

Diagnóstico inteligente de flebotrombosis (*Intelligent Diagnosis of Phlebothrombosis*)

Luis Gerez Martínez,ⁱ Nevelin Salazarⁱⁱ y Rosanna Costagutaⁱⁱⁱ

Campo temático: Inteligencia Artificial (convocatoria especial de Machine Learning)

Resumen

Este artículo presenta la aplicación de una técnica de Inteligencia Artificial al campo de la Medicina. Se trata de una red bayesiana especialmente creada para efectuar el diagnóstico de trombosis venosa profunda o flebotrombosis profunda. La red desarrollada toma en consideración síntomas, antecedentes clínicos, y resultados de determinadas prácticas médicas y de laboratorio para efectuar la detección de la afección en un paciente. Para realizar el testeo de la red se contó con los datos pertenecientes a sesenta casos reales suministrados por una institución de salud y sus correspondientes diagnósticos efectuados por dos médicos especializados. Sobre los resultados se aplicaron las métricas *Precision* y *Recall* obteniéndose valores satisfactorios.

Palabras clave: Red Bayesiana, Diagnóstico médico, Flebotrombosis, Diagnóstico inteligente

ⁱ Universidad Nacional de Santiago del Estero. luis.gerez@gmail.com

ⁱⁱ Universidad Nacional de Santiago del Estero. salazar.irene@gmail.com

ⁱⁱⁱ Universidad Nacional de Santiago del Estero. rcostaguta@hotmail.com

Abstract

This article presents a bayesian network to diagnose deep vein thrombosis or deep phlebothrombosis. The developed network takes into account symptoms, medical history and results of certain medical and laboratory practices to detect patient condition. To test the network, we have data from sixty real cases and their diagnoses made by two specialist doctors. The Precision and Recall metrics were applied, obtaining satisfactory results.

Keywords: Bayesian Network, Medical Diagnostic, Phlebothrombosis, Intelligent Diagnostic

1. Introducción

La aplicación de Inteligencia Artificial (IA) en el área de la medicina, tanto en tareas de diagnóstico como de terapéutica, ya no es una situación novedosa. Día a día vemos surgir aplicaciones inteligentes creadas con la finalidad de ayudar a los profesionales de la salud en la realización de sus quehaceres. Las técnicas de IA usadas son variadas: sistemas expertos, redes neuronales, redes bayesianas, agentes inteligentes, por nombrar sólo algunas. También son variadas las situaciones médicas para las que este tipo de aplicaciones son creadas: análisis genómico, apoyo para toma de decisión en medicina de urgencia, reconocimiento de imágenes clínicas, entre otras.

La incertidumbre es una característica de la medicina. Los médicos experimentan incertidumbre tanto al analizar la sintomatología de un paciente como al considerar la efectividad de los posibles tratamientos a indicarle (Sandoyal, 2014).

Cualquiera sea la enfermedad que se trate, contar con un diagnóstico correcto y oportuno aumentará las posibilidades de curación del paciente. Esto resulta particularmente importante en el caso de la flebotrombosis profunda o trombosis venosa profunda (TVP), ya que puede provocar una enfermedad grave en el paciente, y hasta llevarlo a la muerte. Una TVP ocurre cuando se forma un coágulo de sangre en una vena profunda, por lo general en la parte inferior de las piernas, los muslos o la pelvis, pero también puede aparecer en los brazos. Cualquier persona puede padecerla, aun con escasos síntomas, por ello la necesidad de su diagnóstico certero y precoz.

Las redes bayesianas permiten visualizar relaciones probabilísticas entre variables de interés y realizar inferencias útiles para la toma de decisión en contextos de incertidumbre. En este trabajo se presenta una red bayesiana creada especialmente para la detección correcta y oportuna de una TVP. La experimentación realizada demostró la eficacia en su funcionamiento.

El artículo se organiza como sigue. En la sección 2 se presenta la afección sobre la que se enfoca este trabajo. En la sección 3 se introducen las redes bayesianas. En la sección 4 se describen los pasos ejecutados para crear la red capaz de diagnosticar TVP. En la sección 5 se documenta la experimentación llevada a cabo y sus resultados. La sección 6 contiene antecedentes, y finalmente, en la sección 7 se enuncian conclusiones y futuras líneas de trabajo.

