretaciones que los estudiantes realicen sobre los contenidos, debates, retroalimentación en casos necesarios y actividades que amplíen el conocimiento.

Con fines de calificación y promoción se aplicará el Reglamento Académico vigente en la institución que prevé valoraciones de proceso y final.

VII. MEDIOS AUXILIARES

Pizarras, marcadores, computadoras, proyector, parlantes para multimedia, plataforma virtual, sala de laboratorio equipada para prácticas con sistemas operativos Linux o Windows y acceso a Internet.

VIII. BIBLIOGRAFÍA

- Bishop, C. M. (2006). Pattern Recognition and Machine Learning. Springer.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer.
- Izenman, A. J. (2008). Modern Multivariate Statistical Techniques: Regression, Classification, and Manifold Learning. Springer.
- Murphy, K. P. (2012). Machine Learning: A Probabilistic Perspective. MIT Press.
- Van Der Maaten, L., Postma, E., & Van den Herik, J. (2009). Dimensionality Reduction: A Comparative Review. Journal of Machine Learning Research, 10(66-71), 13.
- Saul, L. K., & Roweis, S. T. (2003). Think Globally, Fit Locally: Unsupervised Learning of Low Dimensional Manifolds. Journal of Machine Learning Research, 4(Jun), 119-155.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.
- Van Der Maaten, L., & Hinton, G. (2008). Visualizing Data using t-SNE. Journal of Machine Learning Research, 9(Nov), 2579-2605.
- Cunningham, J. P., & Ghahramani, Z. (2015). Linear Dimensionality Reduction: Survey, Insights, and Generalizations. Journal of Machine Learning Research, 16(1), 2859-2900.
- McInnes, L., Healy, J., & Melville, J. (2018). UMAP: Uniform Manifold Approximation and Projection for Dimension Reduction. arXiv preprint arXiv:1802.03426.

