



1821 Universidad de Buenos Aires

Resolución Consejo Directivo

Número: RESCD-2026-1420-E-UBA-DCT#FCEN

CIUDAD DE BUENOS AIRES
Jueves 23 de Julio de 2026

Referencia: EX-2026-03535747- -UBA-DMESA#FCEN - - POSTGRADO - Sesión
20/07/2026

VISTO

La nota presentada por la Dirección del Instituto del Cálculo, mediante la cual eleva la información del curso de posgrado **Machine Learning en Ads** para el año 2026,

CONSIDERANDO

lo actuado por la Comisión de Doctorado,

lo actuado por la Comisión de Presupuesto y Administración,

lo actuado por este Cuerpo en la sesión realizada el día 20 de julio de 2026,

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 **Machine Learning en Ads** de 24 horas y 3 semanas de duración, que será dictado por el Dr. Santiago Guillermo Durán.

ARTÍCULO 2°: Aprobar el programa del curso de posgrado **Machine Learning en Ads** que como anexo forma parte de la presente Resolución, para su dictado en el cuarto bimestre de 2026.

ARTÍCULO 3°: Aprobar un puntaje máximo de un (1) punto para la Carrera de Doctorado.

ARTÍCULO 4°: Establecer un arancel de **CATEGORÍA MEDIA**, estableciendo que dicho arancel estará sujeto a los descuentos y exenciones estipulados mediante la Resolución CD N.º 1072/19. Disponer que los fondos recaudados ingresen en la cuenta presupuestaria habilitada para tal fin, y sean utilizados de acuerdo a la Resolución 072/0.

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 Dirección de Movimiento de Fondos, a la Dirección de Presupuesto y Contabilidad, a la Biblioteca de la FCEyN y a la Secretaría de Posgrado con copia del programa incluida. Cumplido, pase a ICA#FCEN y resérvese.

ANEXO

Machine Learning en Ads

PROGRAMA

La industria de la publicidad (Ads) en redes sociales es una industria de gran relevancia en el mundo tecnológico actual, donde distintos actores compiten, investigan y despliegan modelos de punta con resultados altamente precisos. Entre estos actores se incluyen gigantes como Alphabet (Google, YouTube) y Meta (Facebook, Instagram), pero también plataformas más chicas o especializadas como Reddit y Pinterest.

¿Cuántas veces nos preguntamos cómo funciona “el algoritmo”? En este curso daremos herramientas para responder esa pregunta, centrándonos en los sistemas de Machine Learning aplicados y en los distintos elementos que conforman su ciclo de vida. Estudiaremos los componentes del marketplace, las fases por las que pasan los ads antes de ser mostrados a los usuarios, modelos de predicción y ranking, mecanismos de subastas, experimentación, MLOps, y el estado del arte en el uso de IA para entender y optimizar piezas publicitarias (Creative Intelligence).

Se requieren conocimientos previos en Probabilidad y Machine Learning.

Objetivos:

Comprender los problemas centrales de Machine Learning en Ads: ranking, pCTR/pCVR prediction, conversion modeling, bidding, pacing, experimentation, contextual relevance y creative intelligence.

Traducir preguntas de producto o de marketplace a formulaciones matemáticas y de datos.

Diseñar datasets para modelos de ranking y predicción, efectuar análisis de datos exploratorios y modelos causales simples (Data Science).

Entender el rol de ML Engineer durante todo el ciclo de vida de un modelo y en las diferentes etapas de un ad (MLOps).

Conectar herramientas matemáticas con problemas industriales: probabilidad condicional, calibración, optimización, subastas, causalidad, experimentación, aprendizaje de representaciones y modelos multimodales.

Durante una semana nos centraremos en problemas de Computer Vision y Creative Intelligence. Entre otros temas, veremos embeddings de imagen/video/texto, CLIP-like representations, scoring de creativos, contextual ads y medición del efecto del creativo.

Introducir problemas abiertos y de investigación en el estado del arte de la industria de ads.

Contenidos:

Unidad I - Intro y ranking models

o Conceptos básicos: Ads funnel, bidding y pacing.

Introducción al mundo de Ads. Motivación y conceptos básicos: usuarios, anunciantes, presupuesto, subastas, objetivos de campaña.

Ads funnel: upper funnel y lower funnel; awareness, clicks, conversions, value, budget, métricas fundamentales y objetivos de campaña.