2. La trombosis venosa profunda

La TVP o flebotrombosis profunda se produce cuando se forma un coágulo de sangre (trombo) en una o más venas profundas del cuerpo, generalmente en los miembros inferiores, es decir, piernas. La TVP puede causar dolor o hinchazón en las piernas, pero puede estar presente sin síntoma alguno. Se trata de un trastorno grave porque los coágulos sanguíneos que aparecen en las venas pueden

soltarse, desplazarse a través del torrente sanguíneo, y alojarse en los pulmones obstaculizando el flujo de sangre.

La TVP puede ocurrir cuando la persona tiene ciertas enfermedades que afectan la forma en que coagula su sangre. En general, los coágulos surgen como consecuencia de un evento que impide que la sangre circule o se coagule normalmente, como una lesión en una vena o el efecto de ciertos medicamentos. También pueden aparecer si el paciente no se mueve durante mucho tiempo, por ejemplo, después de una cirugía o de un accidente, cuando estuvo confinado a una cama por un largo período.

Los síntomas de una TVP abarcan: hinchazón de la pierna afectada (rara vez afecta ambas piernas), dolor en la zona (generalmente en pantorrilla y se siente como calambre o inflamación), enrojecimiento o manchas en pierna afectada, y también, sensación de calor en ella. En algunos casos estos síntomas no son percibidos por el paciente y la TVP pasa desapercibida.

Existen algunos factores que pueden aumentar el riesgo de sufrir una TVP. Cuantos más factores estén presentes en una persona mayor será el riesgo de que ella la padezca. Los factores de riesgo son los siguientes:

- a) Algunas personas heredan un trastorno que hace que su sangre se coagule más fácilmente. Es posible que esto no produzca coágulos de sangre, a menos que se combine con uno o más de los otros factores.
- b) Cuando las piernas permanecen quietas por largos períodos (reposo prolongado o parálisis los músculos de las pantorrillas) los músculos no se contraen para ayudar a la circulación sanguínea, lo que puede aumentar el riesgo de sufrir coágulos.
- c) Las lesiones en las venas o las cirugías pueden aumentar el riesgo de sufrir coágulos.
- d) El embarazo aumenta la presión en las venas de la pelvis y de las piernas, y por ende aumenta el riesgo de formación de coágulos. Las mujeres con un trastorno de coagulación heredado tienen mayor riesgo de sufrir coágulos sanguíneos durante el embarazo, y esta situación puede continuar hasta seis semanas después de nacido el bebé.
- e) Los anticonceptivos orales y las terapias de reemplazo hormonal pueden aumentar la capacidad de coagulación de la sangre, y en consecuencia el riesgo de formación de coágulos.
- f) El sobrepeso aumenta la presión en las venas de la pelvis y de las piernas, aumentando los riesgos de formación de coágulos.
- g) El fumar afecta la coagulación y la circulación de la sangre, generando mayor riesgo de formación de coágulos.
- h) Ciertos tipos de cáncer y tratamientos oncológicos aumentan las sustancias en sangre que provocan la coagulación, aumentando los riesgos de formación de coágulos.

- i) Las personas con insuficiencia cardíaca tienen funciones cardíacas y pulmonares limitadas, aumentando por ello los riesgos de formación de coágulos.

3. Redes bayesianas

Las redes bayesianas, también conocidas como redes causales, son una de las técnicas de Inteligencia Artificial más utilizadas para modelar dominios inciertos. Una red bayesiana consta de un conjunto de nodos que representan variables de interés, y de arcos dirigidos que conectan estos nodos para representar las relaciones causales entre esas variables (Pearl, 1998). Cada nodo del grafo puede tomar diferentes estados, dependiendo de los valores que pueda asumir cada variable representada. La orientación de los arcos indica la influencia entre variables, es decir, la dirección del efecto. Teniendo en cuenta esto, es posible identificar nodos padres (aquellos desde los cuales parten arcos dirigidos hacia otros nodos) y nodos hijos (nodos que reciben el impacto de arcos provenientes de otros nodos). Dentro de una red bayesiana un nodo puede ser del tipo padre para algunas variables y del tipo hijo para otras. Aquellos nodos que únicamente pertenecen al tipo padre, corresponden a las variables independientes del dominio y se denominan nodos independientes.

