

Aprendizaje de redes bayesianas híbridas con mixturas de funciones base truncadas

Doctoranda: Inmaculada Pérez-Bernabé

Director: Antonio Salmerón Cerdán

Departamento de Matemáticas, Universidad de Almería, Ctra. Sacramento s/n, 04120
Almería, España,

{iperez, antonio.salmeron}@ual.es

Keywords: Redes bayesianas híbridas, mixturas de funciones base truncadas, aprendizaje automático

1. Introducción e hipótesis de partida

Las redes bayesianas [1] comenzaron a popularizarse a finales de la década de los 80 como una herramienta para el tratamiento de la incertidumbre en Inteligencia Artificial. Éstas constituyen una representación estructurada del conocimiento basada en un grafo dirigido acíclico donde cada vértice representa una variable aleatoria y cada arco indica la existencia de dependencia probabilística entre las variables que une. Una de las principales virtudes de las redes bayesianas es que permiten definir algoritmos eficientes de razonamiento que sacan partido de la estructura del grafo subyacente para realizar los cálculos de forma local [2,3,4]. No obstante, la mayor parte de los algoritmos existentes en la literatura están enfocados a problemas donde todas las variables de la red son de tipo cualitativo o discreto, lo que limita el ámbito de aplicación de este tipo de modelos.

Una solución pasa por discretizar las variables continuas, pero este proceso conlleva una pérdida de información, por lo que surge de forma natural el estudio de redes bayesianas donde puedan coexistir variables de tipo discreto y continuo, las llamadas *redes bayesianas híbridas*. La primera solución vino por la adopción del llamado modelo *condicional Gaussiano* [5], bajo el que subyace la suposición de que la distribución conjunta sobre las variables continuas es una normal multivariante. Además de esta restricción, las redes bayesianas de tipo condicional Gaussiano tienen la limitación de que no admiten estructuras donde variables discretas tengan padres continuos, lo que provoca que algunas relaciones no puedan ser representadas.

Con idea de resolver las limitaciones del modelo condicional Gaussiano, surgió el llamado modelo de *mixtura de exponenciales truncadas (MTEs)* [6], compatible con los mismos esquemas de inferencia exacta desarrollados para variables discretas. Desde la aparición de las MTEs, se han desarrollado numerosos trabajos en el ámbito de las redes bayesianas híbridas, destacando la introducción del modelo de *mixturas de polinomios (MOPs)* [7]. Tanto MTEs como MOPs han

sido recientemente generalizadas por el modelo de *mixturas de funciones base truncadas (MoTBFs)* [8].

2. Objetivos

El objetivo principal de la investigación a realizar es la obtención de métodos eficientes y efectivos para el aprendizaje automático de redes bayesianas híbridas basadas en MoTBFs. Este objetivo principal se desglosa en los siguientes subobjetivos:

- **Subobjetivo 1:** Desarrollo de algoritmos para la estimación de MoTBFs univariantes a partir de datos.
- **Subobjetivo 2:** Desarrollo de algoritmos para la estimación de MoTBFs condicionadas a partir de datos.
- **Subobjetivo 3:** Desarrollo de un método para la incorporación de conocimiento a priori en el proceso de aprendizaje de MoTBFs.
- **Subobjetivo 4:** Desarrollo de un algoritmo de aprendizaje de la estructura de la red particularizado al caso de MoTBFs.
- **Subobjetivo 5:** Desarrollo de un paquete software que implemente los métodos citados en los objetivos anteriores.

Todos los subobjetivos se corresponden con **aportaciones originales**. En lo relativo a los subobjetivos 1, 2 y 4, existen trabajos relativos al caso de modelos MTE, pero no esquemas válidos para el ámbito general de la MoTBFs. El objetivo 3 es totalmente novedoso en el ámbito de las redes bayesianas híbridas. En cuanto al subobjetivo 5, la idea es implementar un paquete en el entorno R [9], donde no existe hasta el momento ninguna funcionalidad para el manejo de redes híbridas más allá del modelo condicional Gaussiano.

3. Metodología y plan de trabajo

De forma genérica, la metodología a seguir durante el desarrollo de este proyecto de tesis se corresponde con el habitual método científico:

- formulación de hipótesis, que en nuestro caso implica el desarrollo de algoritmos para el aprendizaje automático de redes híbridas;
- recogida de observaciones: en este caso, disponer de datos reales sobre los que aplicar los algoritmos desarrollados;
- contraste de las hipótesis con las observaciones, es decir, evaluar los avances que proporciona el empleo de los nuevos métodos;
- finalmente, readaptación de las hipótesis iniciales a la luz de los resultados obtenidos.

