



PROMiDAT

IBEROAMERICANO

Programa Iberoamericano de
Formación en Minería de Datos

**“Deep Learning”
en Python**



(506) 2268.8823 - (506) 8708.9091



info@promidat.com



facebook.com/oldemarrodriguez



www.promidat.com

Duración: Cuatro semanas.

Descripción:



En este curso se presentarán los principales métodos en Machine Learning, especialmente enfocados en métodos de “Deep Learning”. El énfasis principal del curso será examinar dichos métodos desde un punto de vista algorítmico y de sus aplicaciones en casos reales. Se le dará especial importancia al uso de los conceptos de machine learning y deep learning en aplicaciones reales con bases de datos de gran tamaño, para esto se utilizarán los programas especializados, como son la plataforma de desarrollo Python y Anaconda Spyder.

¿A quién va dirigido?

Se orienta especialmente a analistas de riesgo, marketing y mercadeo, personal involucrado en proyectos de pronóstico y predicción o en proyectos de “Business Intelligence”, administradores de bases de datos, analistas de sistemas, profesionales en estadística o economía y en general a personas que, basados en los datos de la organización, colaboran en la toma de decisiones.

Objetivos:

En este curso el estudiante será capaz de:

1. Comprender la diferencia entre modelos de aprendizaje supervisado (aprendizaje supervisado) y modelos de aprendizaje no supervisado (aprendizaje no supervisado).
2. Comprender la diferencia entre machine learning, redes neuromales y deep learning.
3. Comprender la necesidad de la utilización de modelos, algoritmos, software para predecir el comportamiento futuro.
4. Utilizar el lenguaje Python en la plataforma Anaconda Spyder para analizar y desarrollar ejemplos con datos reales.
5. Conocer el significado de Deep Learning y por qué es ampliamente usado en problemas de Big Data.

6. Conocer las principales modelos empleados en Deep Learning y su aplicación en clasificación, regresión y series de tiempo.
7. Entender el funcionamiento y método de aprendizaje de las Redes Neuronales clásicas y Convolucionales
8. Desarrollar modelos de Deep Learning con Redes Neuronales empleando las librerías Keras y TensorFlow
9. Usar estructuras especializadas de Redes Neuronales para la aplicación en problemas de visión computacional.

Metodología:

Basado en la teoría y en la aplicación directa de los conceptos aprendidos. Para esto se dispondrán de las siguientes herramientas.

- Una vídeo conferencia semanal, las cuales quedarán grabadas en Webex, para que los alumnos la puedan acceder en cualquier momento.
- Trabajos prácticos semanales.
- Foros para plantear dudas al tutor y compañeros.
- Aula virtual en Moodle.

Luego de este curso el estudiante será capaz de:

Desarrollar y programar proyectos de Machine Learning que involucren predicción utilizando modelos de Deep learning. Luego hace la calibración y la selección del mejor modelo dado un “data set” específico.

Contenido:

1. Algoritmos en Deep Learning (aprendizaje profundo)

- a. Algoritmo del Perceptron.
- b. Redes neuronales de múltiples capas.
- c. Algoritmos basados en Tensor Flow.
- d. Aplicaciones en casos reales con Python, paquetes KERAS y Scikit-Learn.
- e. Algoritmos usados por Google en Python para Deep Learning.

2. Deep Neural Networks (Redes Neuronales profundas)

- a. Redes Neuronales Recurrentes - Recurrent Neural Networks (RNN).
- b. La necesidad de usar RNN.
- c. Los tipos de datos utilizados en las RNN.
- d. Entendiendo a los RNN.
- e. Memoria a corto plazo.
- f. Unidades recurrentes cerradas.
- g. RNN profundos.
- h. Entrenamiento y optimización.
- i. Arquitecturas populares.

3. Descenso de gradiente y su variantes

- a. Desmitificando el descenso del gradiente.
- b. Descenso de gradiente versus descenso de gradiente estocástico.
- c. Momentum y gradiente acelerado de Nesterov.
- d. Métodos adaptativos de descenso de gradientes.

4. Algoritmos avanzados de Deep Learning

- a. Generación de imágenes mediante GAN (Generative Adversarial Networks).
- b. Más información sobre las GAN.
- c. Reconstrucción de entradas mediante codificadores automáticos.
- d. Exploración de algoritmos de aprendizaje de pocos intentos.

Bibliografía:

1. Andreas C. Müller and Sarah Guido. Introduction to Machine Learning with Python: A Guide for Data Scientists. O'Reilly, 1st Edition, 2017.
2. Dusty Phillips. Python 3 Object-oriented Programming, Second Edition. Packt Publishing Ltd, 2015.
3. Eric Matthes. Python Crash Course A Hands-On, Project-Based introduction to Programming. No Starch Press, Inc. 2016.
4. François Chollet. Deep Learning with Python. Manning Publications Co. 2018.

5. Ivan Vasilev. Advanced Deep Learning with Python. Packt Publishing Ltd, 2019.
6. Jake VanderPlas. Python Data Science. O'Reilly, 2017.
7. John Paul Mueller (Author) and Luca Massaron. Python for Data Science for Dummies (For Dummies (Computer/Tech)) 1st Edition, 2015.
8. Steven F. Lott. Mastering Object-oriented Python. Packt Publishing Ltd, 2014.
9. Python Software Foundation. 2017. [Python 3.6.2 documentation](https://docs.python.org/3.6.2/). python.org.
10. Anaconda 2017. [Download Anaconda Distribution Python 3.6 version](https://www.anaconda.com/distribution/#python36). Anaconda Inc.
11. Anaconda 2017. [Anaconda Documentation](https://docs.anaconda.com/). Anaconda Inc.
12. Rowel Atienza. Advanced Deep Learning with Keras. Packt Publishing, 2018.
13. Richard, C. (2013). Learning R: A Step-by-Step Function Guide to Data Analysis. Sebastopol: O'Reilly.
14. Sudharsan Ravichandiran. Master deep learning algorithms with extensive math by implementing them using TensorFlow. Packt Publishing Ltd, 2019.
15. Matloff, N. (2013). The art of R programming: A tour of statistical software design. San Francisco: No Starch Press.