

**KNOWLEDGE MODELING IN THE MEDICAL ASSISTANCE:
A APPROACH TO THE DECISION MAKING****MODELADO DE CONOCIMIENTO EN LA ASISTENCIA MÉDICA:
UNA APROXIMACIÓN PARA LA TOMA DE DECISIONES****MSc. John A. Bohada****Fundación Universitaria Juan de Castellanos**
Carrera 11, No. 11-70. Tunja, Boyacá, Colombia.
Tel.: 57-8-7470333, Fax: 57-8-7470336, Ext. 133.
E-mail: jbohada@jdc.edu.co

Abstract: Medical assistance is the process of medical intervention which is relational to attention the patient health care. This attention is based on three medical activities: diagnosis, treatment and prognosis. In decision making, these activities can be tackled from two approaches: decision and planning. Decision structures are designed to help physician in their task of taking extemporal decisions. Planning structures are designed to guide physicians in the time-dependant complex medical procedures. The goal of this article is to present a model that integrates several learning tools to develop decision and planning structures in the medical domain, specifically in the support of decision making.

Keywords: Machine learning, inductive learning, medical assistance, diagnosis, treatment, prognosis.

Resumen: La asistencia médica es el proceso de intervención médica relacionada con la atención en el cuidado de la salud del paciente. Ésta atención se basa en tres actividades médicas: diagnóstico, tratamiento y prognosis. En la Toma de decisiones, estas actividades pueden ser abordadas desde dos aproximaciones: decisión y planificación. Las estructuras de decisión son diseñadas para ayudar a los médicos en sus tareas de toma de decisiones atemporales. Las estructuras de planificación son diseñadas para guiar a los médicos en los procedimientos complejos dependientes del tiempo. El objetivo de este artículo es presentar un modelo que integra diversas herramientas de aprendizaje para desarrollar estructuras de decisión y planificación en el dominio médico, específicamente en el soporte a la toma de decisiones.

Palabras clave: Aprendizaje automático, aprendizaje inductivo, asistencia médica, diagnóstico, tratamiento, prognosis.

1. INTRODUCCIÓN

La asistencia médica es el proceso de intervención médica relacionada con la atención en el cuidado de la salud del paciente. Sus componentes son los datos e información médica, percepciones, razonamientos, juicios y decisiones de los profesionales de la salud, los procedimientos

usados y las intervenciones aplicadas. Ésta atención inicia con la aplicación de técnicas diagnósticas, continúa con la selección y adaptación de un tratamiento concreto, y finaliza con la realización de un pronóstico que evalúe, de antemano, la evolución del paciente con respecto a ese tratamiento. A lo largo de las últimas décadas, múltiples herramientas basadas en computador han

sido propuestas con el propósito de ayudar a mejorar los procesos involucrados en la asistencia médica. Estas herramientas son concebidas para proporcionar a los médicos de herramientas alternativas que les permitan realizar las tareas de la asistencia médica involucradas en los procesos de toma de decisiones de diagnóstico, definición de tratamientos y pronosis. Por tanto, el desarrollo de Sistemas de Soporte a la Toma de Decisiones (SSTD) es un amplio sector llamado a jugar un rol importante de la medicina moderna. La utilización de los SSTD en la asistencia médica permitirán la realización de cambios en la práctica médica, procesos, y resultados, proporcionando oportunidades para facilitar y mejorar el trabajo de los médicos y últimamente para mejorar la eficiencia y calidad del cuidado médico.

Éste artículo presenta el modelado e integración de herramientas de aprendizaje para desarrollar estructuras de decisión y planificación en el dominio médico, especialmente en el soporte a la toma de decisiones. Donde las estructuras de decisión son diseñadas para ayudar a los médicos en sus tareas de decisión y las estructuras de planificación son diseñadas para guiar a los médicos en procedimientos complejos temporales médicos.

2. EL MODELO DTP

2.1 Descripción del modelo DTP

En este artículo se presenta el modelo DTP (Diagnóstico – Tratamiento – Pronóstico) que unifica el proceso de diagnóstico, tratamiento y pronosis médica. Éste modelo distingue entre los niveles de decisión y planificación.

