CORE
Metadata, citation and similar papers at core.ac.uk
Provided by Servicio de Difusión de la Creación Intelectual

Aplicación de Redes Bayesianas en el Modelado de un Sistema Experto de Triaje en Servicios de Urgencias Médicas

María M. Abad-Grau
Departamento de Lenguajes y Sistemas Informáticos
Universidad de Granada
E-mail: mabad@ugr.es
Tel: +34 958240634
Fax: +34 958243179

Jorge S. Ierache
Facultad de Informática Ciencias de la Comunicación y Técnicas Especiales, Universidad de Morón
jierache@unimoron.edu.ar
Tel: +5411 56272000 (189/746)

Claudio Cervino
Facultad de Medicina
Universidad de Morón
ccervino@unimoron.edu.ar
Tel: +5411 56272000 (774)

Resumen:

Este articulo describe el trabajo actual que estamos realizando para la aplicación de redes bayesianas en el modelado de sistemas expertos de triaje (clasificación) en los servicios de urgencias médicas. Las redes son construidas teniendo en cuenta tanto los datos provenientes de experiencias de triaje como la opinión de médicos expertos en urgencias. El sistema será utilizado con una doble finalidad: a nivel teórico para entender cómo la información requerida en el triaje puede ser modelada mediante redes bayesianas y a nivel práctico para entrenamiento y uso por el personal de triaje.

Introducción

Los servicios médicos de urgencias en la mayoría de los hospitales están sufriendo un fuerte incremento en el número de casos que se presentan. Con el fin de usar los recursos de forma más eficiente, cada vez en más hospitales se hace imprescindible la implantación de un sistema de triaje, o sistema para la catalogación de la urgencia con la que un paciente en la sala de emergencias debe ser atendido. Existen recomendaciones o sistemas estándares de triaje (Gómez Jimenez et al., 2003) para hacerlo. De todos ellos, el CTAS (de amplia difusión en el continente americano) y el MAT (implantado sobre todo en España), disponen de análisis de concordancia y estudios de validez y utilidad. MAT además se basa en categorías sintomáticas y algoritmos clínicos y se encuentra en versión electrónica. Ambos utilizan 5 niveles de triaje, que del 1 al 5 son: resucitación, de emergencia, urgente, menos urgente y no urgente.

Asimismo existen sistemas informáticos que pretenden ayudar a la hora de decidir el nivel de triaje que se le asigna a un paciente. Sin embargo son muy limitadas las funciones que realizan incluso cuestionándose que no son verdaderos sistemas de apoyo a la decisión sino soportes digitales del procedimiento a seguir (Guterman et al., 2003). Algunos de ellos permiten la inclusión de nuevo conocimiento por parte del usuario, generalmente en forma de reglas, son los llamados Sistemas basados en el Conocimiento o Sistemas Expertos como por ejemplo eTRIAGE (Dong et al., 2007), el cual utiliza las reglas CTAS como base de conocimiento. En general estos programas ofrecen precisiones demasiado bajas para poder usarlos como arbitraje en casos individuales (Graber y VanScoy, 2003). Quizás algunas de las limitaciones más relacionadas con su falta de precisión son la falta en cuanto a calidad y cantidad de las variables usadas. Frente a estos sistemas en los que el modelo ha sido creado por el experto o expertos, existen ejemplos de sistemas en los que el conocimiento se puede inducir a partir de los datos (aprendizaje automático o minería de datos), en este caso síntomas, análisis clínicos y otras pruebas, signos vitales, diagnostico final, etc., como por ejemplo el Mobile Emergency Triage System (MET) (Michalowki et al., 2005), para triaje en niños, que usa árboles de decisión y conjuntos aproximados. El principal inconveniente de

otros enfoques como las redes neuronales, los algoritmos basados en instancias y las máquinas de soporte vectorial es que no aportan información legible por el hombre del modelo que relaciona las distintas variables entre si.

En la sección 1 mostramos la potencialidad de las redes bayesianas en los sistemas hospitalarios de triaje. En la sección 2 se definen los distintos tipos de variables que se han tenido en cuanta y como se ha acotado el problema a un subconjunto dentro de cada grupo para restringirnos al triaje relacionado con enfermedades de origen cardiovascular y respiratorio. Asimismo se muestra la estructura de la red bayesiana aprendida de forma automática a partir de una simulación. En la sección 3 se realiza una evaluación comparativa con otros enfoques. Por último, en la sección 4 las conclusiones y futuras líneas de trabajo.

