
TEMARIO

Deep learning

Descripción

En la actualidad el uso de herramientas que permiten a una máquina reproducir el comportamiento humano, inteligencia artificial o IA, ha tomado cada vez mayor relevancia. Como un área integral de IA tenemos el aprendizaje máquina o Machine Learning (ML), el cual permite enseñar a las computadoras y mejorar su aprendizaje. Finalmente, dentro de ML, el aprendizaje profundo o Deep Learning (DL), es un tipo aprendizaje basado en el uso de redes neuronales profundas.

En este curso se presentan los conceptos fundamentales utilizados en DL, así como las arquitecturas más importantes y algunas de sus aplicaciones, por ejemplo, en clasificación de imágenes o en la generación de agentes autónomos. En este curso se conjugan conceptos estadísticos, probabilísticos, computacionales y de manejo de datos que nos ayudarán a entender bien los aspectos detrás de cada modelo y ser capaces de modificar el código y modelos para obtener mejores resultados al entender a fondo cada modelo. El objetivo es así que el estudiante no solo sea capaz de aplicar el código sino entender lo que está siendo implementado.

Los conocimientos adquiridos permitirán entender y aplicar implementaciones de DL, como es la IA generativa, la tecnología basada en reconocimiento de voz o rostro, las herramientas que permiten la identificación de fraudes, la tecnología detrás de los automóviles autónomos, y en general la generación de agentes o robots que pueden efectuar tareas a través de un proceso de aprendizaje basado en recompensas (aprendizaje reforzado).

1. Introducción
 - a) IA, Machine learning y deep learning
 - b) Redes neuronales y redes neuronales profundas
 - c) Hiperparámetros: Balance entre varianza y sesgo
 - d) Arquitecturas más utilizadas en DL.
2. Tensores, máquinas de ejecución y frameworks
 - a) Tensores y operaciones básicas
 - b) Gráficos computacionales y gradientes
 - c) Máquinas de ejecución (back-end): TensorFlow, Theano y CNTK
 - d) Frameworks (API) de alto nivel: Keras como front-end
 - e) Pytorch y torch
 - f) Modelos secuenciales en keras y tensorboard
3. Redes neuronales convolucionales (CNN)
 - a) Generalidades

- b) Convoluciones y filtros: paddings y strides
- c) Capas de pooling, de tipo RELU y densas
- d) Modelos pre-entrenados y Transfer learning
- e) Algunas arquitecturas
 - (i) VGG
 - (ii) ResNet
- 4. Redes neuronales recurrentes (RNN)
 - a) Series temporales y secuencias
 - b) Definición y redes desdobladas
 - c) Limitaciones de RNN
 - d) LSTM networks
 - e) Neuronas GRU
- 5. Entrenamiento de redes neuronales profundas
 - a) Gradientes, descenso del gradiente y backpropagation
 - b) Modificaciones del algoritmo de descenso de gradiente
 - c) Descenso de gradiente estocástico (SGD) y mini-batch GD
 - d) Momentum y gradiente acelerado de Nesterov
 - e) Adagrad, RMSprop y Adadelata
 - f) Adam
- 6. Estrategias para evitar sobreajuste y convergencia inadecuada
 - a) Reducción del tamaño de la red neuronal
 - b) Regularización basada en penalizaciones
 - c) Dropout
 - d) Early stopping
 - e) Vanishing y exploding gradients
 - f) Inicializaciones óptimas en los pesos
 - g) Batch normalization
- 7. Selección de hiperparámetros óptimos (HPO) en Deep learning
 - a) Grid, random search y optimización bayesiana
 - b) Entrenamiento, validación y prueba. Data leakage.
 - c) Hiperparámetros a optimizar
 - d) HPO con TensorFlow y keras
- 8. Autoencoders (AED)
 - a) Motivación
 - b) Definición y aplicaciones
 - c) Clasificación
 - d) Deep convolutional (DCN), deconvolutional y convolutional AE
 - e) Aplicaciones
 - f) Detección de anomalías con autoencoders
- 9. Generative Adversarial Networks (GANs)
 - a) Definición y usos
 - b) Generador y discriminador
 - c) Formalización matemática

- d) Deep convolutional GANs
 - e) Aplicaciones
10. Deep Reinforcement Learning
- a) Cadenas de Markov y Procesos de Decisión Markovianos
 - b) Q-learning
 - c) Deep Q-learning
 - d) Ejemplos de uso de Deep reinforcement learning

Informes: lumialearning@gmail.com