Repaso teórico de herramientas de probabilidad: eventos aleatorios, probabilidad condicional, expected value, calibration, estimadores, intervalos de confianza.

Realizar un análisis de datos exploratorio con datasets Bidding. Second price Auction. Pacing.

Conversación sobre los distintos roles en la industria (Data Scientist, Data Engineer, ML Engineer).

o Etapas del ad: retrieval, pCTR y conversion models.

Recorrido del ad, desde la creación hasta que se muestra.

Exploración vs. Explotación. Boosted bids.

Problema de Retrieval. ¿Cómo reducir un universo grande de candidatos a un conjunto evaluable por modelos más específicos?

pCTR models: definición del ejemplo, label de click, cómo tratar el problema desbalanceado.

Conversion problem: pCVR, ventanas de conversión, cómo tratar un problema raro (pocas conversiones frente al volumen de impresiones).

Repaso teórico de ML para estos modelos: regresión logística como baseline, GBDT, DNN, embeddings categóricos. Métodos de evaluación (AUC, PR-AUC para clasificación, MAE, RMSE para regresión).

Presentación del problema Offline vs. Online.

Unidad II - Experimentation and MLOps

o ML Ops cycle, Feature Engineering y Experimentación

Ciclo de vida de los modelos, desde la generación de data hasta el deployment.
Monitoreo y rollback.

Feature Engineering. Discutir conceptos de backfill, coverage, versionado. Feature store, consistencia train/serving y ownership.

Problemas de volumen y de escala. Batch vs streaming, joins costosos, cobertura, embeddings pesados, caching, latency budgets y online feature serving.

Estudiar las diferentes entidades que forman parte del ecosistema: creative, ad, user, post, campaign, advertiser y context. Discutir sobre su nivel de complejidad y qué implica a nivel de las features.

Onboarding de nuevas features:

1. Pre-requisitos técnicos.
2. Experimentación Offline.
3. Experimentación Online. Cómo setearlo. Considerar restricciones.

Criterios de launch, en función de métricas estadísticas, de negocio y posibles trade-offs.

Privacidad y gestión de features en función de la configuración del usuario.

o Contextual relevance, conversation ads, dimensionality reduction, cold start

Introducción al problema de contextual relevance. Cómo construir features para relacionar entidades.

Representación del contexto en función del contenido orgánico. Text embeddings, post embeddings, community features, señales semánticas, señales de engagement y features temporales.

Ejemplo práctico de post embeddings (GTE) agregados a modelos de pCTR y de Conversions.

Herramientas avanzadas de modelado. Late fusion vs early fusion, concatenación de embeddings, dot products user-context/ad-context, dimensionality reduction, regularización y feature interactions.

Evaluación por slices, dependiendo de métricas de negocio. Posibles efectos negativos sobre diversidad o user experience.

Unidad III - CV and Creative Intelligence

o Creative Intelligence I: Computer Vision, representación de creativos. Caso de Memorable

Introducción a Computer Vision en Ads. Representación de media en los modelos de ranking.

Redes neuronales como modelado de imágenes. CNNs, OCR, ResNET. CLIP Embeddings. Video

Embeddings.

Etapas del ad revisadas desde el creativo: cómo una representación del asset puede influir en retrieval,

pCTR ranking, conversion prediction, quality scoring y feedback para anunciantes.

Caso de Memorable. Memorability y attention como modelo.

1. Data annotation.
2. Training model.
3. Tagging System e Insights Pipeline.

o Creative Intelligence II: creative score, contextual ads y GenAI assets.

Definición del problema de Creative Score. Extraer señales semánticas de calidad del creativo, de otros efectos del marketplace. Casos de uso:

1. Assets generados.
2. Reportar calidad de creativos de diferentes slices.

Problema de features en inference time: algunas señales útiles para entrenar o diagnosticar no existen cuando hay que rankear un nuevo creativo; distinción entre training-only, serving-time y post-delivery features.

Método de Fixed Effects para aislar efectos.

GenAI assets: generación, variación y adaptación de creativos; cómo evaluar calidad sin crear homogeneización, spam, claims engañosos o feedback loops.

Estado del arte de assets generados. Error layers y alucinación.

Contextual ads y creative-context fit.

Discusión de problemas abiertos en CV.