Hemos dividido el plan de trabajo en **cinco tareas**, relacionadas con los objetivos mencionados en la sección 2, distribuidas en un período de tres años. Son las siguientes:

- **Tarea 1. Estimación de densidades MoTBF univariantes.** Plantearemos el problema de la estimación de parámetros como un programa de optimización, siguiendo la filosofía de los llamados M -estimadores [10]. Basaremos la elección del número de funciones base en un criterio de verosimilitud penalizada tipo BIC [11].
Temporización: M1-M18.
Hito 1: Alcance del subobjetivo 1, y publicación de los resultados en una revista JCR.
- **Tarea 2. Estimación de densidades MoTBF condicionadas.** Tomando como base la llamada estructura de árbol mixto [12], desarrollaremos un esquema para la estimación de densidades MoTBF condicionadas, que hará uso del método de estimación univariante desarrollado en la tarea 1.
Temporización: M12-M18.
Hito 2: Alcance del subobjetivo 2, y publicación de los resultados en una revista JCR. Esta tarea puede simultanearse con la tarea 1, y los resultados publicarse en un único trabajo.
- **Tarea 3. Incorporación de conocimiento a priori.** Seguiremos una filosofía similar al enfoque Bayesiano en estimación de parámetros. Sin embargo, en este caso, por la naturaleza semi-paramétrica de las densidades MoTBF, la especificación de información a priori no parece inmediata. Adoptaremos por tanto un esquema basado en la combinación de densidades, una a priori y otra estimada a partir de los datos usando los algoritmos construidos en las tareas anteriores.
Temporización: M19-M24.
Hito 3: Alcance del subobjetivo 3 y publicación de los resultados en una revista JCR.
- **Tarea 4. Aprendizaje estructural de redes híbridas con distribución MoTBF.** Comenzaremos explorando una alternativa simple, como es la aplicación de un algoritmo de aprendizaje de la estructura basado en tests de independencia, como el algoritmo PC, para luego estimar las densidades condicionadas correspondientes a dicha estructura. En una segunda fase, perseguiremos la definición de un estadístico específico para MoTBFs y estudiaremos su distribución en el muestreo, con la idea de construir un contraste de hipótesis específico.
Temporización: M25-M30.
Hito 4: Alcance del subobjetivo 4 y publicación de los resultados en una revista JCR.
- **Tarea 5. Integración del software en un paquete de R.** Esta tarea consistirá en recopilar el software desarrollado en las tareas anteriores para conformar un paquete de R con calidad suficiente como para ser puesto a disposición de la comunidad de usuarios de dicho entorno de análisis de datos.
Temporización: M31-M36.
Hito 5: Alcance del subobjetivo 5 y publicación de los resultados en una revista JCR tipo *Journal of Statistical Software*.

4. Relevancia

Existen innumerables campos de aplicación en los que coexisten variables de tipo discreto y continuo y que en la actualidad no son abordados de una forma totalmente satisfactoria desde el punto de vista de las redes bayesianas fundamentalmente debido a dos razones: por un lado, el todavía insuficiente desarrollo metodológico de las redes bayesianas híbridas, y por otro lado, la no disponibilidad de software que permita abordar tales aplicaciones por parte de usuarios de diferentes ámbitos. Pensamos que el presente proyecto aborda los dos aspectos mencionados, y supondrá un avance significativo no solo del aspecto metodológico, sino de la aplicabilidad de estas técnicas fuera del ámbito de la I.A.

Agradecimientos

El trabajo a realizar en esta tesis está subvencionado por el Ministerio de Economía y Competitividad, a través del proyecto TIN2010-20900-C04-02 y por la Junta de Andalucía mediante el proyecto P11-TIC-7821, con cofinanciación FEDER.

Referencias

1. Pearl, J.: Probabilistic reasoning in intelligent systems. Morgan-Kaufmann (San Mateo) (1988)
2. Jensen, F., Lauritzen, S., Olesen, K.: Bayesian updating in causal probabilistic networks by local computation. *Computational Statistics Quarterly* **4** (1990) 269–282
3. Madsen, A., Jensen, F.: Lazy propagation: a junction tree inference algorithm based on lazy evaluation. *Artificial Intelligence* **113** (1999) 203–245
4. Shenoy, P., Shafer, G.: Axioms for probability and belief function propagation. In Shachter, R., Levitt, T., Lemmer, J., Kanal, L., eds.: *Uncertainty in Artificial Intelligence 4*, North Holland, Amsterdam (1990) 169–198
5. Lauritzen, S.: Propagation of probabilities, means and variances in mixed graphical association models. *Journal of the American Statistical Association* **87** (1992) 1098–1108
6. Moral, S., Rumí, R., Salmerón, A.: Mixtures of truncated exponentials in hybrid Bayesian networks. In: *ECSQARU'01. Lecture Notes in Artificial Intelligence. Volume 2143*. (2001) 135–143
7. Shenoy, P., West, J.: Inference in hybrid Bayesian networks using mixtures of polynomials. *International Journal of Approximate Reasoning* **52** (2011) 641–657
8. Langseth, H., Nielsen, T., Rumí, R., Salmerón, A.: Mixtures of truncated basis functions. *International Journal of Approximate Reasoning* **53** (2012) 212–227
9. R Development Core Team: *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria. (2011) ISBN 3-900051-07-0.
10. Bai, Z., Wu, Y.: General m -estimation. *Journal of Multivariate Analysis* **63** (1997) 119–135

11. Schwarz, G.: Estimating the dimension of a model. *Annals of Statistics* **6** (1978) 461–464
12. Moral, S., Rumí, R., Salmerón, A.: Approximating conditional MTE distributions by means of mixed trees. In: ECSQARU'03. *Lecture Notes in Artificial Intelligence*. Volume 2711. (2003) 173–183