



Resolución de Consejo Directivo **865 / 2023 - EXA -UNSa**

Exp. Nro 596/2023-EXA-UNSa: Autoriza dictado del curso "Fundamentos matemáticos del aprendizaje automático (ML: Machine Learning)", como materia optativa para la Maestría en Matemática Aplicada, a cargo del Dr. Edgardo Javier Trenti.

De: **EXACTAS-Dirección de Posgrado**



Salta,
12/12/2023

VISTO la presentación efectuada por el Dr. Edgardo Javier TRENTI y el Mag. Gustavo Ramiro RIVADERA, por la cual proponen el dictado del curso "*Fundamentos Matemáticos del aprendizaje automático (ML: Machine Learning)*", como materia optativa para la carrera de Maestría en Matemática Aplicada - Plan 2006, y

CONSIDERANDO:

Que se cuenta con despachos favorables del Comité Académico de Maestría en Matemática Aplicada.

Que la Comisión de Docencia e Investigación, desde el punto de vista académico, aconseja autorizar el dictado del curso "*Fundamentos Matemáticos del aprendizaje automático (ML: Machine Learning)*", como materia optativa para la carrera de Maestría en Matemática Aplicada.

Por ello, y en uso de las atribuciones que le son propias.


EL CONSEJO DIRECTIVO DE LA FACULTAD DE CIENCIAS EXACTAS
(en sesión ordinaria del 06/12/2023)
RESUELVE

ARTÍCULO 1º: Tener por autorizado el dictado del curso "*Fundamentos matemáticos del aprendizaje automático (ML: Machine Learning)*", como materia optativa para la carrera de Maestría en Matemática Aplicada - Plan 2006, a cargo del Dr. Edgardo Javier TRENTI, a dictarse del 11 al 15 de diciembre de 2023 (primera parte) y del 26 de febrero al 1 de marzo de 2024 (segunda parte).

ARTICULO 2º: Tener por aprobado el programa analítico y el sistema de evaluación del curso, de acuerdo con las características y requisitos que se explicitan en el Anexo de la presente resolución.

ARTÍCULO 3º: Hágase saber al Dr. Edgardo Javier TRENTI, al Mag. Gustavo Ramino RIVADERA, al Comité Académico de Maestría en Matemática Aplicada, al Departamento de Matemática y a la Dirección Administrativa de Posgrado. Cumplido, resérvese.

mxs/aa


Dr. JOSÉ R. MOLINA
SECRETARIO ACADÉMICO Y DE INVESTIGACIÓN
FACULTAD DE CS. EXACTAS -UNSa.




Mag. GUSTAVO DANIEL GIL
DECANO
FACULTAD DE CS. EXACTAS -UNSa



Resolución de Consejo Directivo **865 / 2023 - EXA -UNSa**

Exp. Nro 596/2023-EXA-UNSa: Autoriza dictado del curso "Fundamentos matemáticos del aprendizaje automático (ML: Machine Learning)", como materia optativa para la Maestría en Matemática Aplicada, a cargo del Dr. Edgardo Javier Trenti.

De: EXACTAS-Dirección de Posgrado



Salta,
12/12/2023

ANEXO de la RCD-N° 865/2023-EXA-UNSa – EXP N° 596/2023-EXA-UNSa

Materia Optativa: “*Fundamentos matemáticos del aprendizaje automático (ML: Machine Learning)*”

Carrera: Maestría en Matemática Aplicada - Plan 2006

Docente Responsable: Dr. Edgardo Javier TRENTI

Cuerpo Docente: Dr. Edgardo Javier TRENTI y Mag. Gustavo Ramino RIVADERA

Fines y objetivos: Internet se ha convertido en una enorme usina de datos. A partir de aplicaciones web, móviles y tradicionales que almacenan datos en “la nube”, es posible obtener datos crudos acerca de casi cualquier temática. La organización de esos datos, la posibilidad de extraer información a partir de ellos, realizar predicciones y clasificar datos nuevos puede resumirse en la búsqueda de “obtener conocimiento”. Si bien este conocimiento puede estructurarse desde los cánones académicos, formalizando el recorrido de causas y consecuencias, existen dispositivos relativamente “antiguos” y conocidos, pero que con la capacidad de cómputo actual han resurgido, con la propiedad de poder clasificar, estructurar y ponderar datos de manera de generar “nuevo conocimiento” allí donde los métodos tradicionales pueden estancarse en la burocracia de encontrar explicación a cada suceso.

