



PROCESOS MARKOVIANOS PARA APRENDIZAJE AUTOMÁTICO

Muchas técnicas de aprendizaje automático (en particular aprendizaje supervisado y aprendizaje reforzado) se basan en modelos Markovianos que alcanzan un equilibrio delicado entre complejidad y computabilidad.

El curso tendrá luego dos partes:

- Estudiaremos el marco matemático de los procesos de decisión Markovianos (MDP) y sus soluciones clásicas (Value iteration, Policy iteration). A partir de estas nociones, veremos algunas técnicas recientes de “reinforcement learning” y estudiaremos ejemplos prácticos donde estas técnicas son útiles.
- También, estudiaremos conceptos de mecánica estadística (con modelos Markovianos) que pueden ser muy relevantes a la hora de atacar problemas de recomendación o de compleción de data faltantes (por ejemplo a través de máquinas de Boltzmann o algoritmos de detección de comunidades en grafos aleatorios).

Detalle del programa:

- 1- Nociones básicas de probabilidad, cadenas y procesos de Markov, nociones de convergencia al equilibrio, velocidades de convergencia,
- 2- Nociones de programación dinámica: soluciones teóricas optimales en problemas de procesos de decisiones Markovianas: ahí damos el marco teórico cuando conocemos completamente el modelo (i.e. tenemos una descripción de las transiciones de una cadena de Markov dependiendo de acciones) y queremos resolver un problema de optimización (maximizar un objetivo dependiendo de las acciones tomadas y de las transiciones de la cadena de Markov).
- 3- Problemas de “bandits”: damos una primera clase de problemas donde el ambiente (o modelo i.e., las transiciones de la cadena de Markov) no es conocido. Ahí tenemos un primer ejemplo de equilibrio entre exploración y explotación. Uno quiere explorar las transiciones de la cadena pero también quiere ser eficiente. Estudiaremos resultados teóricos y heurísticas.
- 4- Miramos a problemas más generales (pero en primer instancia de tamaño chico) y estudiamos varias técnicas para conseguir un equilibrio entre exploración (vía Monte-Carlo o diferencias temporales) y eficiencia (vía programación dinámica).
- 5- Miramos luego problemas con espacios de estados mucho más grandes y estudiamos algunas técnicas modernas en este contexto. Acá hacemos hincapié en consideraciones computacionales y damos ejemplos de métodos que funcionan en la práctica.
- 6- Finalmente, estudiamos problemas de aprendizaje supervisado (por ejemplo máquinas de Boltzmann) donde la noción de convergencia al equilibrio para cadenas de Markov es crucial.

El curso se dividirá entre clases teóricas y clases prácticas donde se estudiarán ejemplos.

BIBLIOGRAFÍA:

Markov Chains: Gibbs Fields, Monte Carlo Simulation, and Queues (Texts in Applied Mathematics), by Pierre Bremaud (2001-02-01), Springer.

Reinforcement Learning: An Introduction, Richard S. Sutton and Andrew G. Barto
Second Edition, in progress MIT Press, Cambridge, MA, 2017

Dynamic programing and optimal control, D. Bertsekas,
SA, 2012

Restricted Boltzmann Machines: Introduction and Review
Guido Montufar, 2018 (lecture notes)



Universidad de Buenos Aires
Facultad de Ciencias Exactas y Naturales

Ref. Expte. N° 337/2018

Ciudad Autónoma de Buenos Aires,
25 FEB 2019

VISTO

La nota a foja 1 de la Dirección del Instituto de Cálculo, mediante la cual eleva la información y el programa del curso de posgrado **Procesos Markovianos para Aprendizaje Automático** para el año 2019,

CONSIDERANDO

Lo actuado por la Comisión de Doctorado,
Lo actuado por la Comisión de Posgrado,
Lo actuado por la Comisión de Presupuesto y Administración,
Lo actuado por este Cuerpo en la sesión realizada en el día de la fecha,
En uso de las atribuciones que le confiere el Artículo 113º del Estatuto Universitario,

**EL CONSEJO DIRECTIVO DE LA FACULTAD
DE CIENCIAS EXACTAS Y NATURALES
RESUELVE:**

ARTÍCULO 1º: Aprobar el nuevo curso de posgrado **Procesos Markovianos para Aprendizaje Automático** de 64 hs. de duración que será dictado por el Dr. Matthieu Jonckheere.

ARTÍCULO 2º: Aprobar el programa del curso de posgrado **Procesos Markovianos para Aprendizaje Automático** obrante a fs. 10/11 para su dictado durante el primer cuatrimestre de 2019.

ARTÍCULO 3º: Aprobar un puntaje máximo de dos (2) puntos para la Carrera del Doctorado.

ARTÍCULO 4º.- Aprobar un arancel de 1200 módulos eximiendo del mismo a estudiantes de grado y posgrado de Universidades Públicas. Disponer que los fondos recaudados ingresen en la cuenta presupuestaria habilitada para tal fin, y sean utilizados de acuerdo a la Resolución 072/03.

ARTÍCULO 5º: Disponer que de no mediar modificaciones en el programa, la carga horaria y el arancel, el presente Curso de Posgrado tendrá una vigencia de cinco (5) años a partir de la fecha de la presente Resolución.

ARTÍCULO 6º: Comuníquese al Instituto de Cálculo, a todos los Departamentos Docentes, a la Dirección de Estudiantes y Graduados, a la Dirección de Movimiento de Fondos, a la Dirección de Presupuesto y Contabilidad, a la Biblioteca de la FCEyN y a la Secretaría de Posgrado con copia del programa incluido. Cumplido, archívese.

RESOLUCION CD N° 0156

SP/ga/03/12/2018

Dr. JUAN CARLOS REBOREDA
DECANO