Forma de evaluación:

Trabajo en grupo. Promocionable 7 a 10.

BIBLIOGRAFIA

Guías / Cursos:

o Ng, A. et al. Machine Learning Specialization. Coursera / DeepLearning.AI / Stanford Online.

o DeepLearning.AI. Machine Learning in Production.

o Google Developers. Rules of Machine Learning: Best Practices for ML Engineering.

Trabajos en revista:

o Edelman, B., Ostrovsky, M., & Schwarz, M. (2007). Internet Advertising and the Generalized Second-Price Auction. *American Economic Review*, 97(1), 242–259.

o Varian, H. R. (2007). Position Auctions. *International Journal of Industrial Organization*, 25(6), 1163–1178.

o McMahan, H. B., Holt, G., Sculley, D., Young, M., Ebner, D., Grady, J., Nie, L., Phillips, T., Davydov, E., Golovin, D., Chikkerur, S., Liu, D., Wattenberg, M., Hrafnkelsson, A. M., Boulos, T., & Kubica, J. (2013). Ad Click Prediction: a View from the Trenches. *KDD*.

o Cheng, H.-T., Koc, L., Harmsen, J., Shaked, T., Chandra, T., Aradhye, H., Anderson, G., Corrado, G., Chai, W., Ispir, M., Anil, R., Haque, Z., Hong, L., Jain, V., Liu, X., & Shah, H. (2016). Wide & Deep Learning for Recommender Systems. *DLRS / RecSys Workshop*.

o Naumov, M., Mudigere, D., Shi, H.-J. M., Huang, J., Sundaraman, N., Park, J., Wang, X., Gupta, U., Wu, C.-J., Azzolini, A. G., Dzhulgakov, D., Mallevich, A., Cherniavskii,

I., Lu, Y., Krishnamoorthi, R., Yu, A., Kondratenko, V., Pereira, S., Chen, X., Chen, W., Rao, V., Jia, B., Xiong, L., & Smelyanskiy, M. (2019). Deep Learning Recommendation Model for Personalization and Recommendation Systems.

o Covington, P., Adams, J., & Sargin, E. (2016). Deep Neural Networks for YouTube Recommendations. RecSys.

o Sculley, D., Holt, G., Golovin, D., Davydov, E., Phillips, T., Ebner, D., Chaudhary, V., Young, M., Crespo, J.-F., & Dennison, D. (2015). Hidden Technical Debt in Machine Learning Systems. NeurIPS.

o Li, Z., Zhang, X., Zhang, Y., Long, D., Xie, P., & Zhang, M. (2023). Towards General Text Embeddings with Multi-stage Contrastive Learning.

o Radford, A., Kim, J. W., Hallacy, C., Ramesh, A., Goh, G., Agarwal, S., Sastry, G., Askell, A., Mishkin, P., Clark, J., Krueger, G., & Sutskever, I. (2021). Learning Transferable Visual Models From Natural Language Supervision. ICML.

o Newman, A., Fosco, C., Casser, V., Lee, A., McNamara, B., & Oliva, A. (2020). Multimodal Memorability: Modeling Effects of Semantics and Decay on Video Memorability.

o Si, C., Jiang, Y., Han, X., Liu, Z., Wang, X., Wang, J., Zhou, X., & Ji, R. (2023). Long-Term Ad Memorability: Understanding & Generating Memorable Ads.

Artículos de industria (opcionales):

o Google Ads Help. Your guide to Smart Bidding.

o Google Ads Help. About Quality Score for Search campaigns.

o Meta Engineering. (2024). Sequence learning: A paradigm shift for personalized ads recommendations.

o Meta Engineering. (2024). Meta Andromeda: Next-gen personalized ads retrieval engine.

Digitally signed by MARTI Marcelo Adrian
Date: 2026.07.23 14:10:08 ART
Location: Ciudad Autónoma de Buenos Aires

Marcelo Marti
Secretario
Secretaría de Posgrado
Facultad de Ciencias Exactas y Naturales

Digitally signed by DURAN Guillermo Alfredo
Date: 2026.07.23 14:50:38 ART
Location: Ciudad Autónoma de Buenos Aires

Guillermo Alfredo Duran
Decano
Decanato
Facultad de Ciencias Exactas y Naturales

Digitally signed by GDE UBA
Date: 2026.07.23 14:50:40 -03:00