

## Modelado de Sistema Experto para Triage en Servicios de Urgencias Médicas

**María M. Abad-Grau**

Departamento de Lenguajes y Sistemas Informáticos  
Universidad de Granada  
E-mail: [mabad@ugr.es](mailto:mabad@ugr.es)  
Tel: +34 958240634  
Fax: +34 958243179

**Jorge S. Ierache**

ISIER - Facultad de  
Informática Ciencias de la  
Comunicación y Técnicas  
Especiales,  
Universidad de Morón  
[jierache@unimoron.edu.ar](mailto:jierache@unimoron.edu.ar)  
Tel: +5411 56272000  
(189/746)

**Claudio Cervino**

Facultad de Medicina  
Universidad de Morón  
[ccervino@unimoron.edu.ar](mailto:ccervino@unimoron.edu.ar)  
Tel: +5411 56272000 (742)

### Abstract

The Probabilistic graphical models, such as the bayesian networks and the diagrams of influences allow to represent of coherent form the knowledge of a dominion under conditions of uncertainty. They are based on the foundations of the theory of the probability and allow to combine the judgment of the expert with the sources of data available. This article describes the present work that we are making for the application of bayesian networks in the modeled one of expert systems of triage (classification) in the services of medical urgencies. The networks are constructed considering as much the originating data of experiences of triage like the opinion of expert doctors in urgencies. The system will be used with one double purpose: at theoretical level to understand how the information required in the triage can be modeled by means of Bayesian networks and at practical level for training and use by the triage personnel.

Key words: Bioinformatics, Triage, Expert systems, Bayesian Networks

### Resumen

Los modelos gráficos probabilísticos, tales como las redes bayesianas y los diagramas de influencias permiten representar de forma coherente el conocimiento de un dominio bajo condiciones de incertidumbre. Están basados en los fundamentos de la teoría de la probabilidad y permiten combinar el juicio del experto con las fuentes de datos disponibles. Este artículo 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.

Palabras claves: Bioinformática, Triage, Sistemas Expertos, Redes Bayesianas

## 1. 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. Existen muchos factores, tales como la frecuente imposibilidad de ser atendidos por familiares en el hogar que aumentan el número de pacientes con ingreso hospitalario. 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.

Algunos ejemplos de sistemas de implantación a gran escala [10], son el sistema canadiense CTAS (The Canadian Emergency Department Triage & Acuity Scale), el ESI (Emergency Severity Index), el MTS (Manchester Triage System) o el MAT (Modelo Andorrano de Triaje). Todos ellos usan una escala de categorías de 5 niveles (ver Tabla 1). Escalas de menos valores no han conseguido los mismos niveles de reproducibilidad, utilidad y validez suficientes para ser considerados estándares [7]. 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.

En la sección 1 hacemos una revisión del estado actual de los sistemas actuales de soporte a la decisión, sistemas expertos y sistemas de minería de datos de soporte al triaje. En la sección 2 mostramos la potencialidad de las redes bayesianas en los sistemas hospitalarios de triaje, dado los buenos resultados que están teniendo para el diagnóstico de enfermedades y otras aplicaciones médicas. Exponemos asimismo los conceptos básicos relacionados con la interpretación del modelo, el aprendizaje e inferencia de las redes bayesianas, y de su uso como herramientas de clasificación. En la sección 3 se definen las redes bayesianas a usar: los distintos tipos de variables que se han tenido en cuenta 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 creada por los expertos. Por último, los métodos de aprendizaje que serán usados para el aprendizaje automático de la estructura de la red. En la sección 4 los métodos de evaluación a utilizar que permitan comparar ambos modelos. Por último, en la sección 5 las conclusiones y futuras líneas de trabajo.

**Tabla 1.** Los 5 niveles de catalogación en el triaje hospitalario.

1. Resucitación	2. De emergencia	3. Urgente	4. Menos urgente	5. No urgente
-----------------	------------------	------------	------------------	---------------

## 2. SISTEMAS COMPUTACIONALES DE APOYO EN EL TRIAJE

Junto con la implantación de los sistemas de triaje hospitalario han aparecido diversos sistemas computacionales para el soporte a la decisión en el triaje. Entre estos se encuentran todos aquellos sistemas estáticos diseñados por médicos en los que el conocimiento se presenta por una serie de reglas que a menudo forman parte del propio código de forma que no es posible la actualización de las reglas por parte del usuario. Así ocurre por ejemplo con el “Automated Triage Management” (ATM) [12], desarrollado por expertos en medicina de urgencias de la Facultad de Medicina de la UCLA, el “Symptoms, Advice, Measure” (SAM) [15], desarrollado por un médico generalista y el Ped's Advice (PA) [15], sólo para servicios de pediatría, desarrollado a nivel local por médicos y enfermeras del Hospital Académico de Niños de Upsala (Suecia). En estos dos últimos sistemas, el usuario (generalmente enfermero-as) introducen una palabra referente al más notable de los síntomas, por ejemplo, tos y el sistema proporciona un cuestionario de respuesta si/no paso a paso.