El concepto básico en el tratamiento de la incertidumbre en redes bayesianas son las probabilidades condicionales. Para cada nodo hijo, se establece la probabilidad de cada uno de sus estados según las combinaciones de estados de sus nodos padre. Existen diferentes formas de obtener los valores para estas probabilidades: pueden ser especificados por un experto en el dominio, obtenerse a partir de información estadística, o calcularse a partir de un conjunto de datos con un algoritmo de aprendizaje automático. Cada nodo independiente tiene una probabilidad asociada, llamada evidencia o probabilidad marginal, que corresponde a una probabilidad simple o incondicional. Los mecanismos de inferencia en las redes bayesianas se basan en el teorema de Bayes el cual permite inferir el estado de una variable determinada considerando el estado de cualquier combinación de las otras variables en la red (Jensen, 1998).

4. Caso de aplicación

El área de diagnóstico clínico corresponde sin duda a un contexto de incertidumbre. Contar con una red bayesiana para diagnóstico de TVP ayudaría al médico a gestionar las incertidumbres del caso y favorecer su proceso de toma de decisión.

El proceso de creación de la red se realizó con la ayuda de un médico especialista en TVP. El primer paso consistió en identificar las variables del dominio a incluir. El especialista manifestó que para diagnosticar una TVP es necesario considerar determinados signos y síntomas, a saber: la existencia de dolor en un miembro inferior, la presencia de edema blando y con fóvea (situación que suele darse al

principio del proceso), la sensación de calor en la zona afectada, cambios en el color de la piel (pudiendo apreciarse cianosis cuando el tono es azulado, o eritema cuando es rojizo), la existencia de circulación colateral al producirse la dilatación de venas superficiales, un cordón venoso palpable, inflamado (algunas veces acompañado de dolor), la presencia de dolor en la parte alta de la pantorrilla al realizar la dorsiflexión del tobillo con la rodilla flexionada en un ángulo de 30° (conocido como Signo de Homans). El experto también estableció que para efectuar un correcto diagnóstico es necesario considerar ciertos antecedentes del paciente: si es o no paciente oncológico, y si tuvo recientemente una hospitalización prolongada debido a una cirugía de pelvis o a algún otro trauma mayor. Por otro lado, también recomendó incluir los resultados de otros estudios conocidos en el ambiente médico como criterios de Wells, los cuales son: una prueba de sangre en laboratorio (Dímero C), una ecografía inicial, y una repetición de la ecografía.

Producto del trabajo conjunto con el especialista se identificaron trece variables: Dolor (DO), Edema (E), Calor local (CL), Color piel (CP), Circulación colateral (CC), Cordón venoso palpable (CVP), Signo de Homans (SH), Antecedentes (A), Dímero C (DC), Ecografía (ECO), Repetición de ecografía (RE), Probabilidad (P), y finalmente, Diagnóstico (D). A todas las variables le corresponde el tipo discreto. DO, CL y SH son booleanas, pudiendo asumir valor Si o No. Las variables DC, ECO y RE asumen valor positivo o negativo según corresponda. Por otro lado, E puede ser negativa si no hay edemas o “Bf” cuando se observa blando de fóvea; CP puede ser negativa si la piel tiene coloración normal, “Ci” si está cianótica o “Eri” si existe eritema; CC puede ser negativa o asumir el valor “Dv” si se observa dilatación venosa; CVP puede ser negativo o “In” cuando el cordón está inflamado; A puede ser “Ca” si se trata de un paciente oncológico, “Cp” si recientemente sufrió alguna cirugía que lo obligó a permanecer en cama mucho tiempo, o “Na” si no se verifican ninguna de las dos situaciones anteriores; P puede resultar “PA” si es alta o “PBM” cuando es moderada o baja; y finalmente, D puede indicar una TVP cuando asume el valor “Tratamiento” o descartar la afección con el valor “TVP excluida”. Las variables y sus valores posibles se muestran en la Tabla 1.

El paso siguiente consistió en definir la topología de la red, es decir, la forma en que las variables convertidas en nodos se conectarían entre sí. La red bayesiana resultante es la que se muestra en la Figura 1.