Decisión es un procedimiento mediante el cual una “*estructura decisional*” es usada para asignar una etiqueta o un valor para un paciente según la información disponible de ese paciente.

La decisión es un proceso de clasificación que propone un diagnóstico, un tratamiento o un pronóstico desde un conjunto finito discreto o continuo limitado de posibles alternativas.

Por ejemplo, los datos médicos acerca de un paciente pueden concluir que ese paciente tiene una determinada enfermedad (diagnóstico), o merece una de varias terapias (tratamiento), o prevé la evolución esperada de ese paciente respecto al tratamiento que siguió (pronóstico).

Planificación es un proceso común en medicina. Esto es observado cuando el médico no tiene ninguna información acerca del paciente y de la enfermedad que lo aqueja, por tanto, no puede llegar a una conclusión acerca del diagnóstico, tratamiento o pronóstico. En tales casos, el médico tiene que organizar la secuencia de acciones a ser tomadas para finalizar en una decisión. Básicamente, estas acciones son ordenar pruebas, análisis, y otros procedimientos médicos como la prescripción de medicamentos, la realización de pruebas clínicas especializadas, etc. El proceso de planificación consiste entonces, en la construcción de “*estructuras de planificación*” que puedan dirigir las tareas de diagnóstico, tratamiento, o pronosis si un simple diagnóstico, tratamiento o pronóstico no es claro.

2.2 Arquitectura del modelo DTP

En el modelado del sistema DTP, la acumulación de datos sería usada para capturar la esencia de los procesos diagnósticos, procedimientos terapéuticos y factores pronósticos, seguidos por la unidad del cuidado de salud que proporcionan esos datos. El sistema DTP está basado en los datos clínicos generados en las consultas o encuentros médico-paciente, y en los datos ya almacenados de la asistencia médica. La arquitectura del modelo DTP es presentada desde dos perspectivas: la decisional y la de planificación.

La *estructura decisional*, como muestra la Fig. 1, puede ser aprendida inductivamente desde bases de datos hospitalarias. Estas bases de datos contienen información supervisada acerca de pacientes pasados y sus características junto con las decisiones tomadas en términos de diagnóstico, tratamiento o pronosis. Las estructuras decisionales pueden ser representadas mediante árboles de decisión (Quinlan, 1996), grafos de decisión (Oliver, 1993), tablas de decisión o reglas (Michalski, 1987), para el caso de la diagnosis. Lenguajes de Representación de Guías de Práctica Clínica o CIGs (por Computer Interpretable Guidelines) (Shahar, 2001) o el modelo SDA (State-Decision-Action) (Riaño, 2005) para el caso del tratamiento y redes probabilísticas tales como Diagramas de Influencia (Howard y Matheson, 1981), Redes Bayesianas (Diez, 1998), o la combinación de Ordenes Parciales y Diagramas de transición de estados (Bohada *et al.*, 2007) para el caso de la pronosis. Las estructuras decisionales representan el conocimiento médico *know-what*.

La *estructura de planificación*, como muestra la Fig. 1 (representados [por corchetes]), puede ser aprendida inductivamente desde bases de datos hospitalarias que contienen información supervisada acerca de los procesos de decisión diagnóstica, terapias y pronósticas de pacientes asistidos previamente. Estos procesos son secuencias de hechos observados (i.e., causas) junto con las acciones consecuentes (i.e., efectos). Entonces, el plan de un paciente particular pasado en un proceso de diagnóstico, tratamiento o pronóstico, es descrito como una secuencia de unidades de información temporal causa-efecto. Por tanto, durante la primera visita el médico observa un conjunto de signos (causa C1) que lo llevan a ordenar algunas acciones médicas (efecto E1), después de un tiempo T1, el mismo médico puede observar otros signos (causa C2) que le hacen cambiar el tratamiento (efecto E2), y así sucesivamente hasta alcanzar una conclusión definitiva. En este proceso de asistencia (llamado [*episodio*] *clínico*), ésta conclusión puede ser un diagnóstico final, su tratamiento o un valor pronóstico. Las estructuras de planificación pueden ser representadas como protocolos médicos que describen el conocimiento médico *know-how*.