1. Redes bayesianas

Las redes bayesianas constituyen una alternativa a los árboles de decisión por permitir la representación de modelos más complejos de diagnosis o prognosis. Las redes bayesianas se basan en los fundamentos de la teoría de la probabilidad y permiten combinar el juicio del experto con las fuentes de datos disponibles, y realizar inferencia entre cualquier subconjunto de variables. Aunque tienen un amplio uso en el ámbito medico, en los sistemas de triaje a penas se han empezado a aplicar. Existen numerosos ejemplos en los que se muestran los buenos resultados que la redes bayesianas están teniendo en el diagnóstico medico (Yoonkyung and Cheol-Koo, 2003; Sebastiani and Perls, 2007).

Una red bayesiana (RB) se compone de dos partes. Por una lado, la estructura, el modelo o parte cualitativa: un grafo dirigido acíclico (GDA) donde cada nodo representa una variable aleatoria y los arcos representan dependencias probabilísticas entre las variables. Por otra parte, de una distribución condicional de probabilidades de la forma $P(x|\Pi_x)$ para cada nodo x dado su conjunto de padres Π_x. Esta parte de la red bayesiana se conoce como la parte paramétrica o cuantitativa de la red.

La mayor asunción de independencia que se representa en una RB se llama la "Propiedad Local de Markov" (Sebastiani et. al., 2005b) que consiste en que cada nodo es independiente de todos sus nodos no-descendientes dados los padres. Así, la distribución de probabilidad conjunta que representa una RB se puede obtener mediante el producto de distribuciones de probabilidades condicionales:

$$P(x_1, x_2, \ldots, x_n) = \prod_{i=1..n} P(x_i|\Pi_{xi}).$$

1.1. Clasificadores bayesianos

Un clasificador es una función que asigna una etiqueta clase a una instancia descrita mediante un conjunto de atributos. Cuando una RB se construye con la finalidad de predecir el valor de una variable clase dada cualquier configuración en el resto de las variables, se tiene un "clasificador bayesiano". Un clasificador bayesiano que suele ser bastante preciso a pesar de su simplicidad es el "clasificador bayesiano simple" (Naive Bayes classifier) (ver figura 1). El modelo de este clasificador asume la independencia de los atributos $\mathbf{x_1, x_2, \ldots, x_n}$ dada la clase $\mathbf{y}$. Aunque esta asunción no se cumple la mayoría de las veces, su generalmente buen comportamiento se debe a la exactitud con la que las distribuciones condicionales pueden calcularse incluso con muestras relativamente pequeñas dado que el conjunto de padres de todas las variables de entrada $\mathbf{x_1, x_2,}$

…, x_n se limita tan solo a la clase: $\Pi_{xi}=\{y\}$, i=1..n.

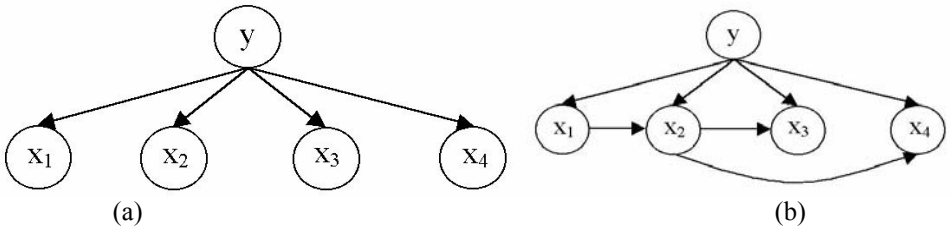

Figura 1. (a) Estructura de un clasificador bayesiano simple con 4 variables de entrada. (b) Estructura de un clasificador aumentado en árbol.

Un modelo de clasificador que mantiene un equilibrio entre simplicidad y validez es el "clasificador simple aumentado en árbol" (Augmented Naive Bayesian networks) (Friedman et al., 1997), el cual permite como máximo un arco entre atributos de entrada.

2. Utilización de redes bayesianas en el triaje hospitalario

Dada la inexistencia, en nuestro conocimiento, de sistemas de triaje basados en redes bayesianas, en este trabajo nos proponemos acotar el tipo de urgencias hospitalarias para las que el sistema debe responder. Siguiendo la opinión de los expertos hemos restringido el problema a las enfermedades cardiovasculares y respiratorias. Así, solo aquellas categorías sintomáticas que guardan más relación con estas enfermedades han sido seleccionadas como variables del grupo (1). Para las variables del grupo (2) y (4) se han tenido en cuenta también aquellas usadas por Novobilski et al. (2004) para la detección del síndrome coronario severo.

