

Resolución Consejo Directivo

Número:

Referencia: EX-2023-03840142- -UBA-DMESA#FCEN - POSTGRADO - SESIÓN
25/09/2023

VISTO:

La nota presentada por la Dirección del Departamento de Computación, mediante la cual eleva la información del curso de posgrado Temas de Posgrado: Enfoques Complementarios en IA para Tareas de Predicción para el año 2023,

CONSIDERANDO:

lo actuado por la Comisión de Doctorado,

lo actuado por este Cuerpo en la sesión realizada en el día de la fecha 25 DE SEPTIEMBRE DE 2023

en uso de las atribuciones que le confiere el Artículo 113° del Estatuto Universitario,

**EL CONSEJO DIRECTIVO DE LA FACULTAD
DE CIENCIAS EXACTAS Y NATURALES**

R E S U E L V E:

ARTÍCULO 1°: Aprobar el nuevo curso de posgrado Temas de Posgrado: Enfoques Complementarios en IA para Tareas de Predicción de 15 horas de duración, que será dictado por la Dra. Marina Cristina. Marinescu con la colaboración del Dr. Sergio Abriola.

ARTÍCULO 2°: Aprobar el programa del curso de posgrado Temas de Posgrado: Enfoques Complementarios en IA para Tareas de Predicción que como anexo forma parte de la presente Resolución, para su dictado en el período de invierno de 2023.

ARTÍCULO 3°: Aprobar un puntaje máximo de medio (0,5) punto para la Carrera del Doctorado.

ARTÍCULO 4°: Establecer que el presente curso no será arancelado (CATEGORÍA 1).

ARTÍCULO 5°: Disponer que, de no mediar modificaciones en el programa, la carga horaria y el arancel, el presente Curso de Posgrado tendrá una vigencia de cinco (5) años a partir de la fecha de la presente Resolución.

ARTÍCULO 6°: Comuníquese a todos los Departamentos Docentes, a la Dirección de Estudiantes y Graduados, a la Biblioteca de la FCEyN y a la Secretaría de Posgrado con copia del programa incluida. Cumplido, pase a COMPUTACION#FCEN y resérvese.

ANEXO

Programa:

Este curso va más allá de los conceptos básicos de Machine Learning estadístico para analizar el aprendizaje de big data a través de Deep Learning aplicado a imágenes y texto, pero también analiza enfoques complementarios que pueden ayudar con las tareas de predicción cuando los datos son insuficientes.

Estos enfoques se basan en modelos que representan el conocimiento común y pueden generarse de arriba hacia abajo (por ejemplo, modelos semánticos) o de abajo hacia arriba (por ejemplo, modelos de lenguaje, gráficos de conocimiento).

El curso comienza con la explicación del tradeoff (balance) de sesgo/precisión y la selección de modelo/característica, después de lo cual repasa rápidamente algunos métodos básicos de aprendizaje supervisado y no supervisado, incluido el aprendizaje en línea.

El siguiente bloque analiza los grafos de conocimiento, las diferentes formas de construirlos y presenta algunas tareas de razonamiento que los hacen útiles en una variedad de aplicaciones de IA para guiar los resultados, sugerir relaciones o refinar el conocimiento existente.

El último bloque introduce el aprendizaje profundo, especialmente dirigido a la visión artificial y las tareas de procesamiento del lenguaje natural. El curso concluye con ejemplos de cómo usar conjuntamente estas tecnologías, junto con la IA simbólica de arriba hacia abajo, para mejorar la predicción cuando los datos no son suficientes o los problemas involucran cuestiones de sentido común y causalidad que la inducción de abajo hacia arriba no está preparada para manejar directamente.

Temario

1. Conceptos y tendencias en machine learning e inteligencia artificial, junto con sus implicaciones en la práctica.
2. Cómo seleccionar las mejores features de input con las cuales realizar predicciones.
3. Cuándo y cómo aplicar distintas técnicas de machine learning, y cómo evaluar si los modelos aprendidos son relevantes.
4. Falencias de abordajes basados puramente en data mining.
5. Poder determinar cuándo es posible lidiar con problemas donde el input data no está estructurada. Ventajas del deep learning por sobre statistical machine learning (y algunas desventajas).
6. Qué es un modelo de lenguaje y cómo usarlo en aplicaciones reales.
7. Cómo funcionan las redes neuronales profundas básicas en aplicaciones de computer vision.
8. Cuándo un knowledge graph es más útil. Fundamentos de cómo construir uno y razonar sobre un knowledge graph.

Bibliografía

1. An Introduction to Statistical Learning with Applications in R, Gareth James, Daniela Witten, Trevor Hastie and Robert Tibshirani. Springer, 2022.
2. Knowledge Graphs: Fundamentals, Techniques, and Applications, Craig A. Knoblock, Mayank Kejriwal and Pedro Szekely. MIT Press, 2021.
3. Natural Language Processing with Python: Analyzing Text with the Natural Language, Steven Bird, Ewan Klein, Edward Loper. O'Reilly Media, Inc., 2009
4. Practical Deep Learning: A Python-Based Introduction, Ronald Kneusel. No Starch Press, 2021

