



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: Clasificación de estados cerebrales utilizando neuroimágenes funcionales

3.- DOCENTES:

RESPONSABLE/S: Enzo Tagliazucchi
COLABORADORES:
AUXILIARES:

4.- CARRERA de DOCTORADO

5.- AÑO: 2017 CUATRIMESTRE/S: SEGUNDO

6.- PUNTAJE PROPUESTO PARA CARRERA DE DOCTORADO: ½ punto.

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

8.- CARGA HORARIA SEMANAL: 15 hs.

Teóricas:
Problemas:
Laboratorio:
Seminarios:
Teórico – Práctico:
Salida a Campo:

9.- CARGA HORARIA TOTAL: 15hs

10.- FORMA DE EVALUACIÓN: Trabajo Final.

11.- PROGRAMA ANALÍTICO:

- Introducción al problema que intentan resolver las neuroimágenes. Principios básicos de fMRI. ¿Qué mide la señal de fMRI? Procesado de datos de fMRI: filtros espaciales y



temporales, corrección de movimiento, normalización y estandarización, técnicas para lidiar con artefactos residuales en los datos.

- Concepto de conectividad funcional en datos de fMRI. Redes de estado de reposo y análisis de componentes independientes. Estimación de la matriz de conectividad utilizando distintos métodos (correlaciones lineales, correlaciones parciales, Lasso, etc). Herramientas para la visualización de la conectividad funcional. Problemas conocidos del análisis multivariado de datos de fMRI
- Aprendizaje supervisado, primera parte. ¿Cómo medir la performance de un clasificador? Distintos algoritmos (SVM, árboles de decisión y métodos de ensemble, redes neuronales) y su aplicabilidad a datos típicos de fMRI. Selección de features. Estimación de parámetros y cross-validation. Algunos errores típicos en machine learning.
- Aprendizaje supervisado, segunda parte. Distintos esquemas de clasificadores multiclase. Midiendo la performance de clasificadores multiclase. Conectividad dinámica y estimación de conectividad funcional en ventanas cortas. Problemas conocidos de la estimación de la conectividad dinámica en fMRI y algunas herramientas para sortearlos.
- Aprendizaje no-supervisado y clustering. El algoritmo k-means, sus parámetros y variaciones. Otros algoritmos (clustering jerárquico, Bayes, detección de módulos en redes). Midiendo la performance de algoritmos de aprendizaje no-supervisado. Breve introducción a repositorios colaborativos online de datos de fMRI.

12.- BIBLIOGRAFÍA:

- John Lu, Z. Q. (2010). The elements of statistical learning: data mining, inference, and prediction. Journal of the Royal Statistical Society: Series A (Statistics in Society), 173(3), 693-694.
- Fornisano, E., De Martino, F., & Valente, G. (2008). Multivariate analysis of fMRI time series: classification and regression of brain responses using machine learning. Magnetic resonance imaging, 26(7), 921-934.
- Miller, A. C., & Guido, S. (2017). Introduction to machine learning with Python. O'Reilly Media.
- Pereira, F., Mitchell, T., & Botvinick, M. (2009). Machine learning classifiers and fMRI: a tutorial overview. Neuroimage, 45(1), S199-S209.
- Bishop, C. M. (2006). Pattern recognition. Machine Learning, 128, 1-58.
- Lemm, S., Blankertz, B., Dickhaus, T., & Müller, K. R. (2011). Introduction to machine learning for brain imaging. Neuroimage, 56(2), 387-399.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... & Vanderplas, J. (2011). Scikit-learn: Machine learning in Python. Journal of Machine Learning Research, 12(Oct), 2825-2830.