



Universidad de Buenos Aires
Facultad de Ciencias Exactas y Naturales

Planilla a completar para presentación de Cursos de Posgrado

1.- DEPARTAMENTO de COMPUTACIÓN

2.- NOMBRE DEL CURSO: Aprendizaje profundo para el análisis de imágenes biomédicas

3.- DOCENTES:

RESPONSABLE/S: Enzo Ferrante

COLABORADORES:

AUXILIARES:

4.- CARRERA de DOCTORADO

5.- AÑO: 2018.

CUATRIMESTRE/S: 2do

6.- PUNTAJE PROPUESTO PARA CARRERA DE DOCTORADO: 2

7.- DURACIÓN (anual, cuatrimestral, bimestral u otra): Intensiva (1 mes)

8.- CARGA HORARIA SEMANAL:

Teóricas:

Problemas:

Laboratorio:

Seminarios:

Teórico - Práctico: 9hs

Salida a Campo:

9.- CARGA HORARIA TOTAL: ~~36~~ 40

10.- FORMA DE EVALUACIÓN:

3 trabajos prácticos obligatorios durante la cursada (uno por bloque) y un trabajo final. Los trabajos prácticos serán desarrollados preferentemente en lenguaje Python, utilizando la biblioteca de cálculo matricial Numpy y una biblioteca de aprendizaje profundo a elección.

- *TP 1:* Implementación completa de un perceptron multicapa utilizando Python y la biblioteca de calculo matricial Numpy para un problema de clasificación simple.

- *TP 2:* Implementación de una arquitectura estándar para la resolución del problema de clasificación de dígitos MNIST con redes neuronales convolucionales profundas. Se sugerirá la utilización del lenguaje Python. Realización de un pequeño informe con análisis de resultados y curvas de entrenamiento.

- *TP 3:* Implementación de una arquitectura estándar para la segmentación de estructuras anatómicas en imágenes 2D. Se sugerirá la utilización del lenguaje Python. Realización de un pequeño informe con análisis de resultados, evaluación de alternativas de diseño y curvas de entrenamiento.

- *Trabajo Final:* el trabajo final sugerido consistirá en la implementación de un método basado en aprendizaje profundo para la resolución de uno de los desafíos abiertos sobre imágenes médicas propuestos en el repositorio abierto Grand Challenge: https://grand-challenge.org/All_Challenges/

Opcionalmente, los alumnos podrán proponer un problema afín a los temas abordados durante el curso, que resulte de su interés ya sea por estar relacionado a su proyecto de tesis de grado o postgrado, o por simple interés personal. El tema será evaluado por el docente quien definirá si el mismo puede ser abordado.

Todo trabajo final deberá constar de un informe que será redactado con formato de artículo científico, y deberá incluir una descripción detallada del método implementado y un análisis de los resultados obtenidos.

11.- PROGRAMA ANALÍTICO:

Descripción general de la materia:

Durante las últimas décadas, los continuos avances en tecnologías para la captura de imágenes biomédicas han dado lugar a una gran variedad de representaciones visuales del interior de organismos vivos a nivel de órganos, tejidos, células y moléculas. Las modalidades de imagen, tales como los rayos-x, resonancias magnéticas, imágenes de ultrasonido, tomografía computada, microscopias, entre muchas otras, juegan un rol fundamental en la práctica clínica y la investigación en ciencias de la vida. Al mismo tiempo, el advenimiento de la era "big data" ha desencadenado un proceso masivo de producción de datos a todo nivel, y las imágenes biomédicas no han sido la excepción. Interpretar dichos datos en la actualidad es posible gracias al desarrollo de métodos computacionales para el análisis de imágenes biomédicas. Dichos métodos forman parte de un campo científico multidisciplinar bien establecido, que se encuentra en la intersección de áreas tan diversas como ciencias de la computación, matemáticas, física, medicina y biología. En este contexto, los métodos basados en aprendizaje automático han cobrado gran relevancia, debido a la necesidad de automatizar los procesos de interpretación de grandes volúmenes de imágenes, con el objeto de extraer información útil a partir de ellas.

Un tipo particular de métodos de aprendizaje automático conocido como 'aprendizaje profundo' (o 'deep learning' en inglés), ha revolucionado el mundo de las ciencias de la computación en los últimos 5 años y desplazado las fronteras del estado del arte, particularmente en diversos problemas de visión computacional y análisis de imágenes tales como reconocimiento de objetos, clasificación, segmentación y registración de imágenes. Dichos problemas encuentran su correlato en el caso específico de las imágenes médicas, y han posibilitado el desarrollo de nuevas herramientas computacionales que alcanzan niveles de precisión muy cercanos a los humanos en tareas concretas, tan variadas como la segmentación de tumores cerebrales en



resonancias magnéticas, el diagnóstico de enfermedades cardíacas o la detección automática de planos de interés en ecografía fetal.

Este curso pretende brindar a los estudiantes los conceptos teóricos fundamentales y las herramientas prácticas necesarias para construir sus propios modelos de análisis de imágenes basados en aprendizaje profundo, con especial foco en aplicaciones relacionadas a las imágenes biomédicas.

Estructura del curso

Este curso teórico-práctico estará dividido en tres grandes bloques. En el primero abordaremos los conceptos básicos del aprendizaje automático con foco en el aprendizaje profundo, incluyendo clasificadores lineales simples, modelos de redes neuronales multicapa, redes neuronales convolucionales y los algoritmos necesarios para entrenarlas. En el segundo, introduciremos nociones básicas de visión computacional y procesamiento de imágenes, definiremos las problemáticas clásicas del área y estudiaremos cómo abordarlas por medio del aprendizaje profundo, haciendo hincapié en las arquitecturas propuestas durante los últimos años. En el tercer bloque ahondaremos en el caso particular del análisis de imágenes biomédicas, sus problemáticas específicas, y estudiaremos modelos recientemente propuestos para resolverlas mediante el uso de métodos basados en aprendizaje profundo.

