FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS UNIVERSIDAD DE CHILE

PROGRAMA DE CURSO

Código	Nombre
MA6922	Seminario Avanzado de Matemáticas II “Aprendizaje con Kernels”
Nombre en Inglés	

SCT	Unidades Docentes	Horas de Cátedra	Horas Docencia Auxiliar	Horas de Trabajo Personal
6	10	5		5

Requisitos	Carácter del Curso
	Electivo de Magister y Doctorado

Resultados de Aprendizaje

En este curso se exploran las técnicas avanzadas del aprendizaje de máquinas con *kernels* (también referidos en español como “núcleos”) desarrolladas en el último tiempo. El enfoque del curso incluye énfasis en los aspectos teóricos teóricos, implementaciones computacionales y también áreas de aplicación.

El trasfondo del curso se basa fuertemente en teoría de probabilidades, aprendizaje automático bayesiano, optimización y análisis funcional. Se busca además, que el estudiante sea capaz de utilizar técnicas de computación científica, modelamiento no paramétrico e inferencia aproximada para generar nuevo conocimiento en el área. Por esta razón, y para lograr los objetivos del curso, los requisitos para inscribir este curso son MA5204 (Aprendizaje de Máquinas) y MA5309 (Aprendizaje de Máquinas Avanzado).

Metodología Docente	Evaluación General
El curso se basa en el estudio, análisis y presentaciones evaluadas de artículos del estado del arte durante las semanas 2 y 7 del semestre. En segunda instancia, y a partir de los artículos referenciados al final de este documento, se explorarán trabajos acordes con la línea investigativa e intereses del curso, en este momento se espera que los alumnos propongan un tema específico y acotado de investigación. Finalmente, cada	El curso contará con las siguientes evaluaciones, cada punto podría representar un 25% de la nota final del curso: ● Presentación de artículos (exploración del estado del arte): Semanas 2 - 7. [Semanal, 7

estudiante será evaluado según un aporte de autoría propia con el objetivo de resolver su propuesta, generada en las segunda mitad del curso (semanas 8 - 15). En cuanto a los aspectos prácticos, estos se centran (de manera no excluyente) en la implementación de las metodologías estudiadas por medio de Python.	evaluaciones] ● Presentación de propuesta de investigación: Semana del 29/04/2019. [1 evaluación] ● Avances semanales de la propuesta : Semana 8 - 15 [8 evaluaciones] ● Artículo Resultante: Semana 15/16. [1 evaluación]

Unidades Temáticas

Número	Nombre de la Unidad	Duración en Semanas
	En el curso se explorarán dos variantes de aprendizaje con kernels. La primera está relacionada con la teoría de espacios de Hilbert de kernel reproductivo, su relación con las garantías de aproximación universal de funciones y su uso para diseñar *embeddings* de distribuciones de probabilidad. El segundo tema está relacionado con kernels de covarianza para procesos gaussianos y cómo éstos permiten diseñar técnicas de aproximación rala de dichos procesos, principalmente aquellas basadas en representaciones armónicas. Cada alumno de este seminario se concentrará en uno de estos temas.	

Bibliografía General
A continuación se describen los primeros artículos considerados las para lecturas semanas: un artículo por alumno por semana. 1. Al-Shedivat, M., Wilson, A. G., Saatchi, Y., Hu, Z., & Xing, E. P. (2016). Learning scalable deep kernels with recurrent structure. *arXiv preprint arXiv:1610.08936*.

2. Hensman, J., Durrande, N., & Solin, A. (2017). Variational Fourier features for Gaussian processes. *Journal of Machine Learning Research*, *18*, 151-1.

3. Lázaro-Gredilla, M. et al (2010), Sparse spectrum Gaussian process regression. *Journal of machine learning*.

4. Lázaro-Gredilla, M. et al (2009), Inter-domain Gaussian processes for sparse Inference using inducing features. *Advances in Neural Information Processing Systems*.

5. Oliva, J. B., Dubey, A., Wilson, A. G., Póczos, B., Schneider, J., & Xing, E. P. (2016). Bayesian nonparametric kernel-learning. *Proc. of Artificial Intelligence and Statistics* (pp. 1078-1086).

6. Simon-Gabriel, C. J., & Schölkopf, B. (2016). Kernel distribution embeddings: Universal kernels, characteristic kernels and kernel metrics on distributions. *arXiv preprint arXiv:1604.05251*.

7. Smola, A., Gretton, A., Song, L., & Schölkopf, B. (2007). A Hilbert space embedding for distributions. In *International Conference on Algorithmic Learning Theory* (pp. 13-31). Springer, Berlin, Heidelberg.

8. Tobar, F (2018). Bayesian nonparametric spectral estimation. *Advances in Neural Information Processing Systems*.

Vigencia desde:	Otoño 2019
Elaborado por:	Felipe Tobar
Revisado por:	Daniel Remenik – Jefe Docente