

Título: Nuevas perspectivas en predicción y modelado dinámico mediante mezclas no-gaussianas

Doctorando: Gonzalo Safont Armero (Programa de Doctorado en Telecomunicación)

Directores: Addison Salazar Afanador, Luis Vergara Domínguez

Resumen de la presentación:

Las mezclas de gaussianas (MoG) son un método frecuentemente utilizado para modelado de datos. Sin embargo, las MoG pueden verse limitadas cuando los datos que modelan no proceden de densidades gaussianas, o resultan complejos para datos con una gran dimensionalidad. En estos casos, resulta interesante el modelado mediante mezclas no gaussianas. Uno de estos tipos de modelado son las mezclas de componentes independientes (mezclas ICA o ICAMM). En el modelo de mezclas ICA, los datos se expresan como una combinación lineal de varias señales estadísticamente independientes entre sí, también llamadas “fuentes”. Este hecho permite modelar de manera más sencilla las señales, ya que cada fuente puede tratarse por separado con un estimador unidimensional.

Nuestro trabajo busca explorar las posibilidades de las mezclas ICA en dos campos diferentes del procesado de señal: la interpolación/predicción de datos, y el modelado dinámico de datos. Esta exploración se realiza con la intención de implementar un sistema combinado que permita un modelado dinámico robusto, soportando incluso datos parciales o con imperfecciones.

El trabajo puede dividirse en tres etapas. En la primera se buscaron métodos de predicción basados en el modelo de mezclas ICA. Esta exploración es novedosa, dada la falta de métodos de predicción/interpolación basados en el modelo que proponemos: en predicción, ICA sólo se ha utilizado como método de pre-procesado. Se siguieron dos líneas de investigación durante esta etapa: a) estimación por el método de máximo a posteriori, donde la verosimilitud de los datos respecto al modelo se maximiza mediante un algoritmo de gradiente; b) estimación de la media condicionada de los datos faltantes respecto a los datos conocidos.

La segunda etapa consistió en la extensión del modelo de mezclas ICA para considerar dependencias temporales. Más concretamente, se decidió considerar la dinamicidad de las mezclas. Esta dependencia temporal se modeló mediante una cadena de Markov oculta (HMM), lo cual permitía la adaptación de varios algoritmos clásicos. La exploración en este tema consideró otros trabajos previos en dicho sentido, pero con la mirada puesta en extender el modelo dinámico. Al igual que la primera etapa, se siguieron dos líneas de investigación diferentes: a) extensión de la cadena de Markov única a un modelo con varias cadenas de Markov acopladas (CHMM), lo cual permite trabajar con datos multimodales; b) el diseño e implementación de algoritmos de entrenamiento semisupervisado que pudieran estimar el modelo a partir de datos de entrenamiento.

Finalmente, la tercera etapa de trabajo consistió en la aplicación de los métodos de las dos primeras etapas a varias aplicaciones reales. Por el momento, los algoritmos de predicción se han aplicado de manera exitosa para la reconstrucción de datos de ensayos no destructivos y para la eliminación de artefactos en señales electroencefalográficas (EEG). También se han aplicado los algoritmos de modelado para detección automática de apneas del sueño y modelar los EEG durante tareas de memorización y concentración. Esta etapa todavía continúa, y el trabajo restante se encaminaría a combinar los métodos de predicción y de modelado dinámico en un único sistema robusto, enfocado a la biomedicina. Una de las aplicaciones en mente para este sistema robusto de modelado dinámico sería la monitorización de pacientes epilépticos y la detección temprana de crisis.