Redes Neuronales y Aprendizaje Estadístico

Curso 2025-26

Módulo: Fundamentos
Materia: Técnicas de Computación Inteligente
Créditos: 3 ECTS

Contenido:

1. *Introducción:* tipos de problemas, aprendizaje automático y aprendizaje estadístico, redes neuronales artificiales.
2. *Fundamentos matemáticos:* dinámica de sistemas, teoría de optimización, inferencia estadística y teoría de regresión (lineal y logística).
3. *Aprendizaje supervisado:* regresión y clasificación, modelos neuronales (y otros) para su implementación.
4. *Aprendizaje no supervisado:* modelos neuronales para su implementación.
5. *Modelos alternativos/avanzados:* modelos gráficos, máquinas de Boltzmann, arquitecturas profundas, etc.
6. *Otros tipos de problemas y posibles soluciones:* aprendizaje en entornos dinámicos, aprendizaje por refuerzo, aprendizaje semi-supervisado, inferencia causal, etc.
7. *Aplicaciones prácticas:* tratamiento de señal, optimización de funciones tipo caja negra, predicción en series temporales, diagnóstico de fallos, control de sistemas y análisis de redes complejas.

Resultados del aprendizaje:

- Conocimiento de los fundamentos matemáticos necesarios para contextualizar los modelos neuronales dentro del procesamiento de información y el aprendizaje estadístico.
- Capacidad para emplear las herramientas matemáticas y el marco formal en el estudio de la funcionalidad de las arquitecturas neuronales.
- Determinación de los ingredientes de un problema para diseñar la arquitectura que mejor se adecúa a su resolución.
- Capacidad para resolver problemas colaborando con compañeros y de exponer sus resultados.
- Uso de herramientas de software (R, Octave…) para la simulación de modelos neuronales.
- Capacidad para emplear los métodos y modelos aprendidos en futura actividad investigadora.

Competencias:

Básicas y generales: CG1, CG2, CG3, CG4, CG5, CG6, CG7

Transversales: CT1, CT2

Específicas: CE2, CE3, CE4, CE5, CE6, CE7

Bibliografía:

E. ALPAYDIN (2020). *Introduction to Machine Learning*. Cambridge, MA: MIT Press.

C.M. BISHOP (2006). *Pattern Recognition and Machine Learning*. New York, NY: Springer-Verlag.

F. CUCKER & D.X. ZHOU (2007). *Learning Theory: An Approximation Theory Viewpoint*. New York, NY: Cambridge University Press.

M.P. DEISENROTH, A.A. FAISAL & C.S. ONG (2020). *Mathematics for Machine Learning*. New York, NY: Cambridge University Press.

C. FERNÁNDEZ, F.J. VÁZQUEZ & J.M. VEGAS (2003). *Ecuaciones Diferenciales y en Diferencias: Sistemas Dinámicos*. Madrid: Thomson Ediciones.

I. GOODFELLOW, Y. BENGIO & A. COURVILLE (2016). *Deep Learning*. Cambridge, MA: MIT Press.

S.S. HAYKIN (2011). *Neural Networks and Learning Machines*. Upper Saddle River, NJ: Pearson Prentice Hall.

R. HERBRICH (2002). *Learning Kernel Classifiers: Theory and Algorithms*. Cambridge, MA: MIT Press.

G. JAMES, D. WITTEN, T. HASTIE & R. TIBSHIRANI (2013). *An Introduction to Statistical Learning: With Applications in R.* New York, NY: Springer-Verlag.

T. KOHONEN (2000). *Self-Organizing Maps*. Berlin, Heidelberg: Springer-Verlag.

Q. MARTÍN & Y.R. PAZ (2007). *Aplicación de las Redes Neuronales Artificiales a la Regresión*. Madrid: La Muralla.

T.M. MITCHELL (1997). *Machine Learning*. New York, NY: McGraw-Hill.

J. PEARL (2016). *Causal Inference in Statistics: A Primer.* Chichester: Wiley.

V.N. VAPNIK (2000). *The Nature of Statistical Learning Theory*. New York, NY: Springer-Verlag.

M. VIDYASAGAR (1993). *Nonlinear Systems Analysis*. Upper Saddle River, NJ: Pearson Prentice Hall.

M. VIDYASAGAR (2003). *Learning and Generalisation: With Applications to Neural Networks*. London: Springer-Verlag.

Software:

Python.

R.

Metodologías docentes:

Método expositivo.
Estudio de casos.
Prácticas de ordenador.

Evaluación:

Entrega de trabajos: 70%
Examen teórico-práctico: 30%

Profesorado:

Nombre: Pedro José Zufiria Zatarain
Despacho: A-306, ETSI en Telecomunicación, UPM
E-mail: pedro.zufiria@upm.es