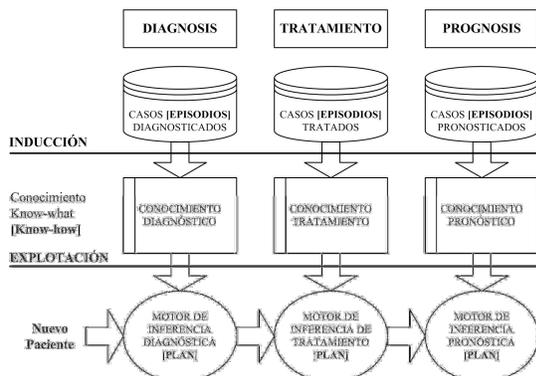


Fig. 1. Arquitectura del modelo DTP: Estructura decisional y de planificación

3. FUNCIONAMIENTO DEL MODELO DTP

3.1 Diagnosis

Diagnosis es el punto de partida del modelo DTP. Una matriz de datos supervisada que contiene la descripción de un conjunto de pacientes con la enfermedad diagnosticada. Cada fila de la matriz representa un *paciente prototipo* (PP) descrito según las mismas características médicas predefinidas (e.g., edad, sexo, porcentaje de colesterol, nivel de azúcar en la sangre, presencia o ausencia de alguna enfermedad específica, etc.).

Un algoritmo de aprendizaje inductivo es usado para transformar esos datos en un conjunto de reglas de producción que representan el *conocimiento diagnóstico*. Aunque el modelo DTP es compatible con muchos de tales algoritmos (Riaño, 1999), el procedimiento inductivo CN2 (Clark y Niblett, 1989) es el que se ha utilizado en este trabajo. Una vez que el conocimiento diagnóstico es generado y representado como reglas, éste puede ser usado para predecir enfermedades de nuevos pacientes. Algunas métricas, como la exactitud o el valor predictivo, pueden evaluar la calidad del proceso diagnóstico.

3.2 Tratamiento

Tratamiento es el punto medio del modelo DTP. Este proceso es basado en el conocimiento *background* del médico, no necesariamente acerca de la enfermedad ya diagnosticada (conocimiento *know-what* teórico), sino también acerca de la experiencia de los casos más representativos o pacientes atípicos que el médico ha tenido que tratar en el pasado (conocimiento *know-how* y *know-what* empírico). El médico utiliza el conocimiento *background* para seleccionar el tratamiento más prometedor que debe adaptarse al paciente antes de ser aplicado. A su vez, los resultados del proceso de tratamiento pueden generar interesantes resultados que podrían modificar el conocimiento *background* del médico. Este proceso es realizado con un modelo CBR (*Case-Based Reasoning*) (Bohada y Riaño, 2004) que incorpora Guías de Práctica Clínica o GPCs para manejar la evidencia científica en el momento de la toma de decisiones médica. Estas GPCs son integradas como CIGs que describen el conocimiento clínico contenido en una GPC de manera formal y determinística. La *base de casos* del modelo CBR está diseñado para contener, por un lado, una o más CIGs (i.e., conocimiento teórico) que generalicen el tratamiento seguido por los pacientes diagnosticados con una enfermedad particular, y por otro lado, los Pacientes Prototipo o PPs (i.e., conocimiento empírico) que representa a los pacientes que han sido atendidos siguiendo cualquiera de estas CIGs. Cada relación CIG-PP unifica en una CIG todas las terapias seguidas para todos los pacientes representados en las PP.

