



Facultad de Ingeniería Comisión Académica de Posgrado

Formulario de Aprobación Curso de Posgrado

Asignatura: Introducción a las Redes Neuronales

(Si el nombre contiene siglas deberán ser aclaradas)

Profesor de la asignatura¹: PhD, Sebastián Basterrech, Researcher, Department of Computer Science, Faculty of Electrical Engineering and Computer Science, VSB-Technical University of Ostrava, Ostrava, Czech Republic
(Original czech denomination of the position: "Pracovník pro vědu a výzkum")
Profesor Libre, INCO, FING, UDELAR.

Profesor Responsable Local¹: Prof. Héctor Cancela, Gr. 5, INCO
(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: INCO
Departamento ó Area: Departamento de Investigación Operativa

¹ Se adjunta CV dado que 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:
(si corresponde, se indicará el número de plazas, mínimo y máximo y los criterios de selección. Asimismo, se adjuntará en nota aparte los fundamentos de los cupos propuestos. Si no existe indicación particular para el cupo máximo, el criterio general será el orden de inscripción en el Depto. de Posgrado, hasta completar el cupo asignado)

Master students of areas related to Computer Science, Cognitive Sciences and Applied Mathematics.

Curso sin cupos.

Objetivos:

The course is an introduction to Artificial Neural Networks (NNs) and their applications on Artificial Intelligence and Machine Learning (ML) fields.
The lectures will be a comprehensive overview of the basic topics and issues about NNs, knowledge representation, and to solve classification and regression problems with NNs.
The course will put the main emphasis on supervised learning, in particular to deal with sequential data.

The students will develop the techniques using the software available at the University (such that: Java, C, R, Python, Matlab, etc.).
The students will work in a mini-project that consists in solving a real-world learning problem.

Conocimientos previos exigidos:

It is required a basic knowledge on the following areas: data structure and algorithms, computer programming, discrete mathematics, basic concepts on probability and statistics.



Facultad de Ingeniería Comisión Académica de Posgrado

Conocimientos previos recomendados:

It is recommended to have basic concepts on numerical optimization techniques.

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): 12
 - Horas clase (práctico): 0
 - Horas clase (laboratorio): 6
 - Horas consulta: 2
 - Horas evaluación: 0
 - Subtotal horas presenciales: 20
 - Horas estudio: 15
 - Horas resolución ejercicios/prácticos: 15
 - Horas proyecto final/monografía: 25
 - Total de horas de dedicación del estudiante: 75
-

Forma de evaluación:

Oral presentation of a scientific article selected by the student. In addition, the student will work in a mini-project that consists in solving a real-world learning problem and present a short written report of this work.

Temario:

Introduction to Machine Learning (ML):

Supervised and Unsupervised Learning.
Regression and Classification Problems.
Performance evaluation techniques on ML.

Overview of models: Linear Methods, GLM, Regression and Classification Tree, SVM.

Overview of metaheuristics techniques for optimization problems (PSO, GA, SA, etc).

Feature Selection Techniques.

Ensemble methods: Bagging, Boosting.

Introduction to Neural Networks:

Historical motivations.

Revisiting interesting classic literature of the early NNs.

The biological paradigm of Neural Networks.

The Perceptron

Linear separable functions

Multilayer perceptron.

Recurrent Structures.

Learning algorithms for Neural Networks

Classes of learning algorithms

Learning in a single-hidden layer network

Backpropagation algorithm

Gradient descent techniques

General Feedforward Networks



Facultad de Ingeniería Comisión Académica de Posgrado

Extreme Learning Machines

Gradient Descent variations.

Second-order learning methods

Conjugate Gradient Method

Quasi-Newton Techniques

Broyden–Fletcher–Goldfarb–Shanno

Levenberg-Marquardt Method

Hessian-free optimization

The exploding-vanishing problem

Online versus Offline techniques

Particular families of NNs

Extreme Learning Machines

Hopfield Networks

Random Neural Networks

Reservoir Computing

Convolutional NNs

Long Short-Term Memory (RNN)

Deep Networks

Unsupervised learning and clustering algorithms

Competitive learning

Topographic maps

Self-organizing maps

Scale Invariant maps

Bibliografía:

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

W. Press, S. Teukolsky, W. Vetterling, and B. Flannery, Numerical Recipes in C, 2nd ed. Cambridge, UK: Cambridge University Press, 1992.

R. Rojas. Neural Networks. A systematic introduction, First Edition, Springer, 1996.

Y. LeCun, L. Bottou, G. Orr and K. Muller, “Efficient BackProp,” in Orr, G. and Muller K. (Eds), Neural Networks: Tricks of the trade, Springer, 1998.

C. Bishop. Pattern Recognition and Machine Learning, Springer, 2006.

T. Hastie, R. Tibshirani and J. Friedman. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. Second Edition, Springer, February 2009.

Mantas Lukoševičius, , Herbert Jaeger, “Reservoir computing approaches to recurrent neural network training,” Computer Science Review, Volume 3, Issue 2, 2009, Pages 127-149.

J. Martens and I. Sutskever, “Training deep and recurrent networks with hessian-free optimization,” Neural Networks: Tricks of the Trade, 2012, Pages 479–535.

S. Basterrech and G. Rubino, “Random Neural Network Model for Supervise Learning Problems,” Neural Network World, Volume 25 (5), 2015, Pages 457-499.

Jürgen Schmidhuber, “Deep learning in neural networks: An overview,” Neural Networks, Volume 61, 2015, Pages 85-117.

Remark: This bibliography is not exhaustive.



Facultad de Ingeniería Comisión Académica de Posgrado

Datos del curso

Fecha de inicio y finalización: 12 al 22 de diciembre 2016

Horario y Salón: a definir