El sistema que se pretende construir es un sistema en capas, de forma que existirán 3 capas determinadas por el nivel de triaje que se pretende identificar. La figura 2 (a) presenta dicha configuración en capas. Se considera que para determinar los casos del nivel 1 no se requiere ni es práctico el uso de sistemas de apoyo a la decisión pues se debe actuar con sólo una muy rápida apreciación visual. En este trabajo nos hemos centrado en la capa externa, la más importante pues es la que pretende discernir entre el nivel de emergencia (nivel 2) y el resto de niveles menos urgentes: niveles 3, 4 y 5. En fases posteriores, se pretenden diseñar las redes bayesianas para las otras dos capas: la capa 2, a usar cuando un paciente es de nivel 3 o superior, llamada "Triaje 3" que determinara aquellos pacientes de nivel de triaje 3 frente a los de nivel 4 y 5 y la capa 4, a usar en pacientes catalogados como de nivel 4 o 5, llamada "Triaje 4" para distinguir aquellos de nivel 4 frente a los de nivel 5. Se pretende dotar también al sistema de variables explicativas o posibles diagnósticos.

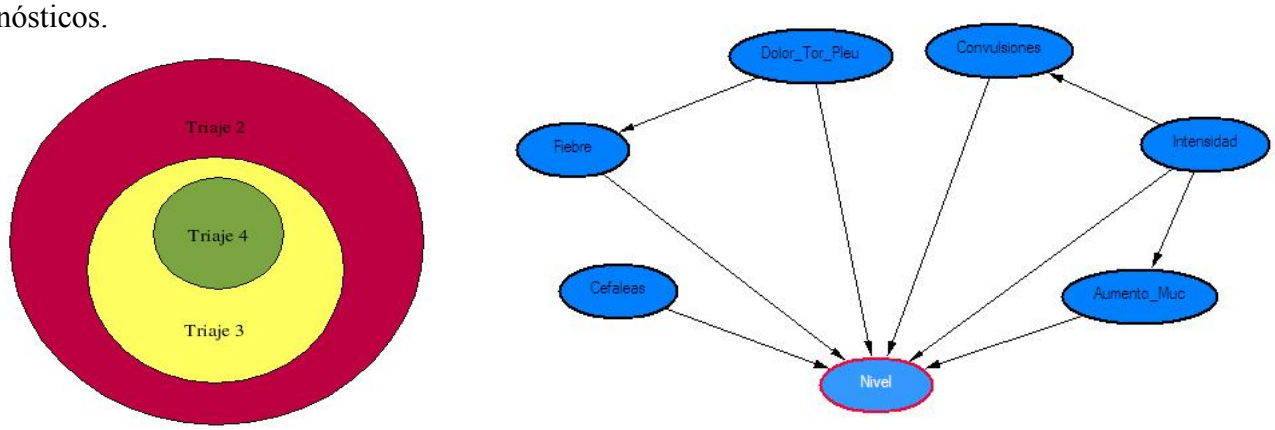

(a) **(b)**

Figura 2: (a) Arquitectura en capas del sistema de soporte a la decisión en el triaje basado en redes bayesianas. (b) Estructura del clasificador bayesiano obtenido a partir del algoritmo K2.

Se pretende utilizar una muestra de más de 1000 casos para realizar le evaluación de los modelos, que será obtenida a partir de casos prácticos en salas de urgencias de hospitales de Buenos Aires (se encuentran entre los potenciales interesados el Hospital Posadas, Hospital de Haedo, Hospital Italiano, Hospital Alemán, entre otros). En el estudio realizado hasta el momento se ha hecho una simulación con 124 casos. Se han escogido 40 variables que han sido seleccionadas a criterio de los expertos. En la figura 2 (b) se puede ver el clasificador bayesiano aprendido a partir de los datos con el algoritmo K2 (Cooper y Herskovits, 92). Se trata de un algoritmo para el aprendizaje automático de redes bayesianas. A partir de la red obtenida, el clasificador de la variable "triaje" puede ser obtenido con la sencilla selección de las variables que forman el manto de Markov (Sebastiani et al., 2005b) de dicha variable. Se ha utilizado el software Bayes Discoverer (Sebastiani et al., 2005b). En un segundo paso se ha utilizado directamente un clasificador bayesiano: el clasificador bayesiano simple, sobre las mismas 40 variables.