En los últimos tiempos, de manera vertiginosa, ha crecido el interés en la Inteligencia Artificial. Y resulta curioso que expertos en la materia, consultados acerca de las virtudes y defectos de estos avances, respondan con cierta ambigüedad, desconfianza y temor acerca de los límites de tecnologías que conocen muy bien. Naturalmente, existe una razón para ello: la inteligencia artificial se divide en dos ramas, una *simbólica* caracterizada por la utilización de estructuras preestablecidas para representar el conocimiento y en la que existe un conjunto de reglas bien establecido que permite obtener respuestas al nivel de expertos en determinadas áreas; y una segunda rama, denominada *subsimbólica*, en la cual la representación del conocimiento se encuentra dispersa en valores como elementos de matrices, sin que se sepa muy bien cómo ese conjunto de valores puede representar la abstracción de características de un objeto de estudio.

Nos resulta un poco paradójico que los expertos manifiesten sus dudas acerca de las capacidades de estos dispositivos, y muchas veces este enigma que se plantea ante nosotros es consecuencia de la presentación habitual de los *dispositivos de aprendizaje automático* como *cajas negras*, atenuando la fuerte carga matemática que subyace en su funcionamiento. En este curso nos proponemos develar algunos de los algoritmos que producen el aprendizaje de *conceptos* y el marco teórico que permite diferenciar entre aquello que es “aprendible” y lo que aparenta no serlo.

Contenidos mínimos: El problema del aprendizaje a partir de un conjunto de datos. Primera aproximación: modelos de aprendizaje por imitación. Redes neuronales. Algoritmo de mínimos cuadrados medios. Algoritmo de aprendizaje por retro-propagación de errores. Proyecto de aprendizaje.

Soporte teórico. Definiciones. Factibilidad del aprendizaje. Marco de aprendizaje PAC (Probablemente Aproximadamente Correcto). Complejidad de Rademacher. Teoría de la



Resolución de Consejo Directivo **865 / 2023 - EXA -UNSa**

Exp. Nro 596/2023-EXA-UNSa: Autoriza dictado del curso "Fundamentos matemáticos del aprendizaje automático (ML: Machine Learning)", como materia optativa para la Maestría en Matemática Aplicada, a cargo del Dr. Edgardo Javier Trenti.

De: **EXACTAS-Dirección de Posgrado**



Salta,
12/12/2023

generalización: cuantificación de hipótesis, dimensión de Vapnik-Chervonenkis. Cota de generalización. Sobreajuste: regularización, validación.

Otros modelos: modelo lineal de regresión, modelos lineales de clasificación, métodos de núcleo, máquinas de soporte vectorial, métodos boosting.

Metodología: La modalidad será presencial teórico-práctica, cada clase consistirá en cuatro horas teóricas y dos horas prácticas, con el complemento de dos horas prácticas no presenciales para el desarrollo de un proyecto final.

Sistema de evaluación: Se deberá asistir al 80% de las clases teóricas y prácticas. Se extenderá certificado de aprobación a quienes cumplan los requisitos de asistencia y superen la evaluación final que consistirá en un examen teórico-práctico y la defensa del proyecto concluido.

Fecha de realización: del 11 al 15 de diciembre de 2023 (primera parte) y del 26 de febrero al 1 de marzo de 2024 (segunda parte).

Lugar de realización: Departamento de Informática, Facultad de Ciencias Exactas de la Universidad Nacional de Salta.

Duración total: 80 horas, distribuidas en dos semanas de cursado intensivo: 10 clases teórico prácticas.

