

Redes Bayesianas

Curso 2024-25

Módulo: Especialización

Materia: Técnicas Estadísticas Avanzadas

Créditos: 3 ECTS

Contenido:

1. *Introducción:* modelos gráficos probabilísticos, teoría de la información y causalidad, grafos.
2. *Tipología y representación de redes bayesianas:* independencia condicional probabilística, categóricas - tablas, gaussianas - distribuciones de probabilidad condicional, mixtas.
3. *Inferencia:*
 - a) Exacta (propagación de CPTs): fuerza bruta, eliminación de variables, paso de mensaje.
 - b) Aproximada (redes gaussianas): muestreo estructurado y por importancia, MCMC, bayes variacional.
 - c) Propagación de evidencia y causalidad en redes.
4. *Aprendizaje:* pesos, arquitectura.
5. *Extensiones y aplicaciones:* categorización, redes bayesianas dinámicas - procesos gaussianos, redes bayesianas profundas, ejemplos en casos de uso.

Resultados del aprendizaje:

- Capacidad para representar, mediante redes bayesianas, la estructura de dependencia de una colección de variables aleatorias.
- Manejo de situaciones de incertidumbre con redes bayesianas, extrayendo las correspondientes conclusiones.
- Aprendizaje automático de la estructura y/o parámetros de una red bayesiana a partir de una base de datos.
- Conocimiento avanzado del software adecuado para los apartados anteriores, en particular el comercial GeNIe y los lenguajes Python y R con los paquetes correspondientes.
- Identificación de problemas en que sean de aplicación los modelos gráficos probabilísticos.
- Elaboración de resultados comparativos de los modelos gráficos probabilísticos respecto de otras técnicas.

Competencias:

Básicas y generales: CG1, CG2, CG3, CG4, CG5, CG6, CG7

Transversales: CT1, CT2

Específicas: CE1, CE2, CE3, CE4, CE5, CE6, CE7

Bibliografía:

B.R. COBB, R. RUMÍ & A. SALMERÓN (2007). Bayesian networks models with discrete and continuous variables. En *Advances in Probabilistic Graphical Models, Studies in Fuzziness and Soft Computing* (pp. 81-102). Berlin, Heidelberg: Springer-Verlag.

R.G. COWELL, A.P. DAWID, S.L. LAURITZEN & D.J. SPIEGELHALTER (2007). *Probabilistic Networks and Expert Systems: Exact Computational Methods for Bayesian Networks*. New York, NY: Springer-Verlag.

D. KOLLER & N. FRIEDMAN (2009). *Probabilistic Graphical Models*. Cambridge, MA: The MIT Press.

K. KORB & A. NICHOLSON (2004). *Bayesian Artificial Intelligence*. Boca Raton, FL: Chapman & Hall / CRC Press.

S.L. LAURITZEN & F. JENSEN (2001). Stable local computation with conditional gaussian distributions. *Statistics and Computing*, 11(2): 191-203.

H. LIU, J. LAFFERTY & L. WASSERMAN (2009). The nonparanormal: Semiparametric estimation of high dimensional undirected graphs. *Journal of Machine Learning Research* 10(10): 2295-2328.

R. NEAPOLITAN (2003). *Learning Bayesian Networks*. Upper Saddle River, NJ: Pearson Prentice Hall.

T. NIELSEN & F. JENSEN (2010). *Bayesian Networks and Decision Graphs*. New York, NY: Springer-Verlag.

J. PEARL (1988). *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*. San Francisco, CA: Morgan Kaufmann Publishers.

I. TSAMARDINOS, L.E. BROWN & C.F. ALIFERIS (2006). The max-min hill-climbing bayesian network structure learning algorithm. *Machine Learning*, 65(1): 31-78.

M. SCUTARI & J.B. DENIS (2015). *Bayesian Networks: with Examples in R*. Boca Ratón, FL: Chapman & Hall / CRC Press.

T. ZHAO et al. (2012). The huge package for high-dimensional undirected graph estimation in R. *The Journal of Machine Learning Research*, 13(1): 1059-1062.

Software:

R con Rstudio y las librerías: *bnlearn*, *dbnR*, *BayesianNetwork*, *BayesianNetBP*, *Compare Causal Network*, *asbio*, *huge*.

Python con Jupyter: *igraph*, *pymc3*, *pyro*.

GeNIe.

Metodologías docentes:

Método expositivo.

Estudio de casos.

Prácticas de ordenador.

Evaluación:

Entrega de trabajos (por grupos): 60%

Examen teórico-práctico: 30%

Asistencia y participación activa: 10%

Profesorado:

Nombre: Jorge González Ortega

Despacho: 408, Facultad de CC Matemáticas, UCM

E-mail: jgortega@ucm.es