

CARDIOLOGÍA DEL ADULTO – ARTÍCULO ORIGINAL

Redes neuronales en el diagnóstico del infarto agudo de miocardio



John J. Sprockel^{a,*}, Juan J. Diaztagle^b, Wilson Alzate^c y Enrique González^d

^a Medicina Interna, Candidatura a Maestría en Ingeniería de Sistemas y Computación, Pontificia Universidad Javeriana. Medicina Interna, Fundación Universitaria de Ciencias de la Salud-Hospital de San José, Bogotá, DC, Colombia

^b Medicina Interna, Epidemiología. Maestría en Fisiología. Medicina Interna, Fundación Universitaria de Ciencias de la Salud-Hospital de San José. Departamento de Ciencias Fisiológicas, Universidad Nacional de Colombia, Bogotá, DC, Colombia

^c Ingeniería de Sistemas. Candidatura a Maestría en Ingeniería de Sistemas y Computación, Pontificia Universidad Javeriana, Bogotá, DC, Colombia

^d Ingeniería eléctrica. Maestría en Ingeniería Eléctrica, Universidad de los Andes, DEA Robotique Université de Paris VI (Pierre et Marie Curie), Doctorat en Informatique Université d'Evry Val d'Essonne, Postdoctorado Université d'Evry Val d'Essonne. Maestría en Ingeniería de Sistemas y Computación, Pontificia Universidad Javeriana, Bogotá, DC, Colombia

Recibido el 30 de julio de 2013; aceptado el 28 de octubre de 2013

Disponible en Internet el 2 de septiembre de 2014

PALABRAS CLAVE

Dolor torácico;
Enfermedad coronaria;
Infarto agudo de miocardio;
Electrocardiograma

Resumen

Introducción: El infarto agudo de miocardio representa la primera causa de muerte no transmisible en el mundo. Una de las herramientas que sirven como soporte a las decisiones en su diagnóstico son las redes neuronales, de las cuales se ha demostrado un buen nivel de precisión. **Métodos:** Se realizó el entrenamiento y la prueba de varias redes neuronales, con diferentes arquitecturas para el diagnóstico del infarto, a partir de los datos de la escala de clasificación de la probabilidad de angina de Braunwald en un grupo de pacientes que ingresaron por dolor torácico al servicio de urgencias del Hospital San José de Bogotá.

Resultados: Se generaron 40 redes que fueron probadas en 5 experimentos de los cuales se obtuvo mayor precisión diagnóstica con el modelo de 5 entradas electrocardiográficas más troponina, aunque el mejor valor predictivo negativo se alcanzó en el modelo con 10 variables clínicas, electrocardiográficas y troponina. Varias de las redes diseñadas tuvieron una sensibilidad y una especificidad del 100%. Se requiere un estudio de validación para comprobar estos hallazgos.

* Autor para correspondencia.

Correo electrónico: jjsprockel@fucsalud.edu.co (J.J. Sprockel).

Conclusiones: Con los resultados encontrados para las redes neuronales en la literatura y en este estudio se puede considerar el uso de esta estrategia de inteligencia computacional en la práctica.

© 2013 Sociedad Colombiana de Cardiología y Cirugía Cardiovascular. Publicado por Elsevier España, S.L.U. Todos los derechos reservados.

KEYWORDS

Chest pain;
Coronary disease;
Myocardial acute
infarction;
Electrocardiogram

Neural networks for the diagnosis of acute myocardial infarction

Abstract

Introduction: Myocardial infarction represents the leading cause of death by a noncommunicable disease worldwide; one of the tools that serve as decision support for establishing a diagnosis are neural networks. They have been shown to have a good level of accuracy.

Methods: Training and testing of several neural networks was performed with different architectures for the diagnosis of the myocardial infarction in a group of patients admitted with chest pain emergency room in the Hospital de San José, Bogotá. This was carried out according to data from the incidence scale of Braunwald's classification of unstable angina.

Results: Forty networks were generated and tested in five experiments obtaining an accurate diagnostic with the electrocardiographic pattern of five entries and troponin. The negative predictive value was 100% in the model with ten clinical variables, electrocardiogram and troponin. Some of the designed networks had a sensitivity and specificity of 100%. A validation study to verify these findings is required.

Conclusions: With the results found for neural networks in the literature and in the present study, we should consider the practical use of this computational intelligence strategy in daily practice.

© 2013 Sociedad Colombiana de Cardiología y Cirugía Cardiovascular. Published by Elsevier España, S.L.U. All rights reserved.