Al final del curso, los alumnos serán capaces de implementar y entrenar modelos estándar basados en redes neuronales profundas para resolver problemas de segmentación, clasificación y registración de imágenes; conocerán las problemáticas generales que se abordan en el campo del análisis de imágenes biomédicas; y contarán con las herramientas tecnológicas necesarias para desarrollar nuevos modelos para el análisis automático de imágenes.

Bloque 1: Introducción al aprendizaje profundo

Introducción y contexto histórico. Aprendizaje supervisado. K vecinos más cercanos (K -NN). Clasificadores lineales clásicos. Redes neuronales feedforward. Perceptrón multicapa. Algoritmo de retropropagación y gradiente descendiente estocástico. Funciones de pérdida. Métodos de regularización.

Aprendizaje profundo. Normalización de Batches. Métodos de inicialización. Redes neuronales convolucionales (RNC). Operaciones básicas. Pooling. Bibliotecas para la implementación de redes neuronales profundas: Tensorflow.

Bloque 2: Visión computacional por medio de aprendizaje profundo

Introducción a la visión computacional. Definición de problemas clásicos en visión: clasificación de imágenes, detección de objetos, segmentación de imágenes, estimación de flujo óptico. Aproximaciones clásicas a la visión computacional.

Arquitecturas de RNC para visión computacional: AlexNet, VGG Net, GoogleLeNet. Redes totalmente convolucionales: FCN. Arquitecturas para estimación de flujo óptico. Auto-codificadores convolucionales y sus aplicaciones al análisis de imágenes.

Bloque 3: Aprendizaje profundo para el análisis de imágenes médicas

Introducción a las imágenes médicas. Modalidades de imagen: Imágenes de Resonancia Magnética (IRM). Rayos-X. Tomografía Computada. Ultrasonido. Definición de problemas básicos del área. Relación con la visión computacional.

Aprendizaje profundo para el análisis de imágenes médicas. Segmentación de patologías y estructuras anatómicas. Arquitecturas de RNC para segmentación de imágenes médicas: DeepMedic, U-Net. Segmentación de imágenes volumétricas.

Casos de aplicación. Segmentación de tumores en IRM y estructuras anatómicas cerebrales. Registración de imágenes cardíacas. Síntesis de imágenes multimodales. Super-resolución de IRM.

Prerrequisitos:

Conocimientos de programación (preferentemente Python) y algoritmos. Conocimiento de álgebra lineal y operaciones matriciales. Conocimientos básicos de probabilidad y estadística. Conocimientos de cálculo básico y derivadas parciales.

12.- BIBLIOGRAFÍA:

(La mayor parte del material está disponible gratuitamente online o será provisto por el profesor)

Libros (impresos y online):

- S. Kevin Zhou, Hayit Greenspan, Dinggang Shen. "Deep Learning for Medical Image Analysis". 1st Edition. ISBN: 9780128104088. Academic Press. 2017
- Ian Goodfellow, Yoshua Bengio and Aaron Courville. "Deep Learning". MIT Press. 2016
- David A. Forsyth, Jean Ponce. "Computer Vision: A Modern Approach". Pearson. 2012
- Nielsen, Michael. "Neural Networks and Deep Learning". Disponible online <http://neuralnetworksanddeeplearning.com/>
- Rosebrok, Adrian. "Deep Learning for Computer Vision with Python". <https://www.pyimagesearch.com/deep-learning-computer-vision-python-book/>

Publicaciones científicas (journals y conferencias):

- Litjens, Geert, et al. "A survey on deep learning in medical image analysis." *Medical image analysis* 42 (2017): 60-88.
- Oktay, O., Ferrante, E., Kamnitsas, K., Heinrich, M., Bai, W., Caballero, J., Cook, S., de Marvao, A., Dawes, T., O'Regan, D. and Kainz, B., 2017. Anatomically constrained neural networks (ACNN): application to cardiac image enhancement and segmentation. *IEEE transactions on medical imaging*.
- Kamnitsas, K., Ledig, C., Newcombe, V.F., Simpson, J.P., Kane, A.D., Menon, D.K., Rueckert, D. and Glocker, B., 2017. Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation. *Medical image analysis*, 36, pp.61-78.
- Ronneberger, O., Fischer, P. and Brox, T., October. U-net: Convolutional networks for biomedical image segmentation. In *Proceedings of MICCAI 2015* (pp. 234-241). Springer, Cham.
- Long, J., Shelhamer, E. and Darrell, T., Fully convolutional networks for semantic segmentation. In *Proceedings of the IEEE CVPR 2015* (pp. 3431-3440).
- Dosovitskiy, A., Fischer, P., Ilg, E., Hausser, P., Hazirbas, C., Golkov, V., van der Smagt, P., Cremers, D. and Brox, T., 2015. FlowNet: Learning optical flow with convolutional networks. In *Proceedings of the IEEE CVPR* (pp. 2758-2766).
- Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. In *Proceedings of ICLR*. 2015
- Krizhevsky, A., Sutskever, I. and Hinton, G.E., ImageNet classification with deep convolutional neural networks. In *Proceedings of NIPS 2012* (pp. 1097-1105).