Inscripciones: por Mesa de Entradas de la Facultad de Ciencias Exactas - UNSa., en el horario de atención al público (lunes a viernes de 10:00 a 12:00 y de 15:00 a 17:00).

Arancel: sin arancel.

Cupo máximo: 16 participantes.

Programa Analítico:

Unidad 1: Introducción: "Sin datos no hay negocio". El problema de aprendizaje: componentes del aprendizaje, conjuntos de datos, modelo de aprendizaje simple, aprendizaje versus diseño. Tipos de aprendizaje: supervisado, no supervisado, reforzado. Aplicaciones.

Unidad 2: Primera aproximación: modelos de aprendizaje por imitación. Perceptrón. Redes neuronales. Algoritmo de mínimos cuadrados medios. Modelo de perceptrón multi capa (MLP: Multi Layer Perceptron). Algoritmo de aprendizaje por retro-propagación de errores. Proyecto de aprendizaje de un concepto.

Unidad 3: Soporte teórico. Factibilidad del aprendizaje. Marco de aprendizaje PAC (Probablemente Aproximadamente Correcto). Garantías para conjuntos finitos de hipótesis: casos consistente e inconsistente. Generalidades: escenarios determinísticos versus estocásticos, ruido y error Bayesiano, errores de estimación y aproximación.

Unidad 4: Teoría de la generalización. Espacio de hipótesis: número efectivo de hipótesis. Complejidad de Rademacher. Función de crecimiento. Dimensión de Vapnik-Chervonenkis. Cota de generalización. Interpretación de la cota de generalización. Sobreajuste. Regularización. Validación.

Unidad 5: Modelos: modelos lineales de regresión, modelos lineales de clasificación, otras arquitecturas de redes neuronales, métodos de núcleo, máquinas de soporte vectorial, métodos boosting.



Resolución de Consejo Directivo **865 / 2023 - EXA -UNSa**

Exp. Nro 596/2023-EXA-UNSa: Autoriza dictado del curso "Fundamentos matemáticos del aprendizaje automático (ML: Machine Learning)", como materia optativa para la Maestría en Matemática Aplicada, a cargo del Dr. Edgardo Javier Trenti.

De: EXACTAS-Dirección de Posgrado



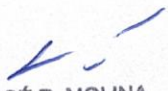
Salta,
12/12/2023

Trabajos Prácticos:

- Funcionamiento del algoritmo de retro-propagación de errores: deducción de la cadena de derivaciones. Caso práctico: elección entre un conjunto de problemas para el proyecto final. Recolección y preparación de los datos.
- Selección del modelo. Validación cruzada. Encuadre del conjunto de datos en el marco PAC. Estudio de factibilidad de generalización.
- Modelos varios de aprendizaje automático. Librerías disponibles. Uso de librerías para el aprendizaje de un concepto sencillo.

Bibliografía:

- Abu-Mostafa, Y. S., Magdon-Ismail, M., Lin, H., 2012. Learning from data. A short course. AMLbook.com.
- Mohri, M., Rostamizadeh, A., Talwalkar, A., 2012. Foundations of Machine Learning. The MIT Press.
- Flach, P. Machine Learning. The Art and Science of Algorithms that Make Sense of Data. Cambridge University Press.
- Bishop, C. M., 2006. Pattern recognition and machine learning. Springer.
- Murphy, K., 2012. Machine Learning: A Probabilistic Perspective. Adaptive Computation and Machine Learning Series. The MIT Press.
- Mitchel, T., 1997. Machine Learning. McGraw-Hill.
- Haykin, S., 2009. Neural Networks and Learning Machines. Prentice Hall. 3ra Edición.
- Shalev-Shwartz, S., Ben-David, S., 2014. Understanding Machine Learning: From Theory to Algorithms. Cambridge University Press.
- Artículos varios.


Dr. JOSÉ R. MOLINA
SECRETARIO ACADÉMICO Y DE INVESTIGACIÓN
FACULTAD DE CS. EXACTAS -UNSa.




Mag. GUSTAVO DANIEL GIL
DECANO
FACULTAD DE CS. EXACTAS - UNSa