Finalmente el sistema recomienda un nivel de triaje. Estos dos sistemas han sido criticados por sus usuarios por no ser sistemas reales de apoyo a la decisión, no estar adaptados a las situaciones de la práctica diaria en las que se hace uso de conocimiento psicológico y ético [13]. Estos programas adolecen por la falta de actualización y adaptación continua a la práctica. Cuando los programas permiten la inclusión de nuevo conocimiento por parte del usuario, generalmente en forma de reglas, deben tener claramente separado el conocimiento del código. Son los llamados Sistemas basados en el Conocimiento o Sistemas Expertos, los cuales representan el modelo de datos (como reglas o árboles de decisión) junto con los datos en la llamada Base de Conocimiento. Un ejemplo es eTRIAGE [5], el cual utiliza las reglas CTAS como base de conocimiento. eTRIAGE puede aceptar modificaciones de las reglas por parte del usuario según su juicio clínico, siempre que lo justifique. Dos ejemplos de programas cuya validez para el uso en salas de emergencias ha sido estudiado [11] son QMR (Quick Medical Reference) e Iliad. Ambos programas van más allá de la mera asignación de un nivel de triaje, pues sugieren un diagnóstico. Aunque Iliad tiene resultados significativamente mejores, ambos programas ofrecen precisiones demasiado bajas para poder usarlos como arbitraje en casos individuales. Por ejemplo, Iliad citó el diagnóstico real entre los 10 más probables en un 51% de las veces (QMR el 51%) y sólo en un 36% lo citó entre los 5 más probables (QMR en un 32%). Quizás algunas de las limitaciones más relacionadas con su falta de precisión son el hecho de que ninguno de ellos tienen en cuenta los medicamentos que los pacientes que acuden a urgencias están tomando. Tampoco permiten introducir la duración de los síntomas ni consideran la secuencia en la que los síntomas aparecen. Algunos síntomas no aparecen por ninguno de sus posibles sinónimos. Esta limitación también ocurre en SAM y PA. Estos sistemas en los cuales el conocimiento se representa en forma de reglas (sistemas basados en reglas) que pueden estar jerarquizadas (árboles de decisión) tienen en común que el modelo (las reglas o el árbol) ha sido directamente construido con el conocimiento del experto o expertos. Existen ejemplos de sistemas basados en el conocimiento en el que el conocimiento se puede inducir a partir de los datos (lo que se llama aprendizaje automático o minería de datos), en este caso síntomas, análisis clínicos y otras pruebas, signos vitales, diagnóstico final, etc., como por ejemplo el Mobile Emergency Triage System (MET) [16], para triaje en niños. MET utiliza “conjuntos aproximados” (del inglés rough sets) para definir “árboles de decisión aproximados”, capaces de representar incertidumbre en las reglas. Estos modelos se ajustan mejor a situaciones reales en las que existe información incompleta y asociaciones no claras entre síntomas y diagnósticos [17]. Además de los algoritmos capaces de aprender árboles de decisión, como C4.5 [20], los modelos para representar conocimiento en los que se basan otras aplicaciones que realizan aprendizaje automático pertenecen a otros muy diversos paradigmas, como por ejemplo redes neuronales, máquinas de soporte vectorial [24], algoritmos basados en instancias o redes bayesianas. Existen ejemplos de todos ellos en diagnóstico médico, como las redes neuronales para el diagnóstico de hipertensión [19], el de algoritmos basados en instancias para el diagnóstico del cáncer a partir de mamografías [2], el de las máquinas de soporte vectorial en la categorización del cáncer a partir de datos de expresión genética [25], o el de redes bayesianas para el cálculo del riesgo de un derrame cerebral a partir tanto de variables clínicas como de información genética [23]. El principal inconveniente de 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 sí. En concreto, las redes neuronales son modelos de caja negra, y sus estructura no puede ser interpretada directamente por el experto. Esto hace a estos sistemas no útiles cuando se pretende que el experto pueda modificarlos según su conocimiento y experiencia. Los árboles de decisión y las redes bayesianas, por el contrario, tienen una interpretación directa, de forma que el modelo puede ser explicitado por un experto, o interpretado e incluso mejorado por él si se aprende de forma automática a partir de un conjunto de datos.