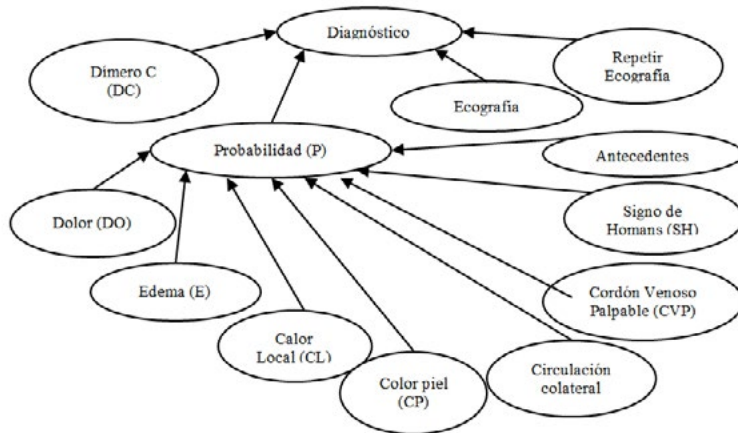


Figura 1. Red bayesiana creada para el diagnóstico de TVP

Dada la existencia de dos nodos de tipo hijo (Probabilidad y Diagnóstico), se procedieron a crear sus respectivas tablas de probabilidad condicional. Para ellos se consideraron los valores posibles de las variables que brindan información al nodo hijo Probabilidad (P), en el primer caso, y al nodo Diagnóstico (D) en el segundo. En las Tablas 2 y 3 se muestran algunas de esas probabilidades. La definición de los valores probabilísticos contenidos en las celdas fue realizada por el médico especialista en TVP.

Variables	Valores posibles
Dolor (D)	<ul style="list-style-type: none"> • Si • No
Edema (E)	<ul style="list-style-type: none"> • Blando con fovea (Bf) • No
Calor local (CL)	<ul style="list-style-type: none"> • Si • No
Color piel (CP)	<ul style="list-style-type: none"> • Cianosis (Ci) • Eritema (Eri) • No
Circulación colateral (CC)	<ul style="list-style-type: none"> • Dilatación venosa (Dv) • No
Cordón venoso palpable (CVP)	<ul style="list-style-type: none"> • Inflamado (In) • No
Signo de Homans (SH)	<ul style="list-style-type: none"> • Si • No

Continúa...

Antecedentes (A)	<ul style="list-style-type: none"> • Cáncer (Ca) • Cirugía pelvis (Cp) • Ninguno de los anteriores (Na)
Dímero C (D)	<ul style="list-style-type: none"> • Positivo (Pos) • Negativo (Neg)
Ecografía (E)	<ul style="list-style-type: none"> • Positivo (Pos) • Negativo (Neg)
Repetir ecografía (RE)	<ul style="list-style-type: none"> • Positivo (Pos) • Negativo (Neg)
Probabilidad (P)	<ul style="list-style-type: none"> • Baja/Moderada (PBM) • Alta (PA)
Diagnóstico (D)	<ul style="list-style-type: none"> • Tratamiento • TVP excluida

Tabla 1. Variables identificadas y valores que pueden asumir

Luego, la red fue implementada usando el software Elvira (<http://www.ia.uned.es/~elvira/instalar/>), resultando la red que muestra la Figura 2. Esto implicó crear con el software el grafo mostrado en la Figura 1, definir los valores posibles en cada caso (Tabla 1), y también crear y cargar las tablas de probabilidad condicionales (Tablas 2 y 3). Al finalizar estas actividades la red bayesiana quedó en condiciones de ser utilizada para efectuar el testeo de su correcto funcionamiento.

4. Experimentación y análisis de resultados

Para testear la red construida se decidió comparar el diagnóstico efectuado por la red para 60 pacientes reales, con el realizado para esos mismos casos por dos médicos especialistas en TVP. El desempeño de la red se evaluó adaptando las métricas *Precision* y *Recall* utilizadas en los sistemas adaptativos de recuperación y de filtrado de información (Gena, 2005), donde *Precision* es el ratio entre los contenidos relevantes para el usuario y los presentados a él, y *Recall* es el ratio entre los contenidos relevantes para el usuario y el total de contenidos disponibles. Matemáticamente estas métricas se definen como: $Precision = TP/TP+FP$ y $Recall = TP/TP+FN$; siendo TP el número de contenidos relevantes propuestos al usuario; FP los contenidos propuestos al usuario pero que no le resultaron interesantes; y FN los contenidos no sugeridos al usuario pero que probablemente habrían sido de su agrado. Por lo expuesto, se conoce a TP como cantidad de verdaderos positivos, a FP como cantidad de falsos positivos y a FN como cantidad de falsos negativos (Gena, 2005).