Introducción

El infarto agudo de miocardio (IAM) es una de las condiciones que se manifiestan con dolor torácico y ponen en riesgo la vida; de ahí que su diagnóstico apropiado y oportuno determine la instauración de una serie de medidas que pueden cambiar su historia natural.

Gran parte de los esfuerzos diagnósticos para dolor torácico en el servicio de urgencias se encaminan a esta entidad, teniendo en cuenta que sus síntomas son variables y los pacientes los perciben de maneras muy diferentes¹.

Una condición particular en la práctica clínica son los errores en el proceso de atención médica², motivo por el cual se ha hecho prioritaria la búsqueda de medidas para controlar esta situación. El diagnóstico y el tratamiento de la isquemia coronaria no escapan a ello^{3,4}. Ante este hecho y con la necesidad consiguiente de contar con un mayor sustento del conocimiento en la práctica diaria, junto con el ambiente propiciado por el uso de nuevas tecnologías, se ha intentado dar un estímulo para la generación y la utilización de sistemas de soporte en la toma de decisiones clínicas encaminados a esta condición⁵. Uno de estos son las redes neuronales.

De acuerdo con la *Computational Intelligence Society del Institute of Electrical and Electronics Engineers (IEEE)*, las redes neuronales son paradigmas computacionales basados en modelos matemáticos con capacidad de un fuerte patrón de reconocimiento. Una red neuronal es un algoritmo de cálculo que se basa en una analogía del sistema nervioso⁶. Se




Figura 1 Ejemplo de una red neuronal con 5 neuronas (variables) de entrada, 2 neuronas en la capa oculta y una neurona de salida.

intenta imitar la capacidad de aprendizaje de este, haciendo que reconozca gradualmente patrones de asociación entre las entradas (variables predictivas) y los estados dependientes de ellas (salidas)^{7,8}. La señal progresa desde las entradas, luego por la capa oculta, hasta obtener una respuesta traducida en el nivel de activación de los nodos de salida, los cuales predicen el resultado con base en las variables de entrada⁷. En la [figura 1](#) se ejemplifica una red neuronal con 5 neuronas de entrada, 2 neuronas en la capa oculta y una neurona de salida, aplicada al diagnóstico del infarto.

De otro lado, se han publicado gran cantidad de estudios que utilizan redes neuronales, con diferentes aproximaciones para apoyar el diagnóstico de los síndromes coronarios agudos⁹⁻²³. En el artículo que se publica en este número

se efectúa una descripción del desempeño de varias redes neuronales en el diagnóstico del IAM, a partir de los datos obtenidos de las 18 variables de la escala de valoración de la probabilidad de angina descrita por Braunwald et al.²⁴ en 1994, aplicada a una población de pacientes que consultaron por dolor torácico al hospital San José de Bogotá.

Metodología

Base de datos

Se tomó la base de datos de una población compuesta por pacientes mayores de 18 años que consultaron al servicio de urgencias del Hospital San José por dolor torácico como motivo de consulta principal, entre el 20 febrero y el 30 de octubre de 2012. Esta base de datos hacía parte del estudio «Estructuración e implementación de una ruta crítica para el manejo de pacientes con síndrome coronario agudo en el servicio de urgencias del hospital San José de Bogotá». El muestreo de los casos elegidos de la base de datos se realizó por conveniencia, a partir de aquellos en que se diligenció correctamente la ruta crítica; estuvo compuesta por 159 pacientes, de los cuales 37 tuvieron diagnóstico de IAM.

Descripción de la red neuronal

Se usó NEUROSOLUTIONS®, un ambiente de desarrollo de redes neuronales creado por NeuroDimension Inc., el cual se comercializa bajo licencia EULA (*End-user license agreement*). Se diseñó un grupo de experimentos consistentes en distintas variaciones de la estructura de redes neuronales, que tenían en común una capa oculta, una neurona de salida, la tasa de aprendizaje y el uso de *back propagation* con *momentum* (el algoritmo que permite el entrenamiento de la red). Se varió el número de neuronas (variables) de entrada, escogidas a partir de diferentes criterios o heurísticas:

- Cinco neuronas: provenientes de los datos del ECG consignados en la escala de Braunwald.
- Seis neuronas: la anterior más el resultado de la tropoina.
- Diez neuronas: las que se presentaban con mayor frecuencia entre quienes se diagnosticó un infarto.
- Dieciocho neuronas: todos los componentes de la escala de Braunwald.