### 3 REDES BAYESIANAS

Las redes bayesianas están ampliamente aceptadas como herramientas de inteligencia artificial capaces de representar incertidumbre en la resolución de un problema [18]. Constituyen una valiosa ayuda para representar relaciones entre variables. Además permiten describir con claridad sistemas complejos mediante la información que se extrae de su estructura. La inferencia bayesiana que se realiza sobre la red facilita la comprensión de la estructura del sistema. Las relaciones dinámicas también pueden representarse, en el caso de que la relación entre variables varíe con el tiempo. Algunos ejemplos de aplicaciones recientes con buenos resultados son en su uso para la detección de correos electrónicos maliciosos [6] o en la segmentación de mercados [14]. Cuando las relaciones de dependencia entre variables son causales la red se conoce con el nombre de Red Causal de Creencias (del inglés, Causal Belief Networks) o Red Probabilística Causal (Causal Probabilistic Networks).

Aunque los árboles de decisión (1) son muy útiles en la construcción de clasificadores, (2) generalmente presentan una alta fiabilidad y (3) pueden representar incertidumbre usando por ejemplo conjuntos aproximados, una jerarquía es una estructura más restrictiva de la que se necesita para representar las relaciones causa-efecto entre un conjunto de hábitos y de enfermedades (modelo predictivo) o las relaciones efecto-causa entre un conjunto de síntomas y de enfermedades (modelo de diagnóstico). Las redes bayesianas constituyen una alternativa a los árboles de decisión, por permitir la representación de modelos más complejos de diagnóstico o pronóstico. 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. En definitiva no están orientadas solo a la clasificación sino que permiten representar modelos complejos entre síntomas, diagnósticos e incluso información genética [23]. Además pueden tratar información incompleta y, en el proceso de inferencia, permiten comparar de forma sencilla sus resultados con los del experto. Aunque tienen un amplio uso en el ámbito médico, en los sistemas de triaje a penas se han empezado a aplicar. Existen algunos estudios que demuestran el mejor comportamiento de las técnicas de aprendizaje automático en la construcción de modelos de redes bayesianas que cuando son expertos médicos quienes lo hacen, como es el caso de su uso en salas de urgencia no para asignar un valor en la escala de triaje sino tan solo para la detección del síndrome coronario severo [19],[8]. La intención fue restringir el problema a un pequeño número de variables (14) que pudieran influir en la existencia del síndrome. Aunque los resultados de la red aprendida directamente eran mejores que la creada por expertos, información tal como los medicamentos que se han consumido, u otros factores sintomáticos así como la secuencia de aparición de los síntomas podrían ser de gran ayuda para mejorar la precisión de las predicciones.

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  $P(x_i|\Pi_x)$  para cada nodo  $x$  dado su conjunto de padres  $\Pi_x$ . 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” [22] 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:

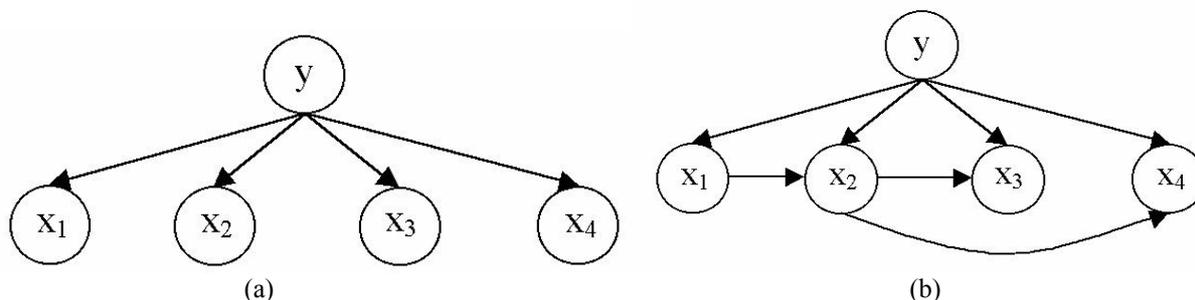
$$P(x_1, x_2, \dots, x_n) = \prod_{i=1..n} P(x_i|\Pi_{x_i}).$$