Evidencias: DO, E, CL, CP, CVP, SH, A	P(P=PBM)	P(P=PA)
DO=S, E=Bf, CL=S, CP=Ci, CC=Dv, CVP=In, SH=S, A=Ca	0	1
DO=S, E=Bf, CL=S, CP=Ci, CC=Dv, CVP=In, SH=S, A=Cp	0	1
DO=S, E=Bf, CL=S, CP=Ci, CC=Dv, CVP=In, SH=S, A=Na	0	1
DO=S, E=Bf, CL=S, CP=Ci, CC=Dv, CVP=In, SH=N, A=Ca	0	1
DO=S, E=Bf, CL=S, CP=Ci, CC=Dv, CVP=In, SH=N, A=Cp	0	1
DO=S, E=Bf, CL=S, CP=Ci, CC=Dv, CVP=In, SH=N, A=Na	0	1
DO=S, E=Bf, CL=S, CP=Ci, CC=Dv, CVP=N, SH=S, A=Ca	0	1
DO=S, E=Bf, CL=S, CP=Ci, CC=Dv, CVP=N, SH=S, A=CP	0	1
DO=S, E=Bf, CL=S, CP=Ci, CC=Dv, CVP=N, SH=S, A=Na	0	1
DO=S, E=Bf, CL=S, CP=Ci, CC=Dv, CVP=N, SH=N, A=Ca	0	1
DO=S, E=Bf, CL=S, CP=Ci, CC=Dv, CVP=N, SH=N, A=CP	0	1

Tabla 2. Algunas probabilidades condicionadas para el nodo Probabilidad (P)

Evidencias: P, D, ECO, RE	P(D=TVP excluida)	P(D=Tratamiento)
P=PA, DC=Pos, ECO=Pos, RE=Pos	0	1
P=PA, DC=Pos, ECO=Pos, RE=Neg	0	1
P=PA, DC=Pos, ECO=Neg, RE=Pos ¹	0	1
P=PA, DC=Pos, ECO=Neg, RE=Neg	1	0
P=PA, DC=Neg, ECO=Pos, RE=Pos	0	1
P=PA, DC=Neg, ECO=Pos, RE=Neg	0	1
P=PA, DC=Neg, ECO=Neg, RE=Pos	1	0
P=PA, DC=Neg, ECO=Neg, RE=Neg	1	0
P=PBM, DC=Pos, ECO=Pos, RE=Pos	0	1
P=PBM, DC=Pos, ECO=Pos, RE=Neg	0	1
P=PBM, DC=Pos, ECO=Neg, RE=Pos	1	0
P=PBM, DC=Pos, ECO=Neg, RE=Neg	1	0
P=PBM, DC=Neg, ECO=Pos, RE=Pos	1	0
P=PBM, DC=Neg, ECO=Pos, RE=Neg	1	0
P=PBM, DC=Neg, ECO=Neg, RE=Pos	1	0
P=PBM, DC=Neg, ECO=Neg, RE=Neg	1	0

Tabla 3. Probabilidades condicionadas para el nodo Diagnóstico (D)