3. Evaluación

Para analizar los datos de la simulación se han utilizado los siguientes algoritmos de aprendizaje automático: (1) C4.5 (Quinlan, 1996): Basado en la creación de un árbol de decisión, C4.5 es el más aplicado entre los de su clase (C45). (2) El vecino más cercano: Un algoritmo basado en instancias (Aha, et al., 1991). Se usarán los parámetros k=1 y k=5 (VMC1, VMC5). (3) K2: Algoritmo genérico para creación de redes bayesianas. (4) Clasificador bayesiano simple (Naive Bayes classifier): Específico para clasificadores, con estimación de máxima verosimilitud (BS0) y estimador bayesiana con factor α=1 (BS1).

De cada uno de ellos se ha obtenido la precisión (en porcentaje de aciertos) utilizando validación cruzada de 5 hojas. La tabla 1 muestra la precisión para cada uno de los métodos empleados, ordenador por la misma. Como puede observarse, todos los algoritmos de redes bayesianas utilizados obtienen mejor precisión.

Tabla 1. Resultados de precisión obtenidos por los 6 algoritmos empleados.

Algoritmo	*Precisión*
BS1	87,90%
K2	86,99%
BS0	86,23%
C45	79,67%
VMC5	80,63%
VNC1	80,50%

4. Conclusiones y trabajo futuro

Con este trabajo se ha mostrado el potencial que las redes bayesianas suponen para el uso en sistemas expertos en el triaje hospitalario. En una siguiente fase de este trabajo se pretende la experimentación con casos reales. En trabajos posteriores se puede ampliar el sistema a otras categorías sintomáticas que estén relacionadas con enfermedades de distintos orígenes y realizar un diseño modular como se sugiere por Michalowki et al. (2005).

Agradecimientos: Este trabajo ha sido soportado en parte por el proyecto TIN2005-02516 del

Ministerio de Ciencia y Tecnología de España.

Referencias:

- Aha David W, Kibler Dennis, Albert Marc K (1991). "Instance-Based Learning Algorithm", Machine Learning 6, pp. 37-66.
- Cooper GF, Herskovits E (1992). “A Bayesian method for the induction of probabilistic networks from data”, Machine Learning, 9, pp. 309-347.
- Dong SL, Bullard MJ, Meurer DP, Blitz S, Akhmetshin E, Ohinmaa A, Holroyd BR, Rowe BH (2007). “Predictive validity of a computerized emergency triage tool”. Academic Emergency Medicine 14 (1), pp. 16-21.
- Friedman, N., Geiger, D. and Goldszmidt, M. (1997) “Bayesian network classifiers”, Machine Learning, 29, pp. 131-163.
- Gómez Jimenez, J, Segarra X, Prat J, Fernando JB, Albert E, Borras M (2003) “Concordancia, validez y utilidad del programa informático de ayuda al triaje (PAT) del Modelo Andorrano de Triaje (MAT)”. Emergencias 1 (5), pp. 339-44.
- Guterman JJ, Mankovich NJ, Hiller J (2003). “Assessing the effectiveness of a computer-based decision support system for emergency department triage”, Engineering in Medicine and Biology Society, 1993. Proceedings of the 15th Annual International Conference of the IEEE pp. 592 – 593.
- Michalowski Wojtek, Wilk Szymon, Farion Ken, Pke John et al. (2005) “Development of a decision algorithm to support emergency triage of scrotal pain and its implementation in the MET system”. INFOR, Nov 2005.
- Novobilski Andrew J, Fermire Francis M, Sonnemaker David (2004). “Mining Bayesian Networks to Forecast Adverse Outcomes Related to Acute Coronary Syndrome." ." The 17th International FLAIRS Conference 2004.
- Quinlan, JR (1996). "Improved Use of Continuous Attributes in C4.5", Journal of Artificial Intelligence Research, 4, pp. 77-90.
- Sebastiani P, Abad-Grau M, Ramoni MF. (2005b) Learning Bayesian networks. In Data Mining and Knowledge Discovery Handbook pp 193-230. Springer, New York, NY.
- Sebastiani Paola, Perls Thomas T (2007). “Complex Genetic Models”, Bayesian Belief networks: a practical guide to applications. Olivier Pouret, Patrck Nam and Bruce G. Marcot (Eds.). Wiley, NY.
- Yoonkyung Lee, Cheol-Koo Lee (2003). “Classification of multiple cancer types by multicategory support vector machines using gene expression data”, Bioinformatics 19 (9), pp. 1132-1139.