En el proceso de *recuperación de casos*, un nuevo paciente es descrito en términos de alguna característica booleana médica. Esta descripción puede ser usada para comparar el paciente con todas las filas PP (i.e., descriptores básicos) en la base de casos, con el fin de recuperar esa CIG que

se relaciona con el PP más cercano al nuevo descriptor básico. Para este proceso se utiliza la *distancia Hamming* para calcular la diferencia entre los pacientes reales y los descriptores básicos. Los nuevos pacientes pueden ser *atípicos* o *típicos* dependiendo de si ellos están distantes o no a cualquiera de los descriptores básicos en la base de casos. Es decir, un *threshold* predefinido es introducido para definir el límite entre pacientes atípicos o típicos. Cuando el modelo CBR está trabajando en modo no supervisado, la llegada de un nuevo paciente atípico implica que el sistema pare sin proponer ninguna terapia. Únicamente en el modo supervisado, o cuando el paciente es típico, el sistema adapta la CIG al paciente.

Modificación de la base de casos, la prognosis en la mejor forma de predecir la exactitud de la CIG cuando esta está aplicada a un paciente concreto. Cuando los mecanismos de prognosis no están disponibles, el criterio del médico acerca de la adecuación del tratamiento es aplicado. Si un CIG obtiene *buenos resultados* cada vez, éste es adaptado a los nuevos pacientes que llegan. La distancia Hamming es usada para evaluar como de atípico es el nuevo paciente.

Pacientes atípicos fueron definidos formalmente como aquellos pacientes cuya distancia a todos los descriptores básicos en la base de casos PPs están por encima del *threshold* predefinido. Cuando éste criterio se combina con los modos de trabajo del sistema (i.e., supervisado y no supervisado) tres situaciones pueden ocurrir:

- El nuevo paciente no es atípico y la CIG adaptada ha mejorado el estado del paciente. En este caso, la base de casos no cambia.
- El nuevo paciente es atípico y la CIG adaptada mejora el estado del paciente. Si el sistema está en modo supervisado, el paciente es incorporado como un descriptor básico al PP que es relacionado al CIG que ha sido adaptado al paciente. Si el sistema está en modo no-supervisado, ninguno de los procesos de adaptación y modificación son aplicados porque el riesgo de proponer una terapia inapropiada es alto.
- La CIG en la base de casos no produce un buen resultado. En este caso, es obligatorio introducir un nuevo caso CIG-PP en la base de casos de modo que el nuevo caso pueda extender el conocimiento sobre la asignación de la terapia. La nueva CIG puede ser propuesta por los médicos o, de otro modo, inducida por algún proceso automático (Riaño,

2003; Riaño, 2004). Inicialmente, el PP relacionado al nuevo CIG únicamente contendrá un descriptor básico del paciente. Si este paciente no es atípico en la base de casos, una redistribución del descriptor básico más cercano será considerado.

3.3 Prognosis

Prognosis es el proceso final del modelo DTP. Éste proceso utiliza variables predictoras para decidir la evolución de la enfermedad del paciente. Dos variables de predicción, medidas de acuerdo a sus frecuencias relativas, son consideradas: morbilidad y mortalidad. *Morbilidad* es la incidencia de enfermedad dentro de una población. También hace referencia a los efectos adversos causados por un tratamiento. *Mortalidad* es el número de muertes en un tiempo dado o lugar. También hace referencia a la proporción de muertes dentro de una población.

El *nivel de datos* en prognosis refiere a una estructura decisional de almacenamiento que contiene casos pronosticados. La eficacia es medida en términos de morbilidad y mortalidad relativa.

La *morbilidad relativa* hace referencia a la frecuencia del número de casos para los cuales hay una prevalencia de una enfermedad que ha seguido un tratamiento, dividida por el número de personas que han recibido ese tratamiento. Por otro lado, la *mortalidad relativa* hace referencia a la frecuencia del número de muertes para una diagnosis particular cuando un tratamiento es seguido en un año, dividido por el total de pacientes que han seguido ese tratamiento en el mismo año.