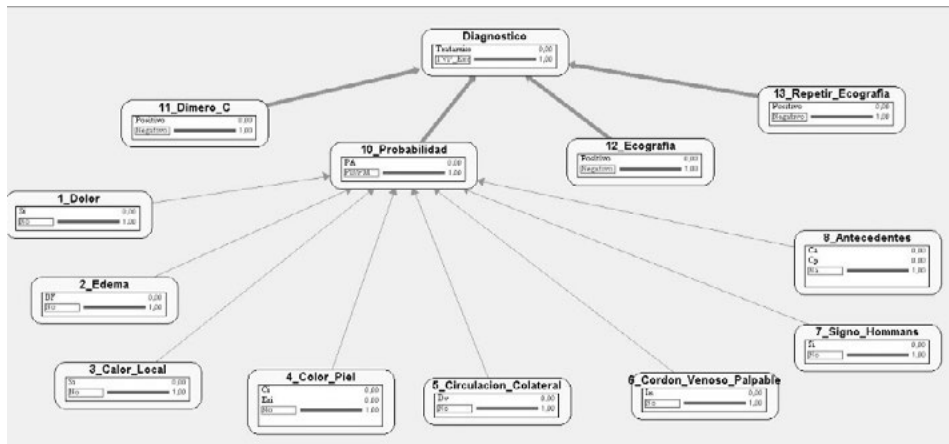


Figura 2. Red bayesiana implementada con Elvira

En este caso, para aplicar las métricas, se consideraron a TP como la cantidad de diagnósticos verdaderamente correctos (coincidencia entre el diagnóstico de la red y el brindado por los médicos), a FP como la cantidad de diagnósticos de TVP erróneos (cuando la red reconoció TVP y los médicos no), y como FN a los casos en los que la red no detectó la TVP y los médicos la diagnosticaron. Las métricas calculadas se muestran en Tabla 4. Por ejemplo, la tabla muestra en la segunda columna los resultados vinculados con el médico 1, quien tuvo 42 coincidencias (VP) en el diagnóstico positivo de la TVP con el realizado por la red, y 18 oportunidades en las que la red diagnóstico TVP y él no lo hizo (FP). Una lectura similar puede hacerse con los resultados relacionados con el médico 2, quien fue coincidente con la red 38 veces (VP) y no coincidente en 22 oportunidades (FP). Por otro lado, se considera importante destacar la ausencia de falsos negativos (FN=0) para los diagnósticos de ambos médicos, es decir, la inexistencia de casos donde reconocida la TVP por los médicos la red no la hubiera diagnosticado.

Métricas	Red/Médico1	Red/Médico2
TP	60	60
VP	42	38
FP	18	22
FN	0	0
Precision= TP/TP+FP	60/60+18=0,77	60/60+22=0,73
Recall= TP/TP+FN	60/60+0=1	60/60+0=1

Tabla 4. Resultados del testeo

Considerando los resultados obtenidos para ambos médicos, la red muestra un desempeño satisfactorio, con una *Precision* promedio de 0,75 y un *Recall* igual a 1.

5. Trabajos relacionados

González Cedillo (2019) contrasta la performance de algunos algoritmos de aprendizaje supervisado clasificando pacientes propensos a sufrir enfermedades cardíacas. En la experimentación se incluyeron 303 instancias de pacientes con diferentes características, 70% de esas tuplas se usaron como instancias de entrenamiento y el 30 % restante para prueba. Los resultados obtenidos sugieren que los algoritmos mencionados son los más eficientes, sobre todo para trabajos médicos.

Férez Rubio (2017) presenta una guía práctica para la construcción de redes bayesianas en medicina en el marco de su tesis de maestría en Bioinformática y Bioestadística. En su trabajo formula un amplio marco teórico sobre los conceptos y contenidos probabilísticos sobre los que se fundamentan las redes bayesianas, y también resuelve casos prácticos en el área de la medicina utilizando el software Elvira. El autor afirma que las redes bayesianas constituyen una herramienta de valor incalculable para la toma de decisiones clínicas.

Ordoñez-Ordoñez et al. (2016) presentan una red bayesiana para medicina veterinaria. Los autores desarrollaron una red que diagnostica enfermedades infecciosas virales en algunas especies caninas y felinas. La red se basa principalmente en la experiencia de los médicos, en estudios clínicos de laboratorio y registros de información sintomatológica de cada enfermedad encontrada en fuentes bibliográficas. Para crear la red los autores experimentaron con tres herramientas que cuentan con una interfaz gráfica y un modo inferencia que permite obtener resultados de acuerdo con los signos clínicos que presente cada animal. Una de esas herramientas fue el software Elvira.

Sprockel & Diaztagle (2015) desarrollaron una red bayesiana para diagnosticar síndromes coronarios agudos (SCA). Los autores crearon su red tomando la sintomatología de 159 pacientes y luego validaron la validaron con otro grupo de 108 pacientes hospitalizados con sospecha de SCA. Los autores afirman que la red presenta un rendimiento aceptable.

Salarte Martínez & Castro Bermúdez (2012) desarrollaron un modelo híbrido, que combina árboles de decisión con redes bayesianas, para el diagnóstico de enfermedades cardiovasculares complejas. Los resultados obtenidos demuestran que es adecuado determinar o no la administración de un procedimiento clínico a un paciente con enfermedad cardiovascular usando sintomatología y datos clínicos. Los autores crearon su red valiéndose del software Elvira.

Al igual que en González Cedillo (2019), Ordoñez-Ordoñez et al. (2016), Sprockel & Diaztagle (2015) y Salarte Martínez & Castro Bermúdez (2012) en

este trabajo se consideran las características o sintomatología clínica presente para inferir una conclusión aplicando razonamiento bayesiano, en particular, la predicción de la patología TVP. Al igual que en este trabajo, Férrez Rubio (2017), Ordoñez-Ordoñez et al. (2016) y Salarte Martínez & Castro Bermúdez (2012) eligieron al software Elvira debido a las facilidades que suministra para diseñar y experimentar con redes bayesianas.