Los otros aspectos que se variaron fueron el número de neuronas en la capa oculta (2, 3, 4, 6 y 10) y el *momentum* escogido (0,3 y 0,5). Cada una de las redes fue probada en 5 experimentos. De cada uno de ellos se construyó una tabla de 2×2 calculando, a partir de estos resultados, sensibilidad, especificidad, valores predictivos y precisión. Se obtuvieron los promedios y su respectiva desviación estándar para graficar finalmente los resultados obtenidos.

El estudio fue aprobado por el comité de investigaciones y el comité de ética en investigación con seres humanos de la Facultad de Medicina de la Fundación Universitaria Ciencias de la Salud, Hospital San José de Bogotá. No se requirió la obtención de un consentimiento informado.

Resultados

Se diseñaron 40 redes neuronales, las cuales fueron entrenadas y probadas, cada una en 5 experimentos. Se obtuvieron los datos de sensibilidad, especificidad, precisión, así como valores predictivos positivo y negativo, los cuales se exponen en la [tabla 1](#) con sus respectivos promedios y desviaciones estándar (DE).

Puede notarse escasa variación en el desempeño de cada red a través de cada uno de los experimentos de entrenamiento efectuado (pequeña desviación estándar). El modelo de 5 datos electrocardiográficos fue el que tuvo menor capacidad de clasificar el diagnóstico del infarto.

El modelo de 6 neuronas de entrada tuvo el mejor rendimiento diagnóstico, de manera consistente entre las diferentes arquitecturas exploradas. En la [figura 2](#) se observa que con la adición de variables clínicas y antecedentes (10 y 18 variables de entrada) no se mejoró el desempeño global, aunque la red que obtuvo los mejores resultados en las pruebas fue la de 10 variables con 2 neuronas en la capa oculta y *momentum* de 0,5 (que tuvo 2 de 5 experimentos con el 100% de precisión).

En la mayor parte de los casos las redes tuvieron alta sensibilidad, con grados variables de especificidad. Los modelos con el número más grande de entradas tuvieron mejor desempeño al aumentar el número de neuronas en la capa oculta, aunque el número más alto de neuronas no aportó mejor capacidad de discriminación.

Discusión

El proceso de elaboración de una red neuronal es, en su mayoría, un trabajo de ensayo y error (según algunas apreciaciones «artesanal») e implica realizar el mayor número de pruebas con diferentes arquitecturas⁶. En la [tabla 2](#) se resumen 15 artículos representativos relacionados con la evaluación de las redes neuronales en el diagnóstico del IAM; se observan diferentes maneras de abordar el problema, muchas basadas en el ECG y otras en datos clínicos y de laboratorio. En la mayoría de casos se obtuvieron arquitecturas muy similares, con una sola capa oculta y 2 posibles resultados de salida. En este estudio se presenta un conjunto de experimentos siguiendo lo aprendido en la revisión realizada, considerando distintos grupos de datos de entrada, solo desde el ECG hasta la totalidad de los componentes de la escala de Braunwald y sometiendo a variación el número de neuronas de la capa oculta y el *momentum* durante el entrenamiento.

Los hallazgos del estudio demuestran que no es posible basarse únicamente en los datos del ECG para el diseño de una red neuronal para el diagnóstico del infarto. Si bien su especificidad es aceptable (cercana al 89%), se correlaciona con baja especificidad. Así mismo, se debe tener en cuenta que la escala de clasificación de la probabilidad de Braunwald no incluye todas las variaciones de hallazgos electrocardiográficos de los síndromes coronarios agudos e infarto (por ejemplo, el bloqueo de rama izquierdo nuevo o los criterios de Sgarbosa), con lo que se podría llegar a mejorar el rendimiento de una red neuronal que los incorpore. En todo caso, se sabe que un ECG normal no descarta infarto; entre el 1 y el 6% finalmente lo tiene²⁵. Por otro lado, es

Tabla 1 Resultados de los diferentes experimentos de diseño de las redes neuronales