Una aproximación pronóstica basado en una *Belief Network* (BN) es propuesta para el proceso de inducción de conocimiento pronóstico desde los datos de pacientes almacenados que han seguido un tratamiento con resultados eficientes. Éste conocimiento es usado por un *motor de inferencia probabilística* para obtener factores pronósticos que permita relacionar estos factores a los datos de nuevos pacientes para la enfermedad de cierto paciente. Los datos respecto a la eficiencia de la GPC son usados para calcular la probabilidad condicional en esta red. La *Fig. 2* muestra un ejemplo de este proceso, donde la red está compuesta por nodos expresados por variables discretas que representan datos de pacientes, diagnosis, tratamientos, morbilidad y mortalidad.

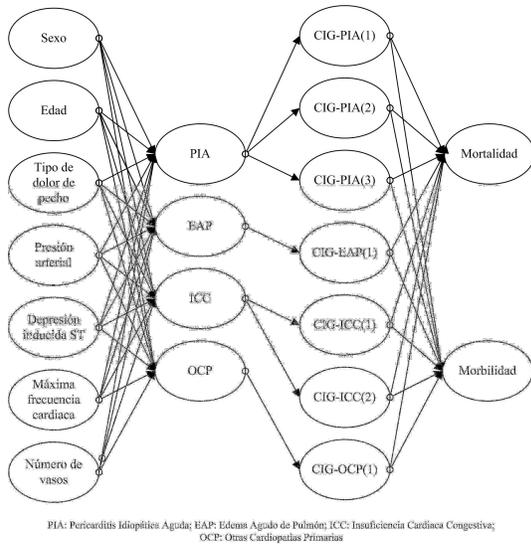


Fig. 2. Capas de la BN para la prognosis de enfermedades cardiacas

Todos los datos de los pacientes están conectados a todas las diagnósicos (e.g., $P(EAP | sexo = mujer)$), las diagnósicos son conectadas únicamente a los tratamientos particulares e.g. $P(CIG_ICC(2) | ICC)$, y todos los tratamientos son conectados a todas las variables pronósticas (e.g. $P(morbilidad = baja | CIG_CCI(2))$).

La red obtenida tiene múltiples utilidades pronósticas según el tipo de probabilidad condicional que el algoritmo de inferencia probabilística calcula. Por ejemplo, $P(mortalidad = alta | edad = adulto)$, $P(morbilidad = promedio | diagnosis = ICC)$, $P(morbilidad = baja | tratamiento = CIG_ICC(1))$. Es posible calcular el valor pronóstico de morbilidad y mortalidad condicionadas a una o varias descripciones de los pacientes (e.g. edad, sexo, síntomas, signos, etc.), o a una diagnósico particular, o a una guía de tratamiento concreto.

4. PRUEBAS Y RESULTADOS

Aunque los procesos de diagnóstico dentro del modelo DTP han sido probados con 4 bases de datos de enfermedades cardiacas disponibles en el repositorio de la Universidad de Irvine (Blake y Merz, 2007) (Cleveland.dat, Hungarian.dat, Long-beach-va.dat, and Switzerland.dat), los resultados no han sido incluidos en este trabajo dado que únicamente muestran el buen funcionamiento del algoritmo CN2, aspecto ya reportado por los autores del CN2 (Clark y Niblett, 1989).

Para el tratamiento, se muestra el funcionamiento del modelo CBR. Se ha probado la implementación con dos enfermedades cardiacas: Fibrilación Auricular (FibA) e hipertensión (Hip). Para cada enfermedad, tres CIGs son introducidas en la base de casos. El modelo CBR ha sido probado definiendo un PP por cada uno de las seis CIGs. Estos PPs fueron fijados con tres descriptores de pacientes básicos como resultado del estudio de los casos más representativos de los diferentes CIGs (Ray, 2003; Martín *et al.*, 2003; Munger, 2003; Lombera *et al.*, 2003; JNC7 Express, 2003 y Schwartz *et al.*, 2003) utilizados en este trabajo. De igual forma, el threshold fue fijado en 0.2 para FibA y 0.19 para Hip. Mil nuevos pacientes fueron definidos aleatoriamente y usados para conocer la evolución y los valores finales del tamaño de los seis PPs en la base de casos.