Para la construcción del modelo y/o los parámetros de una RB, se puede además aplicar la

estadística bayesiana que permite representar conocimiento a priori. Esto significa que la red puede tener en cuenta tanto la opinión del experto y representarla como conocimiento a priori y utilizarla para que, combinada con datos estadísticos se infiera la información a posteriori. A menudo confiar solo la opinión del experto para construir la estructura de la red no suele tener tan buenos resultados como cuando se unen datos empíricos para mejorar la precisión de la estructura. En el aprendizaje de una RB se llevan a cabo dos pasos: primero construir el modelo, después las distribuciones de probabilidad condicionada. En este trabajo, uno de los modelos construidos se ha hecho por expertos y el otro será automáticamente inferido a partir de un conjunto de datos teniendo en cuenta el conocimiento del experto como información a priori.

### 3.1 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  $x_1, x_2, \dots, x_n$  dada la clase  $y$ . 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  $x_1, x_2, \dots, x_n$  se limita tan solo a la clase:  $\Pi_{x_i} = \{y\}$ ,  $\forall i=1..n$ .



**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) [9], el cual permite como máximo un arco entre atributos de entrada. Para mejorar el comportamiento de un clasificador, a menudo se hace necesaria la selección automática de variables, de forma que aquellas variables que sean superfluas queden eliminadas [3].

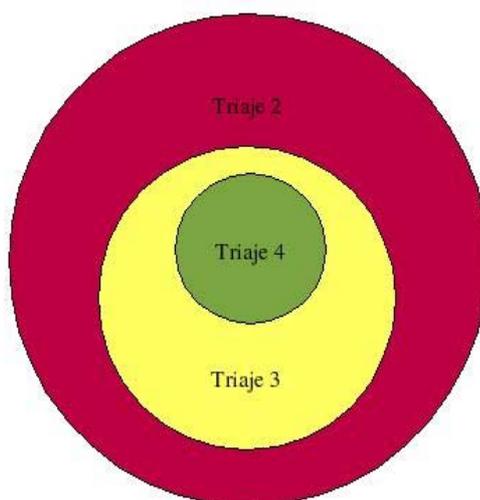
## 4. UTILIZACIÓN DE REDES BAYESIANAS EN EL TRIAJE HOSPITALARIO

Un clasificador bayesiano puede definirse para el triaje hospitalario si la clase es el nivel de triaje y las variables de entradas aquella información que deba tenerse en cuenta para inferir la clase. Uno de los problemas que han sido señalados por el personal de los servicios de urgencia como inconvenientes de los sistemas computacionales de triaje es su limitación en cuanto a las variables que tienen en cuenta para determinar el nivel de triaje. Considerando esas indicaciones, las

recomendaciones de los estándares de triaje (CTAS y MAT), las realizadas por otros expertos en medicina de urgencias que colaboran en este trabajo y la tan reclamada necesidad de usar vocabularios comunes, hemos considerado el uso de 5 categorías distintas de variables: (1) síntomas (se ha usado el estándar PAT V 3.0 [10], de categorías sintomáticas, que define 32 categorías sintomáticas y 14 subcategorías que agrupan un total de 575 motivos de consulta - síntomas y síndromes - codificados según CIE-9-MC) [10], (2) el historial clínico (que puede consistir tan solo en la información que el propio paciente o sus familiares provean in situ), (3) constantes vitales, (4) variables subjetivas y (5) signos vitales.

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 [19] 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 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.



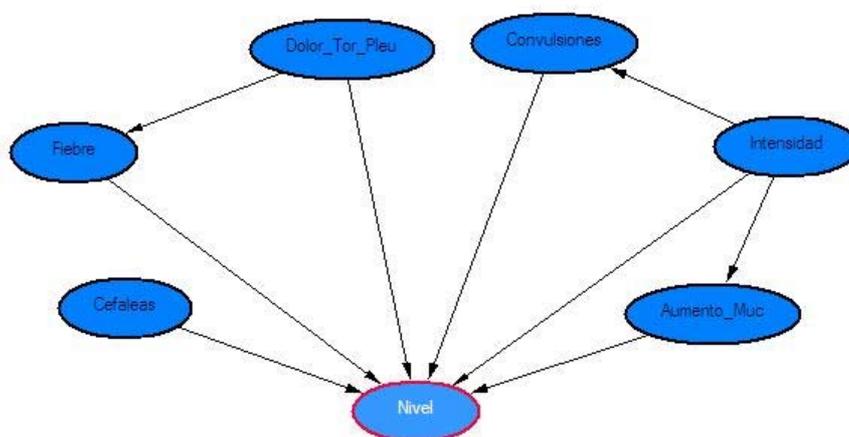
**Figura 2:** Arquitectura en capas del sistema de soporte a la decisión en el triaje basado en redes bayesianas.