Entradas	Capa oculta	Momentum	Sensibilidad (media)	Sensibilidad (DE)	Especificidad (media)	Especificidad (DE)	VPP (media)	VPP (DE)	VPN (media)	VPN (DE)	Precisión (media)	Precisión (DE)
5	2	0,50	88,00	0,00	28,57	0,00	55,20	0,00	70,42	0,00	58,29	0,00
5	2	0,30	88,00	0,00	28,57	0,00	55,20	0,00	70,42	0,00	58,29	0,00
5	3	0,50	88,00	0,00	28,57	0,00	55,20	0,00	70,42	0,00	58,29	0,00
5	3	0,30	88,80	1,79	28,57	0,00	55,42	0,49	71,96	3,44	58,69	0,89
5	4	0,50	88,00	0,00	28,57	0,00	55,20	0,00	70,42	0,00	58,29	0,00
5	4	0,30	88,00	0,00	28,57	0,00	55,20	0,00	70,42	0,00	58,29	0,00
5	6	0,50	88,80	1,79	28,57	0,00	55,42	0,49	71,96	3,44	58,69	0,89
5	6	0,30	88,00	0,00	28,57	0,00	55,20	0,00	70,42	0,00	58,29	0,00
5	10	0,50	88,00	0,00	28,57	0,00	55,20	0,00	70,42	0,00	58,29	0,00
5	10	0,30	88,00	0,00	28,57	0,00	55,20	0,00	70,42	0,00	58,29	0,00
6	2	0,50	90,40	2,19	85,71	0,00	86,35	0,29	89,97	2,05	88,06	1,10
6	3	0,50	89,60	2,19	85,71	0,00	86,24	0,29	89,22	2,05	87,66	1,10
6	4	0,50	88,00	4,90	85,71	0,00	86,00	0,70	87,89	4,24	86,86	2,45
6	6	0,50	88,80	1,79	85,71	0,00	86,14	0,24	88,47	1,67	87,26	0,89
6	10	0,50	91,20	1,79	85,71	0,00	86,45	0,24	90,71	1,67	88,46	0,89
6	2	0,30	88,80	1,79	85,71	0,00	86,14	0,24	88,47	0,89	87,26	0,89
6	3	0,30	88,80	1,79	85,71	0,00	86,14	0,24	88,47	1,67	87,26	0,89
6	4	0,30	89,60	2,19	85,71	0,00	86,24	0,29	89,22	2,05	87,66	1,10
6	6	0,30	90,82	2,72	88,57	6,39	89,24	6,03	90,68	2,22	89,70	2,65
6	10	0,30	90,40	6,07	85,71	0,00	86,31	0,85	90,20	5,40	88,06	3,03
10	2	0,50	100,00	0,00	77,14	25,95	84,23	16,84	100,00	0,00	88,57	12,98
10	3	0,50	100,00	0,00	51,43	12,77	67,73	6,25	100,00	0,00	75,71	6,38
10	4	0,50	100,00	0,00	51,43	7,82	67,45	3,48	100,00	0,00	75,71	3,91
10	6	0,50	100,00	0,00	60,00	30,97	74,44	17,28	100,00	0,00	80,00	15,49
10	10	0,50	98,40	3,58	45,71	29,28	66,23	12,68	92,82	16,06	72,06	15,78
10	2	0,30	100,00	0,00	54,28	6,39	68,73	2,84	100,00	0,00	77,14	3,19
10	3	0,30	98,40	3,58	74,28	23,48	82,00	16,43	98,52	3,31	86,34	10,74
10	4	0,30	100,00	0,00	57,14	17,49	70,95	9,78	100,00	0,00	78,57	8,75
10	6	0,30	100,00	0,00	54,29	11,95	69,01	5,84	100,00	0,00	77,14	5,98
10	10	0,30	99,20	1,79	51,43	7,82	67,28	3,34	98,69	2,93	75,31	3,64
18	2	0,50	100,00	0,00	60,00	6,40	71,56	3,49	100,00	0,00	80,00	3,20
18	3	0,50	98,40	3,58	54,28	6,39	68,34	3,72	96,85	7,04	76,34	4,98
18	4	0,50	100,00	0,00	60,00	6,40	71,56	3,49	100,00	0,00	80,00	3,20
18	6	0,50	99,20	1,79	68,57	6,39	76,08	3,41	98,94	2,37	83,89	3,10
18	10	0,50	100,00	0,00	68,57	15,65	77,00	9,58	100,00	0,00	84,28	7,82
18	2	0,30	100,00	0,00	60,00	6,39	71,55	3,48	100,00	0,00	80,00	3,20
18	3	0,30	98,40	3,58	60,00	6,39	71,20	3,76	97,54	5,49	79,20	4,03
18	4	0,30	100,00	0,00	60,41	6,23	70,28	5,01	100,00	0,00	79,52	3,61
18	6	0,30	98,40	2,19	57,14	14,29	70,20	7,34	96,98	4,19	77,77	7,70
18	10	0,30	100,00	0,00	54,28	6,39	68,73	2,84	100,00	0,00	77,14	3,19

VPP: valor predictivo positivo; VPN: valor predictivo negativo.

