

DEPARTAMENTO DE MATEMÁTICAS

OFRECIMIENTOS DE CURSOS

2013 - 1

Código Curso MATE-3706	Nombre del curso: OPTIMIZACIÓN NO LINEAL con aplicación a las Máquinas de Vectores de Soporte	Créditos/horas 3
	Profesor: María de los Angeles González Lima	
Prerrequisitos: Algebra Lineal II, Cálculo en varias variables.		
<p>Objetivos: Muchas aplicaciones de la vida real pueden ser modeladas como problemas de Optimización no lineal sin restricciones o problemas de Optimización donde la función objetivo es cuadrática y convexa, con restricciones lineales. En este curso se estudiarán las condiciones de optimalidad y teoría de dualidad para este tipo de problemas así como métodos iterativos que nos permitan resolverlos. Como una aplicación se introducirá a las Máquinas de Vectores de Soporte y estudiará desde el punto de vista de su conexión con optimización. El método de Máquinas de Vectores de Soportes (SVM por su sigla en ingles, introducido por Vladimir Vapnik en 1979) forma parte de los llamados métodos de aprendizaje o entrenamiento supervisados que permiten analizar datos y reconocer patrones. Estos métodos son usados para clasificar objetos (o hacer análisis de regresión) en múltiples aplicaciones, como por ejemplo en el reconocimiento de caracteres escritos a manos, detección de caras, categorización de textos, etc, por lo cual SVM es en la actualidad una herramienta de uso frecuente en distintas disciplinas. La teoría de SVM se basa en la resolución de un problema de Optimización cuadrático convexo de grandes dimensiones para lo cual se han desarrollado diversos métodos de resolución que se estudiarán en el curso.</p>		
<p>Contenido:</p> <ul style="list-style-type: none"> - Introducción. Qué es un problema de Optimización? Con y Sin restricciones. - Problemas sin restricciones: Condiciones de Optimalidad (en general), caso particular: función convexa y cuadrática. - Descripción métodos iterativos, órdenes de convergencia, Búsqueda lineal exacta e inexacta. - Métodos (mayor descenso, Newton, Quasi-Newton, gradiente espectral) Parcial I. - Problemas con restricciones: Condiciones de Optimalidad para restricciones lineales. Caso Particular: Convexo y cuadrático. - Dualidad. - Métodos para problemas cuadráticos (restricciones activas, Puntos interiores, etc) Parcial II. <p>SVM:</p> <ul style="list-style-type: none"> - Introducción. Problema Linealmente Separable de clasificación binaria: Planteamiento del problema de Optimización asociado. Derivación del problema dual. Relación entre ambos problemas. Definición de Vectores Soporte. - Problema Linealmente no Separable: Planteamiento del problema considerando márgenes de error. Planteamiento del problema dual: Clasificador C-SVC. Funciones Kernel. Problema dual con funciones Kernel 		



- Métodos de descomposición (Osuna et al).
- Métodos LIBSVM (y GPDLT – opcional).
- Manejo de base de datos con problemas de SVM. Uso de LIBSVM. Parcial III.

Forma de Evaluación:

La evaluación considerará una combinación de tres parciales; exposiciones, tablero, tareas, de parte de los estudiantes y un proyecto.

Bibliografía principal:

J. Nodedal, S. Wright, Numerical Optimization, Springer, 2000.

N. Cristianini and J. Taylor, An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods. United Kingdom: Cambridge University Press, 2000.

Bibliografía complementaria:

D. P Bertsekas, Non Linear programming, Athena Scientific, 2nd Ed., 1998.
J.E. Dennis, R. Schnabel, Numerical Methods for Unconstrained Optimization and Nonlinear Equations, Prentice hall, 1983.
R. Fletcher, Practical methods of Optimization, Willey, 2nd. Ed., 1987.
M.S. Bazaraa, H. D. Sherali and C. M. Shetty, Non Linear Programming Theory and Algorithms, Willey, 2nd. Ed., 1993.
D. Luenberger, Programación lineal y no lineal, 1989.

Artículos en SVM:

E. Osuna, R. Freund, and F. Girosi, Support Vector Machines: Training and Applications, Tech. Rep. A.I. Memo No. 1602, C.B.C.L. Paper No. 144, Massachusetts Institute of Technology, Cambridge, MA, USA, 1997.
Thorsten Joachims, Learning to Classify Text Using Support Vector Machines. Dissertation, Kluwer, 2002.
T. Joachims, 11 in: Making large-Scale SVM Learning Practical. Advances in Kernel Methods - Support Vector Learning, B. Schölkopf and C. Burges and A. Smola (ed.), MIT Press, 1999.
R.-E. Fan, P.-H. Chen, and C.-J. Lin. Working set selection using the second order information for training SVM. Journal of Machine Learning Research 6, 1889-1918, 2005.
M. D. Gonzalez-Lima, W. W. Hager, and H. Zhang, An affine-scaling interior-point method for continuous Knapsack constraints with application to Support Vector Machines. SIAM Journal on Optimization, 21(1), 361-390, 2011.
T. Serafini, G. Zanghirati, L. Zanni, Gradient Projection Methods for Large Quadratic Programs and Applications in Training Support Vector Machines, Optim. Meth. Soft. 20 (2005), 353-378.
Y.H. Dai, R. Fletcher, New Algorithms for Singly Linearly Constrained Quadratic Programming Problems Subject to Lower and Upper Bounds, Math. Prog. 106(3) (2006), 403-421. Also as Research Report NA/216, Dept. of Mathematics, University of Dundee, UK (2003).
L. Zanni, An Improved Gradient Projection-based Decomposition Technique for Support Vector Machines, Computational Management Science 3(2) (2006), 131-145.