



PROGRAMA

Cátedra: APRENDIZAJE DE MÁQUINAS

1) OBJETIVOS

Objetivo General

El curso introducirá modelos y algoritmos avanzados de aprendizaje de máquinas, con un fuerte énfasis en algoritmos de aprendizaje de modelos para clasificación (decisiones discretas), regresión (decisiones continuas) y *clustering*.

Objetivos buscados por la Cátedra

Introducir al alumno a estas técnicas con un fuerte énfasis en el aspecto práctico de estos algoritmos, orientando toda la planificación en torno a la programación de estos algoritmos y análisis de su funcionamiento frente a problemáticas reales (e.g., clasificación de emails como deseados/no-deseados, control adaptativo, compresión de imágenes, entre otros).

Objetivos de logros para el estudiante

Al finalizar la asignatura, el estudiante se llevará consigo un conjunto de herramientas pequeño pero comprendidas en profundidad. Además del conjunto de herramientas de aprendizaje automatizado, el alumno aprenderá un lenguaje de programación nuevo: **R**, que le permitirá en el futuro producir prototipos rápidos de herramientas de aprendizaje.

Así mismo, la planificación orientada a la práctica confronta al alumno con la necesidad de adquirir conocimiento de manera autónoma, que junto a la permanente asistencia de la cátedra, resultará en adquisición de nuevas herramientas de aprendizaje para el alumno.

Por último, cada laboratorio requiere de la presentación de un reporte técnico de los resultados obtenidos, resultando en la asimilación de estas nuevas aptitudes al finalizar el cursado.

2) CONTENIDOS MÍNIMOS (Según Plan de Estudios vigente)

Clasificadores lineales, Árboles de decisión, redes neuronales, máquinas de vectores soporte, clasificadores Bayesianos, métodos de *clustering*, y aprendizaje por refuerzo.

3) PROGRAMA ANALÍTICO

UNIDAD TEMÁTICA	CONTENIDOS	Referencia a bibliografía	Lecturas (en capítulos)
0 Introducción a las herramientas de trabajo	o.1. Herramientas de Linux para procesamiento de datos: expresiones regulares, <i>tr</i> , <i>cut</i> , <i>paste</i> , <i>grep</i> , <i>sed</i> , y <i>gawk</i> . o.2. Lenguaje R o.3. Introducción a los paquetes de R para aprendizaje. o.4. Metodología de aprendizaje: <i>inquiry-based learning</i> .	[1], [2], [3], [4], [5], [6], [7]	[2] 10,12,13,A [3] 1-3, 5-7, 9-10. [4] 1
1 Aprendizaje supervisado: clasificación	1.1. Introducción al aprendizaje de máquinas. Taxonomía del aprendizaje de máquinas 1.2. Aprendizaje Inductivo. 1.2.1. Problemática del aprendizaje inductivo: Sobre-ajuste, generalización, datos discretos, numéricos y ordinales; datos faltantes. 1.2.2. Árboles de decisión. Teoría de la información de Shannon. 1.2.3. Evaluación de clasificadores: <i>accuracy</i> , <i>precision</i> , <i>recall</i> , correlación curvas ROC. 1.3. Aprendizaje de clasificadores 1.3.1. Naïve Bayes y otros clasificadores 1.3.2. Perceptrón 1.3.3. Métodos discriminativos vs. generativos para el aprendizaje de clasificadores 1.3.4. Clasificadores de máximo margen, <i>Support Vector Machines</i> .	[8], [9], [10], [11], [12], [13], [14], [15], [16], [17], [21]	[8] completos [9] 1.1 – 1.5 [10] 1.1 – 1.3, 3, 6.1-6.3, 6.9 [11] 1
2 Aprendizaje supervisado: Regresión	1. Problemas de regresión, 1.1. Árboles de Regresión 1.2. Regresión logística y regresión con Naïve Bayes 1.3. Redes neuronales: Perceptrón y discriminadores lineales y no lineales. 1.4. Redes multicapa para aproximación de funciones no-lineales 1.5. Regresión con máquinas de vectores soporte: <i>Support Vector Regression</i> .	[8], [9], [10], [11], [12], [13], [14], [15], [16], [18]	



Nivel: 4º
 Carrera: Ingeniería en Sistemas de Información
 Cantidad de horas semanales: 8
 Área: Modelos
 Profesores Titular: Facundo BROMBERG
 Cursado:
 Bloque: Tecnologías Básicas
 Auxiliares JTP: Alejandro EDERA
 Auxiliares Ayudante de 1era: Ana Laura DIEDRICHS (cargo cubierto con beca doctoral UTN)