Para incrementar la robustez de las conclusiones, el proceso fue repetido 30 veces y el resultado promedio reportado. Dos tipos de análisis fueron hechos: En primer lugar, los factores de crecimiento de los PPs como los nuevos pacientes fueron tratados por el sistema CBR. En segundo lugar, el tamaño de los PPs en la base de casos una vez todos los pacientes han sido tratados. La Fig. 3 muestra el promedio de crecimiento de la base de casos para cada CIG. El principal resultado que se observa es que no todos los CIGs tienen el mismo grado de aplicabilidad. Por ejemplo, FibA2 y FibA3 muestran similar promedio el cuál es muy diferente al crecimiento de FibA1. Esto significa que el número de descriptores básicos necesitados para representar el espacio de aplicabilidad de FibA1 es menor que el número de descriptores básicos para FibA2 y FibA3, es decir, la CIG de FibA1 es más genérica que las otras dos. Un similar caso se observa para Hip1 y Hip2 respecto a Hip3.

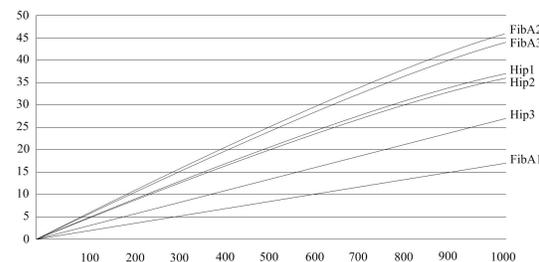


Fig. 3. Evolución promedio de los PPs en la base de casos

Otras interesantes observaciones están en el crecimiento logarítmico de la base de casos con respecto al arribo de nuevos pacientes, y el bajo

porcentaje promedio de nuevos pacientes que se necesitan para ser almacenados: 10.26% y 9.83% para fibrilación auricular e hipertensión, respectivamente. La Tabla: 1 muestra el tamaño promedio de la base de casos después de mil pacientes, analizadas a través de 30 repeticiones del proceso.

Tabla: 1. Media y desviación estándar del tamaño de la base de casos

	Fibrilación Auricular				Hipertensión			
	CIG1	CIG2	CIG3	Rec.	CIG1	CIG2	CIG3	Rec.
M	22.20	44.50	35.90	897.4	37.20	36.00	25.10	901.67
DS	11.53	15.99	13.93	19.14	6.23	7.00	4.93	10.39

Rec: Rechazado; M: media; DS: desviación estándar

La media (M) y la desviación estándar (DS) son dadas. Desde esta tabla se puede concluir que el criterio propuesto para la modificación de la base de casos tiene una baja variabilidad, particularmente para las CIGs de Hipertensión, lo que significa que la proporción de descriptores básicos en cada PP se mantiene estable en todas las pruebas realizadas. Las pruebas muestran que la asignación correcta de un tratamiento está directamente relacionada a los descriptores del paciente usados en las PPs iniciales. Es decir, las CIGs y PPs de la base de casos inicial deberán ser supervisados por algún experto médico antes que el sistema comience el trabajo o, de lo contrario, el sistema CBR sugeriría una terapia que no es la mejor en la base de casos. Las pruebas de la asignación correcta de un tratamiento para un paciente son directamente relacionadas al paciente.

Para prognosis, se usó una base de datos que contiene episodios de todos los pacientes admitidos en el Hospital Joan XXIII (Tarragona-España) en 2005, 2006, y 2007. El número de pacientes y la estadía media en días es de 13 y 10.5 para "Pericarditis Idiopática Aguda o PIA", 103 y 9 para "Edema Agudo de Pulmón or EAP", 64 and 11 para "Insuficiencia Cardíaca Congestiva o ICC", y 21 y 8 para "Otras Cardiopatías Primarias o OCP". La prognosis ha sido probada para las variables diagnósticas de sexo, considerando hombre (H) y mujer (M) por separado, y edad, discretizando entre joven (< 17 años), edad media (entre 17 y 60 años) y persona mayor (mayores de 60 años). Las probabilidades condicionales en la (a) representan los conceptos de "probabilidad de diagnosticar una enfermedad particular condicionada al hecho que el paciente tiene alguna característica (e.g., es hombre, es joven, etc.)". Estas probabilidades son pequeñas dado que ellas son calculadas sobre la

cantidad total de pacientes en el hospital y no únicamente sobre aquellos con enfermedad cardíaca. Este es un requerimiento del modelo DTP, el cual está destinado a aplicarse a pacientes que no han sido diagnosticados.

