

Formulario de Aprobación Curso de Posgrado 2019

Asignatura: Técnicas de Aprendizaje Automático

(Si el nombre contiene siglas deberán ser aclaradas)

Profesor de la asignatura ¹: Dr. Mathias Bourel, grado 3, IMERL.
(título, nombre, grado o cargo, Instituto o Institución)

Profesor Responsable Local ¹:
(título, nombre, grado, Instituto)

Otros docentes de la Facultad:
(título, nombre, grado, Instituto)

Docentes fuera de Facultad:
(título, nombre, cargo, Institución, país)

Programa(s): Diploma Especialización Ingeniería de Software, Diploma Especialización Seguridad en Informática y Diploma Especialización en Sistemas de Información y Tecnologías de Gestión de Datos.

Instituto ó Unidad: Instituto de Matemática y Estadística Prof. Rafael Laguardia
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: 45

Nº de Créditos: 6

Público objetivo y Cupos: Estudiantes de posgrado interesados en el área de Ciencias de datos.
Sin cupo.

Objetivos: Introducir los aspectos metodológicos de algunas técnicas modernas de aprendizaje automático. Aplicar dichas técnicas a conjuntos de datos reales e interpretar los resultados obtenidos. Acercar el estudiante al empleo de los paquetes para el análisis estadístico de datos disponibles en el ambiente de desarrollo de software libre R (<http://www.r-project.org/>). .

Conocimientos previos exigidos: Conocimientos de probabilidad y estadística

Conocimientos previos recomendados:

Metodología de enseñanza:

- Horas clase (teórico): 29
- Horas clase (práctico): 5
- Horas clase (laboratorio): 0
- Horas consulta: 9
- Horas evaluación: 2
 - Subtotal horas presenciales: 45
- Horas estudio: 25
- Horas resolución ejercicios/prácticos: 20
- Horas proyecto final/monografía: 0
 - Total de horas de dedicación del estudiante: 90

Forma de evaluación: Resolución de ejercicios propuestos durante el curso y prueba presencial final.

Temario:

1. Introducción a la modelización. Matriz de datos. Aprendizaje supervisado y no supervisado. Modelización: inferencia y predicción.
2. Clasificación. Clasificación bayesiana. Métodos de k vecinos más cercanos
3. Árboles de clasificación y regresión (CART).
4. Métodos de agregación de modelos: Bagging, Boosting, Random Forest, Stacking.
5. Clusters: jerárquicos, no jerárquicos, basados en modelos. Spectral Clustering.
6. Support Vector Machines.

Bibliografía:

(título del libro-nombre del autor-editorial-ISBN-fecha de edición)

- Bourel, M. (2012) Model aggregation methods and applications. Memorias de trabajos de difusión científica y técnica, Vol. 10, p. 19-32, 2012.
- Breiman L. (2001). Random forests. Machine Learning 45 (1): pp 5–32
- Breiman L. (1996). Bagging. Machine Learning 24: pp 123–140.
- Breiman L., Friedman J, Stone CJ & RA Olshen (1984) Classification and Regression Trees. Wadsworth Internacional Group, Belmont, CA.
- Duda, R.O, Hart, P. E and Stork, D.G, (2012) Pattern Classification, John Wiley & Sons.
- Everitt, B. and Hothorn, T. , (2010) A Handbook of Statistical Analyses Using R, 2nd edition, Chapman & Hall/CRC.
- Hastie T., Tibshirani R and Friedman J (2011). The Elements of Statistical Learning: Data Mining, Inference and Prediction. (5th. Edition). Springer Series in Statistics.
- James, G., Witten, D., Hastie, T., Tibshirani, R. (2013) An introduction to Statistical Learning with Applications in R, Springer.
- Peña, D. (2002). Análisis de datos multivariantes, Mac Graw Hill



Facultad de Ingeniería Comisión Académica de Posgrado

Datos del curso

Fecha de inicio y finalización: Desde el 11/3/2019 hasta el 24/4/2019

Horario y Salón: Lunes y Miércoles de 18 a 21 hs. Salón a confirmar