En la tabla 2 pueden verse algunas de las variables que han sido elegidas por los expertos para la red bayesiana de la capa externa del sistema. Se pretende utilizar una muestra de más de 1000 casos para realizar la evaluación de los modelos, que será obtenida a partir de casos prácticos en salas de urgencias de hospitales de Buenos Aires. 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. La tabla 2 muestra algunas de ellas, el acrónimo y la categoría a la que pertenecen. En la

figura 3 se puede ver el clasificador bayesiano aprendido a partir de los datos con el algoritmo K2 [4]. 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 [21] de dicha variable. Se ha utilizado el software Bayes Discoverer [22], tanto para el aprendizaje y representación del modelo como para el aprendizaje paramétrico. En un segundo paso se ha utilizado directamente un clasificador bayesiano: el clasificador bayesiano simple, sobre las mismas 40 variables. El software usado ha sido MLT [1].

**Tabla 2:** Algunas de las variables seleccionadas por los expertos y categoría a la que pertenecen. En total fueron seleccionadas 40 variables.

<i>Variable</i>	<i>Acrónimo</i>	<i>Categoría</i>
Disnea	Disnea	PAT V 3.0
Dolor torácico pleurítico	DolorTorPleu	PAT V 3.0
Ortopnea	Ortopnea	PAT V 3.0
Dolor torácico en el esfuerzo	DolorTorEsf	PAT V 3.0
Dolor torácico en reposo	DolorTorRep	PAT V 3.0
Cianosis	Cianosis	Signo vital
Intensidad del cuadro	Intensidad	Variable subjetiva
Palpitaciones	Palpitaciones	Signo vital
Aumento de mucosidad	Aumento_Muc	PAT V 3.0
Sudoración	Sudoración	Signo vital
Convulsiones	Convulsiones	PAT V 3.0
Cefaleas	Cefaleas	PAT V 3.0
Fiebre	Fiebre	Constante vital



**Figura 3:** Estructura del clasificador bayesiano obtenido a partir del algoritmo K2.

## 5. EVALUACIÓN

Para analizar los datos de la simulación se han utilizado los siguientes algoritmos de aprendizaje automático:

- C4.5 [20]: Basado en la creación de un árbol de decisión, C4.5 es el más aplicado entre los de su clase (C45).
- El vecino mas cercano: Un algoritmo basado en instancias [2]. Se usarán los parámetros  $k=1$  y  $k=5$  (VMC1, VMC5).
- K2: Algoritmo genérico para creación de redes bayesianas.
- Clasificador bayesiano simple (Naive Bayes classifier): Especifico para clasificadores, con estimación de máxima verosimilitud (BS0) y estimador bayesiana con factor  $\alpha=1$  (BS1).

De cada uno de ellos se ha obtenido la precisión (en porcentaje de aciertos). Se ha utilizado validación cruzada de tamaño 5, de manera que las estimaciones mostradas son valores medios de 5 pruebas realizadas tras dividir la muestra en 5 partes y para cada prueba utilizar una parte (1/5) de los datos para hacer las estimaciones y el resto de los casos (4/5) para entrenamiento o aprendizaje del modelo. En fases posteriores se pretende también calcular la curva ROC que relaciona sensibilidad (o capacidad de detectar un caso grave cuando lo es) con especificidad (o capacidad de rechazar un caso como grave cuando es realmente no grave). La tabla 3 muestra la precisión para cada uno de los métodos empleados, ordenador por la misma:

**Tabla 3.** Resultados de precisión obtenidos por los 6 algoritmos empleados. Se muestran los valores medios usados en una validación cruzada de 5 hojas.

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

Como puede observarse, todos los algoritmos de redes bayesianas utilizados obtienen mejor precisión.