Siempre que ha habido pacientes de cada una de las cuatro enfermedades consideradas en 2005, 2006, y 2007, una GPC separada ha sido creada e incorporada en la base de casos. La proporción de pacientes en cada año ha sido usada para calcular las probabilidades condicionadas en la Tabla: 2(b). Estos porcentajes hacen referencia a la idea de "la probabilidad de ser tratado siguiendo una GPC concreta condicionada al hecho que tiene una de las cuatro enfermedades bajo estudio (i.e., PIA, EAP, ICC, y OCP).

Finalmente, la tabla 2(c) contiene los porcentajes que describen la "probabilidad que un paciente se cure, muera (mortalidad), o continúe enfermo (morbilidad) después de aplicar una de las GPC generadas con los pacientes del año 2005".

De las tablas anteriores se puede concluir que no hay claras diferencias en el diagnóstico entre hombres y mujeres (e.g., $P(EAP/H)@P(EAP/M)$), no hay gente joven afectada con enfermedad cardíaca (i.e., $P(PIA/<17) = P(EAP/<17) = P(ICC/<17) = P(OCP/<17) = 0,0\%$), la mayoría de las personas afectadas son mayores de 60 años, no hay casos de PIA en los años 2005 y 2006 (i.e. $P(2005/PIA) = P(2006/PIA) = 0$), los pacientes tratados según la guía PIA en los años 2005 y 2006 no se curaron completamente o murieron (i.e., $P(cura/PIA2005) = P(mortalidad/PIA2005) = 0,0\%$), y muy a menudo todas las enfermedades cardíacas siguen siendo crónicas después de seguir cualquiera de los tratamientos propuestos (i.e., $P(morbilidad/PIA2005)=P(morbilidad/EAP2005) = P(morbilidad/ICCI2005)=P(morbilidad/OCP2005)>60,0\%$).

Tabla: 2. Probabilidad condicional en los niveles de diagnóstico, tratamiento y pronóstico

		(a)			
		PIA	EAP	ICC	OCP
H		0.07%	0.51%	0.32%	0.14%
M		0.07%	0.57%	0.36%	0.08%
< 17		0.00%	0.00%	0.00%	0.00%
17 - 60		0.02%	0.17%	0.12%	0.08%
> 60		0.16%	1.28%	0.78%	0.20%

(b)

	2005	2006	2007
AIP	100.00%	0.00%	0.00%
ALE	34.79%	27.70%	37.50%
CCI	19.39%	29.09%	51.51%
OPC	33.87%	24.19%	41.93%

(c)

	Cura	Mortalidad	Morbilidad
AIP2005	0.00%	0.00%	100.00%
ALE2005	30.35%	5.35%	64.28%
CCI2005	13.33%	0.00%	86.66%
OPC2005	7.69%	3.84%	88.46%

5. CONCLUSIONES

Este artículo describe los primeros pasos hacia el desarrollo del modelo DTP y las pruebas realizadas en el dominio médico, particularmente en las actividades de la asistencia médica: diagnóstico, tratamiento y pronóstico. La aplicación de este modelo ha sido para solucionar problemas de decisión diagnóstica, para identificar componentes para el proceso de planificación, para aplicar un mecanismo de inferencia (en la actividad de tratamiento), y para proponer un mecanismo de pronóstico para tomar decisiones.

Los datos de pacientes utilizados en este trabajo para las actividades de diagnóstico, tratamiento y pronóstico corresponden a repositorios y bases de datos extranjeras, por tanto, se plantea como trabajo futuro, realizar las diferentes pruebas, tanto en las actividades de diagnóstico, tratamiento y pronóstico con datos reales de Hospitales de Colombia.

