

CURSO DE POSGRADO

APRENDIZAJE AUTOMÁTICO (MACHINE LEARNING)

INFORMACIÓN AMPLIADA

APRENDIZAJE AUTOMÁTICO (MACHINE LEARNING)



Tipo de actividad: Curso de posgrado

Denominación: Aprendizaje Automático (Machine Learning)

Destinatarios: Egresados universitarios de carreras de grado del área en Ciencias de la Computación, Ingeniería, Matemática, Estadística o disciplinas afines, interesados en iniciarse en la Inteligencia Artificial.

Carga horaria: 40 horas.

Dictado del curso: 16/03/2026 al 10/04/26

Inscripción: hasta el 12/03/26 por [SIU Guaraní](#)

Modalidad: Virtual

Arancel:

- General: \$ 90.000
- Descuento del 20% para docentes ordinarios y alumnos de posgrado de la FaCENA.
- Alumnos extranjeros: USD 80.00

Fundamentación

El Aprendizaje Automático constituye la base de la Inteligencia Artificial moderna. A partir de modelos estadísticos y algoritmos, permite construir sistemas capaces de aprender de los datos. Este curso ofrece una formación introductoria con énfasis en la práctica, dirigida a profesionales que deseen incorporar herramientas de análisis y modelado predictivo en su área de desempeño.

Contenidos

1. Introducción a la Inteligencia Artificial y al Aprendizaje Automático. Se presenta el concepto general de Inteligencia Artificial (IA) y su relación con el Aprendizaje Automático (Machine Learning, ML). Se analizan los principales tipos de aprendizaje (supervisado, no

supervisado y por refuerzo), sus aplicaciones prácticas y el flujo básico de un proyecto de ML: recolección de datos, entrenamiento, validación y evaluación de modelos.

2. Regresión lineal y logística. Se estudian los modelos de regresión más utilizados para problemas de predicción y clasificación. La regresión lineal se aplica a variables continuas, mientras que la regresión logística se emplea en problemas de clasificación binaria. Se explican los conceptos de función de costo, coeficientes, ajuste del modelo y métricas de desempeño.
3. Árboles de decisión y Random Forest. Se introduce la técnica de los árboles de decisión como modelo interpretable basado en reglas, y su extensión, los bosques aleatorios (Random Forest), que combinan múltiples árboles para mejorar la precisión y reducir el sobreajuste. Se discuten sus ventajas, limitaciones y parámetros de ajuste.
4. Máquinas de soporte vectorial (SVM). Se presentan los métodos de agrupamiento más comunes dentro del aprendizaje no supervisado. Se estudia el algoritmo k-means y las técnicas de clustering jerárquico, aplicadas a la segmentación de datos sin etiquetas, junto con estrategias para determinar el número adecuado de grupos. Clustering (k-means, jerárquico).
5. Validación cruzada y métricas de evaluación. Se explican las técnicas para evaluar el rendimiento y la capacidad de generalización de los modelos, como la validación cruzada y las métricas de desempeño.
6. Taller práctico con scikit-learn. Se realiza un taller aplicado utilizando la biblioteca scikitlearn de Python, implementando los algoritmos estudiados sobre conjuntos de datos reales. Se guía al estudiante en todo el proceso: carga de datos, entrenamiento, validación y análisis de resultados.

Objetivos

Que el/la estudiante logre:

- Comprender los fundamentos teóricos y prácticos del Machine Learning.
- Implementar modelos clásicos de clasificación y predicción.

- Desarrollar competencias en análisis y manejo de datos.

Objetivos específicos:

- Manejar librerías de Python aplicadas al aprendizaje automático.
- Aplicar algoritmos de regresión, árboles de decisión, máquinas de soporte vectorial (SVM) y clustering.
- Evaluar modelos mediante métricas de desempeño.
- Desarrollar mini-proyectos prácticos aplicados a casos reales.

Metodología de enseñanza

El curso se desarrollará en modalidad virtual, combinando instancias sincrónicas y asincrónicas. Se priorizarán las clases virtuales interactivas con exposición docente, acompañadas de talleres prácticos en Google Colab que permitan a los estudiantes aplicar de manera inmediata los conceptos teóricos.

Se propondrán actividades individuales y grupales de producción, análisis y resolución de problemas, fomentando el intercambio colaborativo mediante foros de discusión y espacios de trabajo en línea. Asimismo, se desarrollarán mini-proyectos aplicados que promuevan la autonomía, la investigación y la búsqueda de información por parte de los participantes, integrando la práctica profesional con los contenidos del curso.

Las estrategias de enseñanza contemplarán el análisis de casos reales, la simulación y modelización con herramientas TIC, la elaboración de informes breves y la reflexión crítica en torno a los resultados obtenidos. Se prevé un sistema de tutorías de seguimiento tanto sincrónicas como asincrónicas, destinadas a orientar la realización de trabajos prácticos, la revisión de avances en los proyectos y la preparación de la evaluación final.

Los recursos didácticos incluirán guías de lectura, tutoriales, datasets abiertos, videos explicativos y cuadernos de programación interactivos. De este modo, se garantizará un aprendizaje activo, progresivo y aplicado a situaciones concretas, favoreciendo el desarrollo de competencias en el campo del Aprendizaje Automático.

Instancias de evaluación y aprobación

La evaluación se llevará a cabo de manera continua y formativa, utilizando las herramientas que ofrece el Aula Virtual UNNE y otros entornos TIC de apoyo. Se implementarán actividades tanto sincrónicas como asincrónicas que permitan verificar la adquisición de conocimientos, el desarrollo de competencias técnicas y la capacidad de aplicar los contenidos en contextos prácticos.

Docentes:

Docente Coordinadora: Mgter. Paola L. Schlesinger.

Docente Dictante: Dr. Guillermo Horacio Ramírez Cáceres

Docente Tutor Virtual: Lucas Oviedo.

Bibliografía General

Bishop, C. Pattern Recognition and Machine Learning. Springer, 2006.

Géron, A. Hands-On Machine Learning with Scikit-Learn, Keras & TensorFlow. O'Reilly, 2022.

Hastie, T., Tibshirani, R., Friedman, J. The Elements of Statistical Learning. Springer, 2009.