## 6. CONCLUSIONES Y TRABAJO FUTURO

Los árboles de decisión se vienen usando de forma convencional por representar el conocimiento de forma muy intuitiva y parecida a como los expertos lo hacen: en una serie de reglas jerarquizadas. Sin embargo, parece que en modelos relacionados con síntomas y enfermedades a menudo hay reglas inconsistentes, que han hecho que se utilicen árboles de decisión aproximados. 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. Se pretende realizar un diseño modular como se sugiere por Michalowski, et al (2003).

**Agradecimientos:** Este trabajo ha sido soportado en parte por el proyecto TIN2005-02516 del Ministerio de Ciencia y Tecnología de España.

## 8. REFERENCIAS:

- [1] Abad-Grau MM, Arias-Aranda D (2006). "Operations Strategy and Flexibility: modeling with Bayesian classifiers". *Journal of Industrial Management and Data Systems*, 106 (4), pp. 460-484.
- [2] Aha David W, Kibler Dennis, Albert Marc K (1991). "Instance-Based Learning Algorithm", *Machine Learning* 6, pp. 37-66.
- [3] Caruana, R.A. and Freitag, D. (1994), "Greedy attribute selection", in *Proceedings of the Eleventh International Conference on Machine Learning*, Morgan Kaufmann Publishers, New Brunswick, NJ, pp. 28-36.
- [4] Cooper GF, Herskovits E (1992). "A Bayesian method for the induction of probabilistic networks from data", *Machine Learning*, 9, pp. 309-347.
- [5] 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.
- [6] Dong-Her, S.; Hsiu-Sen, C.; Chun-Yuan, C.; Lin, D. (2004) "Internet security: malicious e-mails detection and protection", *Industrial Management and Data System*, 104, pp. 613-623.
- [7] Fernandes CM, Wuerz R, Cark S, Djurdjev O (1999). "How reliable is Emergency department triage?", *Annals of Emergencies in Medicine*, 34, pp. 141-147.
- [8] Fesmire FM, Novobilski A (2004). "First step in the Erlanger Artificial Intelligence Initiative: development of a Bayesian network utilizing initial triage history to risk stratify chest pain patients for thirty-day adverse outcome.", *Annals of Emergency Medicine* 42, pp. 857-888.
- [9] Friedman, N., Geiger, D. and Goldszmidt, M. (1997) "Bayesian network classifiers", *Machine Learning*, 29, pp. 131-163.
- [10] Gómez Jimenez, J, Segarra X, Prat J, Fernando JB, Albert E, Borrás 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.
- [11] Graber MA, VanScoy D (2003). "How well does decisión support software perform in the emergency department?", *Emergency Medicine Journal* 20, pp. 426-428.
- [12] 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.
- [13] Holmstrom, Inger (2007). *Decision aid software porgrams in telenursing: not used as intended?*

Experiences of Swedish telenurses. *Nursing and Health Sciences*, 9, pp. 23-28.

[14] Kuong-Wei, W.; Kuo-Fang, P. (2002) "Market segmentation via structured click stream analysis", *Industrial Management and Data System*, 102, pp. 493-502.

[15] Marklund B (2000). "Symptom, Rad, Atgard". Vanersborg: Vardutveckling AB.

[16] Michalowski, Wojtek, Kersten, Wilk, Szymon, Slowinsky, Roman (2003) Designing Man-Machine interactions for Mobile Clinical Systems: MET Triage support using palm handhelds. *European Journal of Operational Research*, 177 (3), pp. 1409-1417.

[17] 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.

[18] Nadkarni, S. and Shenoy, P.P. (2001) "A bayesian network approach to make inferences in causal maps", *European Journal of Operational Research*, 128, pp. 479-498.

[19] 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.

[19] Poli Riccardo, Cagnoli Stefano, Livi Riccardo, Coppini Hiuseppe, Valli Guido (1991). "A Neural Network Expert System for Diagnosing and Treating Hypertension", *Computer* 24(3), pp. 64-71.

[20] Quinlan, JR (1996). "Improved Use of Continuous Attributes in C4.5", *Journal of Artificial Intelligence Research*, 4, pp. 77-90.

[21] Sebastiani P, Abad-Grau M. M., Ramoni, M. F. (2005) Bayesian Networks for Genomic Analysis, In ER Dougherty, I Shmulevich, J Chen, ZJ Wang. *EURASIP Book Series on Signal Processing and Communications: Genomic Signal Processing and Statistics* pp 281-320. Hindawi, New York, NY.

[22] 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.

[23] 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.

[24] Vapnik, V.N. (1998), *Statistical Learning Theory*, J. Wiley, New York.

[25] 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.