RECONOCIMIENTOS

Este trabajo fue realizado mientras realice mi estancia en la *Universidad Rovira i Virgili* en la ciudad de Tarragona, España, con la colaboración del grupo de investigaciones en Inteligencia Artificial (BANZAI) de esta misma Universidad y dirigido por el Dr. David Riaño.

REFERENCIAS

- Quinlan, J. R. (1996). *Induction of decision trees*, *Machine Learning*, Vol. 1, p. 81-106.
- Oliver, J. J. (1993). *Decision graphs: an extension of decision trees*, Technical report,

- Department of CS, Monash University, Australia, 92/193, p. 1-13.
- Michalski, R. S. (1987). *Concept Learning*, Encyclopaedia of AI, John Wiley & Sons.
- Shahar, Y. (2001). *Automated Support to Clinical Guidelines and Care Plans: the intention-oriented view*.
- Riaño, D. (2007). *The SDA* Model: A Set Theory Approach*, Machine Learning and Management of Health-Care Procedural Knowledge, 20th IEEE Int. Workshop on CBMS 2007, Maribor, Slovenia.
- Howard, R. A. y Matheson, J. E. (1981). *Influence Diagrams*, the Principles and Applications of Decision Analysis, p. 719-762.
- Diez, F. J. (1998). *Aplicación de modelos gráficos probabilistas en medicina*, En: Gámez J. A. y Puerta J. M. (eds.), "Sistemas Expertos Probabilísticos en Medicina", Universidad de Castilla-La Mancha, Cuenca.
- Bohada, J. A., Riaño, D. y Real, F. (2007). *Induction of Partial Orders to Predict Patient Evolutions in Medicine*, In Artificial Intelligence in Medicine, Springer LNAI 4594, p. 489-499.
- Riaño, D. (1999). *On the process of making descriptive rules*, LNAI 1624 (1999), 182-197.
- Clark, P. y Niblett T. (1989). *The CN2 Induction Algorithm*, ML 3, p. 262-283.
- Bohada, J. A. y Riaño D. (2004). *A CPG-based CBR model to offer the best available medical therapy*, Frontiers in Artificial Intelligence and Applications, Vol. 109, p. 62-71.
- Riaño, D. (2003). *Guideline Composition from Minimum Basic Data Set*, the 16th IEEE Symposium on Computer-Based Medical Systems, NY, p. 231-235.
- Riaño, D. (2004). *Time-Independent Rule-Based Guideline Induction*, ECAI2004, 2004.
- Blake, C. L., y Merz C. J (2007). *UCI Machine Learning Repository*, <http://www.ics.uci.edu/~mllearn/MLRepository.html>
- Ray, I. B. (2003). *Atrial fibrillation: present treatment protocols by drugs and interventions*, JIACM 4/3, p. 213-227.
- Martín, A., Merino, J., del Arco, C., Martínez, J., Laguna, P., et al. (2003). *Documento de consenso sobre el tratamiento de fibrilación auricular en los servicios de urgencias hospitalarios*, Rev. Española de Cardiología, 56/8, p. 801-816.
- Munger, T., et al. (2003). *Healthcare Guideline: Atrial Fibrillation*, Institute for Clinical Systems Improvement ICSI.

Lombera, F., Barrios, V., Soria, F., Peralta, L., Cruz, J., et al. (2000). *Guías de práctica clínica de la Sociedad Española de Cardiología en hipertensión arterial*, Rev. Española de Cardiología 53/1, p. 66–90.

JNC7 Express (2003). The Seventh Report of the Joint National Committee on: *Prevention, Detection, Evaluation, and Treatment of High Blood Pressure*, National High Blood Pressure Education Program, NIH publication.

Schwartz, G., et al. (2003). *Healthcare Guideline: Hypertension Diagnosis and Treatment*, Institute for Clinical Systems Improvement ICSI, EU.