6. Conclusiones

Este artículo muestra la creación y testeo de una novedosa red bayesiana para diagnóstico de Trombosis Venosa Profunda. Los resultados obtenidos demuestran que la red puede ser un recurso utilizable por el personal médico como apoyo en sus procesos de toma de decisión, para llegar a un diagnóstico precoz y oportuno.

Actualmente se está ampliando el testeo de la red mediante una aplicación a la que acceden los médicos para diagnosticar casos reales suministrados por una entidad de salud. Luego, esos casos serán procesados por la red bayesiana construida y se computarán nuevamente las métricas *Precision* y *Recall*. De obtenerse nuevamente métricas satisfactorias, se procederá a implementar las interfaces necesarias para que la red pueda ser utilizada de manera remota por profesionales de la salud.

A mediano y largo plazo se espera poder crear nuevas redes bayesianas que apoyen el quehacer médico para diagnosticar otros tipos de afecciones, como la embolia pulmonar (EP) y la trombosis cerebral (TC). Ambas afecciones presentan sintomatología que podría ser representada con variables en sendas redes bayesianas. La EP es una obstrucción en una de las arterias de los pulmones, que generalmente presenta síntomas como: falta de aire, dolor de pecho, tos, latidos del corazón rápidos o irregulares, desvanecimientos, entre otros. La TC es la pérdida de oxígeno de una región del cerebro como consecuencia de la obstrucción por un coágulo de la arteria que lo irriga. Algunos de sus síntomas son: súbita desviación de la comisura labial, habla enredada o imposibilidad para hablar, debilidad o adormecimiento de un lado del cuerpo. Con el asesoramiento de los especialistas que colaboraron en la creación y validación de la red incluida en este trabajo, será posible crear las redes bayesianas orientadas a la detección de EP y TC. Además, se cuenta con casos reales para validar sus respectivos funcionamientos.

Referencias

- Férez Rubio, J.A. (2017). *Redes Bayesianas aplicadas a la Medicina*. Trabajo Final para Master Universitario en Bioinformática y Biomedicina. España: Universidad Abierta de Catalunya. Disponible en: <http://openaccess.uoc.edu/webapps/o2/bitstream/10609/63906/6/jferezrTFM0617Mmemoria.pdf>
- Gena, C. (2005). Methods and techniques for the evaluation of user-adaptive systems. *The Knowledge Engineering Review*, 20 (1), 1-37. UK: Cambridge University Press.
- González Cedillo, C. (2019). Diagnóstico de enfermedades cardíacas con los algoritmos supervisados. *Revista Ciencia y Tecnología*, 19, 117-128. Argentina: Universidad de Palermo.
- Jensen, F. (1998). *An introduction to Bayesian Networks*. UK: UCL Press.
- Ordoñez Ordoñez, P. Guamán, Jima, D., Patiño Rivera, S. & Torres Carrión, H. (2016). Diagnóstico de enfermedades infecciosas virales en especies canina y felina utilizando redes bayesianas. *Proc. Del Cong. Int. de Sistemas Inteligentes y Nuevas Tecnologías*. Disponible en: https://www.researchgate.net/publication/313477263_Diagnostico_de_enfermedades_infecciosas_virales_en_especies_canina_y_felina_utilizando_redes_bayesianas
- Pearl, J. (1988). *Probabilistic reasoning in intelligent systems: networks of plausible inference*. USA: Morgan Kaufmann Publishers Inc.
- Salarte Martínez, G. & Castro Bermúdez, Y. (2012). Modelo híbrido para el diagnóstico de enfermedades cardiovasculares basado en inteligencia artificial. *Tecnura*, 16 (33), 35-52. Colombia: Universidad Distrital Francisco José de Caldas.
- Sandoyal, E. (2014). La incertidumbre en Medicina. *Tendencias en Medicina*, 44, 131-138. Uruguay: Farmanuario.
- Sprockel, J. & Diaztagle, J. (2015). Precisión diagnóstica de un modelo de redes bayesianas en los síndrome coronarios agudos. *Revista Salud*, 47(2), 179-185. Colombia: Universidad Industrial de Santander.