<p>3 Aprendizaje no supervisado: Clustering</p>	<p>3.1. Aprendizaje no supervisado: agrupación o Clustering 3.2. Distintos Métodos de Clustering. 3.2.1. Redes de neuronas no supervisadas 3.2.2. Aprendizaje Bayesiano no Supervisado.</p>	<p>19</p>	<p>[19] 14.1, 14.3.1-14.3.11</p>
<p>4 Aprendizaje semi-supervisado: aprendizaje por refuerzo</p>	<p>4.1. Toma de decisiones sencillas: 4.1.1. Fundamentos de la teoría de utilidad 4.1.2. Utilidad multi-atributo 4.1.3. Valor de la información 4.2. Toma de decisiones secuenciales: 4.2.1. Aprendizaje de política óptima en Procesos de Decisión de Markov: algoritmos de iteración de valores e iteración de políticas. 4.2.2. Aprendizaje de política óptima en Procesos de Decisión de Markov con utilidades desconocidas: algoritmo de aprendizaje por refuerzo.</p>	<p>20</p>	<p>[20] 16.1-4, 16.6, 17.1-17.3, 21.1 y 21.2.</p>

4) BIBLIOGRAFIA/PUBLICACIONES/GUÍAS DIDÁCTICAS/MATERIAL DE ESTUDIO

Nro.	Autor/es / Título	Edición / Editorial / Año	Principal	Complementaria
1	man pages de tr, cut, paste, grep, sed y gawk.		X	
2	Sobell, Mark . <i>A Practical Guide to Linux Commands, Editors, ad Shell</i> [link] .	2 nd Edition. Prentice Hall. 2010	X	
3	Venables, W. N. and Smith, D. M. <i>An introduction to R. Notes on R: A Programming Environment for Data Analysis and Graphics.</i> [link]	Version 2.13.1 (2011-07-08).	X	
4	Rancière Jacques, <i>El Maestro Ignorante.</i> [link]		X	
5	Dougherty, D. and Robbins, A. <i>sed & awk.</i> [link]	2 nd Edition. O'Reilly		X
6	Moore, Andrew. <i>Machine Learning Tutorials.</i> [link]			X
7	Búsqueda de código R: Rseek , Google Code			
8	Bromberg, F. (2011) <i>Introducción al Aprendizaje de Máquinas.</i> [link]		X	
9	Bishop, C. M. <i>Pattern Recognition and Machine Learning.</i> [link]	Springer	X	



Nivel: 4º
 Carrera: Ingeniería en Sistemas de Información
 Cantidad de horas semanales: 8
 Área: Modelos
 Profesores Titular: Facundo BROMBERG
 Cursado:
 Bloque: Tecnologías Básicas
 Auxiliares JTP: Alejandro EDERA
 Auxiliares Ayudante de 1era: Ana Laura DIEDRICHS (cargo cubierto con beca doctoral UTN)

10	Mitchell, T. (1995) <i>Machine Learning</i> . [link]	McGraw-Hill.	X	
11	Nilsson, N. (1998). <i>Introduction to Machine Learning</i> . [link]		X	
12	Witten I. H. and Eibe F. Data Mining: Practical Machine Learning Tools and Techniques.	2 nd de. Elsevier. (de los programadores de WEKA).		X
13	Mitchell, T. Generative and Discriminative Classifiers: Naive Bayes and Logistic Regression , Borrador capítulo de libro.	2005		X
14	C. Campbell. An introduction to kernel methods			X
15	Nello Christianini. A Tutorial on Support Vector Machines . International Conference on Machine Learning.	ICML 2001. Duración 3 horas, muy completo)		X
16	Gunn, Steve R., <i>Support vector machines for classification and regression</i> . http://eprints.ecs.soton.ac.uk/6459/	Technical Report University of Southampton, 1998.		X
17	Curso de Tom Mitchell , 2do semestre 2011: http://www.cs.cmu.edu/~tom/10701_sp11/lectures.shtml			X
18	Mitchell, T. <i>Naïve Bayes and Logistic regression</i> . http://www.cs.cmu.edu/~tom/mlbook/NBayesLogReg.pdf		X	
19	Hastie, Tibshirany and Friedman, Elements of Statistical Learning.. http://www-stat.stanford.edu/~tibs/ElemStatLearn/	2da Edición 2009	X	
20	Stuart Russell y Peter Norvig. <i>Inteligencia Artificial, un Enfoque Moderno</i> .	Pearson Educación, 2º Edición 2004.	X	
21	Bromberg Facundo, Support Vector Machines [link].		X	

Lugar y fecha: MENDOZA, Agosto 15 2013	DIRECTOR DE CÁTEDRA Apellido y nombre: BROMBERG, Facundo Nº de Legajo: 57953
	Firma