

Redes Neuronales y Teoría Conexionista

Dr. Segura, Enrique Carlos (Profesor Regular Asociado Dedicación Exclusiva)

Programa:

El curso pretende dar una visión introductoria de los paradigmas de Redes Neuronales que más trascendencia han tenido en el desarrollo de la disciplina. Esta consiste, esencialmente, en un enfoque de problemas tales como el aprendizaje, la memoria y la inteligencia en general, desde el punto de vista de los mecanismos que se supone se hallan presentes en un sistema nervioso natural (v.g. el humano) y que lo proveen de esas facultades. Considerada en relación con su potencial tecnológico, se trata de un intento de desarrollar sistemas artificiales capaces de resolver problemas prácticos mediante la modelación de sistemas biológicos. Las Redes Neuronales Artificiales representan un paradigma metodológico alternativo en el campo de las Ciencias Cognitivas.

El objetivo es desarrollar sistemas computacionales capaces de realizar tareas intelectuales complejas, tales como la resolución de problemas, el reconocimiento y clasificación de patrones, procesos inductivos y deductivos. Además, se lograría el manejo de la incertidumbre, la ambigüedad, la suposición y la integración de información proveniente de diferentes y múltiples fuentes, lo cual es inalcanzable desde la actual informática. Esta limitación es intrínseca al modelo formal de procesamiento de la información a partir del cual se han venido construyendo las computadoras desde los años 40' a esta parte, modelo debido a Von Neumann y que consiste, en esencia, en la aplicación secuencial de un conjunto de transformaciones sobre los datos de entrada para producir la salida deseada. Dichas operaciones conforman un programa, son fijas y deben ser conocidas de antemano por el programador. Este esquema es abandonado desde la perspectiva conexionista o neuronal: las neuronas operan en forma paralela y no requieren sincronización de ningún tipo; por otro lado, poseen propiedades de autoorganización que les permiten actuar cooperativamente en la resolución de problemas sin necesidad de instrucciones precisas sobre los pasos a seguir, es decir que no requieren ser programadas, ya que pueden aprender a partir de su interacción con el entorno, modificando paulatinamente sus interconexiones.

El sistema biológico de percepción de un insecto es miles de veces más flexible y poderoso que cualquier programa de computadora por extenso, robusto y potente que sea. Por eso se intenta comprender cómo las neuronas computan datos; es el primer paso para reconstruir artificialmente una red neuronal.

Mucho más primitiva que el cerebro, dado que éste posee unos diez mil a cien mil millones de neuronas, y su replicación está hoy fuera del alcance de los científicos. Pero absolutamente revolucionaria en el ámbito del procesamiento de datos.

Temario:

- Introducción (1 semana)
 - Inspiración biológica de las redes neuronales artificiales.
 - Neurona biológica vs. neurona artificial. El modelo de MacCulloch y Pitts.
 - El proceso de aprendizaje desde el punto de vista del conexionismo: algoritmos vs. paradigmas.

- El paradigma conexionista en el contexto histórico (i.e frente a otros como el matemático, el lógico-operacional, el computacional, autómatas celulares).
- Un poco de historia.
- Nuevas tendencias: big data, data mining, redes neuronales profundas.
- Aplicaciones de las redes neuronales artificiales.
- Aprendizaje supervisado (5 semanas)
 - El Perceptrón simple. Clasificación según la función de transferencia (escalón, lineal, no-lineal). La regla Delta de aprendizaje. Teorema de Rosenblatt. Propiedades y limitaciones. La regla de Hebb.
 - Perceptrones multicapa: capacidad de generalización. El gran salto en la universalidad computacional. Teoremas (Funahasi, Grossberg).
 - El método de Backpropagation y otras estrategias de aprendizaje.
 - Aplicaciones del Perceptrón.
 - Autoencoders y redes profundas basadas en autoencoders
 - Redes Convolucionales
- Aprendizaje no supervisado (5 semanas)
 - Aprendizaje Hebbiano no supervisado. Breve introducción al Análisis de Componentes Principales. Características: extracción vs. selección. Modelos de Oja y Sanger: propiedades, teoremas de convergencia.
 - Aprendizaje competitivo simple. Feature Extraction. Cuantización vectorial.
 - Mapas topológicamente organizados. Inspiración biológica: los trabajos del Hubel y Wiesel. Mapeo de características.
 - Modelo de Fritzke. Consideraciones sobre la construcción de arquitecturas.
 - Aplicaciones de los modelos de aprendizaje no supervisado.
- Memorias asociativas y modelos basados en energía (5 semanas)
 - Modelo de Hopfield. Propiedades, capacidad, limitaciones.
 - Inspiración física: el modelo ferromagnético.
 - Hopfield estocástico. La distribución de Boltzmann. Teoremas de equilibrio termodinámico.
 - Otras variantes del modelo de Hopfield: continuo, pseudoinversa, BAM.
 - Algunas aplicaciones.
 - Máquinas de Boltzmann.
 - Redes profundas basadas en el modelo de Hopfield: Deep Belief Networks, Máquinas de Boltzmann Profundas.

Bibliografía

- Bengio, Y., Goodfellow, I. y Courville, A.; Deep Learning (*Adaptive Computation and Machine Learning series*), Cambridge, MA, MIT press, 2017.
- Bengio, Y., Lecun, Y. y Hinton, G.; Deep learning for AI; *Communications of the ACM*, 64(7), 58-65, 2021.

- Frei, S., Chatterji, N. y Bartlett, P. L; Benign overfitting without linearity: Neural network classifiers trained by gradient descent for noisy linear data, *Proc. 35th Conference on Learning Theory (COLT2022)*, 2022.
- Goodfellow, I., Bengio, Y. y Courville, A.; Deep Feedforward Networks; *Deep Learning 1*, MIT Press, 2016.
- Goodfellow, I., Bengio, Y. y Courville, A.; Deep Learning, MIT Press, 2016.
- Haykin, S; "Neural Networks and Learning Machines", Upper Saddle River, Pearson-Prentice Hall, 2011.
- Hertz, J. J., Krogh, A. y Palmer, R.; "Introduction to the Theory of Neural Computation", Redwood City, Addison-Wesley Publishing Company, 1991.
- Kruse, R., Borgelt, C., Klawonn, F., Moewes, C., Steinbrecher, M. y Held, P.; "Computational intelligence: a methodological introduction", Springer, 2013.
- LeCun, Y. ; The Power and Limits of Deep Learning; *Research-Technology Management* 61: 22-27, 2018.
- Taylor, M.; Neural Networks Math: a visual introduction for beginners, Blue Windmill Media, 2017 (nivel introductorio).
- Wilson, H. ; Artificial Intelligence. Grey House Publishing, 2018.