



Facultad de Ingeniería Comisión Académica de Posgrado

Formulario de Aprobación Curso de Posgrado

Asignatura: Introducción al Aprendizaje Profundo

(Si el nombre contiene siglas deberán ser aclaradas)

Profesor de la asignatura¹: Dr. Pablo Sprechmann - New York University – USA.

(título, nombre, grado o cargo, Instituto o Institución)

Profesor Responsable Local¹: Dra. Paola Bermolen – Gr. 3 – IMERL.

(título, nombre, grado, Instituto)

Otros docentes de la Facultad:

(título, nombre, grado, Instituto)

Docentes fuera de Facultad:

(título, nombre, cargo, Institución, país)

Instituto ó Unidad: IMERL/IIE

Departamento ó Area:

¹ Agregar CV si el curso se dicta por primera vez.

(Si el profesor de la asignatura no es docente de la Facultad se deberá designar un responsable local)

Horas Presenciales: 20

(se deberán discriminar las mismas en el ítem Metodología de enseñanza)

Nº de Créditos: 5

(de acuerdo a la definición de la UdelaR, un crédito equivale a 15 horas de dedicación del estudiante según se detalla en el ítem metodología de la enseñanza)

Público objetivo y Cupos: Estudiantes de Maestría en Ingeniería Matemática, Ingeniería Eléctrica, Estadística, Computación y carreras afines. No hay cupos.

Objetivos:

El aprendizaje profundo es una técnica que emplea redes neuronales para resolver problemas de aprendizaje de máquinas. Su principal objetivo es aprender a partir de una serie de datos observados, representaciones que puedan ser de utilidad para resolver problemas de alto nivel como ser predicción, restauración o clasificación. Dichas representaciones se denominan profundas por estar construidas a partir de una jerarquía compuesta por capas que representan las observaciones con un nivel creciente de abstracción. El aprendizaje profundo pretende descubrir las propiedades intrínsecas de grandes bases de datos construyendo representaciones distribuidas, tanto en contextos supervisados como no supervisados.

El presente curso brinda una introducción al aprendizaje profundo. El propósito del mismo es presentar a los estudiantes los principales aspectos de modelado, algorítmicos y de optimización de forma de que ellos mismos puedan implementar sus propios modelos. Se presentarán modelos simples basados en redes convolucionales que permiten explicar matemáticamente algunas de las propiedades claves para su éxito. Todos los conceptos serán ilustrados con aplicaciones específicas en los campos de visión por computadoras, procesamiento de audio y procesamiento de texto.

Conocimientos previos exigidos: Conocimientos básicos de álgebra lineal y probabilidad y estadística.

Conocimientos previos recomendados: Familiaridad con conceptos básicos de reconocimiento de patrones, procesamiento de señales y Optimización.



Facultad de Ingeniería Comisión Académica de Posgrado

Metodología de enseñanza:

(comprende una descripción de la metodología de enseñanza y de las horas dedicadas por el estudiante a la asignatura, distribuidas en horas presenciales -de clase práctica, teórico, laboratorio, consulta, etc.- y no presenciales de trabajo personal del estudiante)

- Horas clase (teórico): 18
- Horas clase (práctico):
- Horas clase (laboratorio):
- Horas consulta: 2
- Horas evaluación:
 - Subtotal horas presenciales:20
- Horas estudio: 10
- Horas resolución ejercicios/prácticos: 15
- Horas proyecto final/monografía: 30
 - Total de horas de dedicación del estudiante: 75

Forma de evaluación: La evaluación consiste en un proyecto de fin de curso (potencialmente en equipos de dos estudiantes), cuyo objetivo es investigar e implementar una técnica de aprendizaje profundo. Podrá ser implementar un trabajo publicado recientemente o bien evaluar alguna de las técnicas discutidas en una aplicación de interés. Se evaluarán dos entregables: (i) una propuesta de proyecto que utilice técnicas de aprendizaje profundo presentada sobre el final del curso; y (ii) reporte final a entregarse aproximadamente 60 días luego de la finalización del curso.

Temario: Tentativamente, se intentaran cubrir los siguientes temas

- 1) Introducción y motivación. Aprendizaje de representaciones.
- 2) Aprendizaje supervisado. Redes neuronales convolucionales y como entrenarlas.
- 3) Propiedades de las redes convolucionales: invarianza, covarianza, redundancia y invertibilidad.
- 4) Modelos auto-supervisados. Predicción de video, Word2vec.
- 5) Conexión con otros métodos: dictionary learning, árboles de decisión, SVM.
- 6) Modelado de secuencias, redes recurrentes.
- 7) Modelos no-supervisados. Autoencoders, enfoque variacional y adversarial networks
- 8) Aplicaciones

Bibliografía:

La bibliografía seguirá varios artículos y algunos capítulos de libros publicados recientemente.

Deep Learning, Goodfellow, Bengio, Courville, Book in preparation for MIT Press, 2016.
Elements of Statistical Learning, Hastie, Tibshirani, Friedman, Springer, 2001.
Deep Learning, Y. LeCun, Bengio & Hinton, Nature, 2015.
Understanding Deep Convolutional Networks, S. Mallat, 2016.
Learning Stable Group Invariant Representations with Convolutional Networks, J. Bruna et. al., 2013.
Intriguing Properties of Neural Networks, C. Szegedy et al., 2013.
Visualizing and Understanding Convolutional Networks. M. Zeiler, R. Fergus, 2014.
The tradeoffs of Large Scale Learning Bottou, Bousquet, 2008.



Facultad de Ingeniería Comisión Académica de Posgrado

Datos del curso

Fecha de inicio y finalización: del 12 al 16 de diciembre de 2016

Horario y Salón: A confirmar.