Tabla 2 Redes neuronales en el diagnóstico de infarto

Autor, año	Estrategia	Pacientes	Resultados	Comentarios
Baxt, 1991 ^{9,a}	ANN para diagnóstico de infarto. Veinte entradas, 2 capas ocultas de 10 neuronas	356 pacientes (178 entrenamientos y 178 pruebas), retrospectivo	Sensibilidad: 97,2% Especificidad: 96,2% (sensibilidad: 92% y especificidad: 96% en las pruebas)	Comprueban la utilidad de una ANN previamente creada y la comparan con el concepto de los médicos
Baxt, 1996 ^{10,a}	ANN para diagnóstico de infarto. Veinte entradas, 2 capas ocultas de 10 neuronas (la misma)	1.071 pacientes de urgencias por dolor torácico con sospecha de IAM	Sensibilidad: 96% Especificidad: 96%	Unicéntrico
Ellenius, 1997 ^{11,b}	ANN tipo SLP con algoritmo BP, para diagnóstico de infarto. Usaron fuzzificación para medir el tamaño del infarto	88 pacientes (50 entrenamientos y 38 pruebas) pertenecientes al estudio BIOMACS	Sensibilidad: 100% Especificidad: 93% VPP: 85% VPN: 100%	Se tuvieron en cuenta diferentes arquitecturas de las ANN Favoreció a los médicos, pero en diagnóstico fue más temprano
Hedén, 1997 ^{12,a}	ANN tipo MLP usando la variación de Langevin de BP, para diagnóstico de infarto con base en el ECG Capa de entrada 72, y una capa oculta de 15 neuronas	1.120 ECG de pacientes en unidad de dolor torácico 10.452 ECG de control	La ANN mostró mayor sensibilidad que la de los criterios basados en reglas convencionales y que los cardiológicos Especificidad: 95,2%	Comparado con los cardiológicos
Ohno-Machado, 1998 ^{13,b}	Se construyeron 100 ANN con 100 diferentes grupos de entrenamiento removiendo datos progresivamente y se compararon con la que tenían todos los datos. Todas con 40 entradas, 30 en capa oculta y una salida	700 pacientes para entrenamiento, 553 pacientes con pruebas con sospecha de infarto y 500 pacientes para validación	La remoción de datos no afecta el rendimiento de la ANN hasta un umbral del 40%	Evaluó la remoción de las observaciones redundantes para la reducción del tiempo de entrenamiento
Cházaro, 1998 ^{14,b}	ANN usando BP, para diagnóstico de infarto. 95 variables, una capa oculta y 2 salidas; se eligió la mejor configuración entre 5 y 20 nodos ocultos	563 pacientes (422 entrenamiento y 141 pruebas). 104 con datos faltantes. 53 con infarto y 369 sin infarto	Sensibilidad: 85% Especificidad: 91% (ANN de 20 nodos) (Md: 87 y 78% y RL: 81 y 86%)	Comparó con RL y los médicos de urgencias
Ellenius, 2000a ^{15,a}	ANN de múltiples tipos (9 en total), centrados en mioglobina, troponina y tiempo de los síntomas	Pacientes con sospecha de infarto y ECG no conclusivo	Sensibilidad: 77-95% Especificidad: 88-96% Los mejores fueron tres: MSLP y FSLP	Evaluó el desempeño de diferentes estructuras de ANN
Ellenius, 2000b ^{16,a}	ANN tipo MSLP para diagnóstico de infarto, análisis de Monte Carlo para verificar la evolución respecto a los biomarcadores (series de tiempo)	Pacientes de los estudios IMACS y FAST, 167 en total con SCA y 790 sin SCA	Inició en la población A: Sensibilidad: 93% Especificidad: 92% Encuentran una función de corrección para ajustar los resultados a otra institución	Evaluó la posibilidad de transferir los resultados obtenidos en un grupo de pacientes a otro distinto

Tabla 2 (continuación)

Autor, año	Estrategia	Pacientes	Resultados	Comentarios
Baxt, 2002 ^{17,a}	ANN <i>feed-forward</i> usando BP, para diagnóstico de infarto, técnica de varianza de Jackknife	Entrenamiento: 50 pacientes con IAM, 1.000 sin IAM Pruebas: 28 pacientes con IAM, 200 sin IAM 2.204 pacientes evaluación prospectiva	Sensibilidad: 94,5% Especificidad: 95,9% (RL: 77,3 y 75%)	Comparado vs. regresión logística La ANN funciona bien pese a un 5% de datos perdidos Estudio de costos
Hollander, 2004 ^{18,a}	Dos ANN para diagnóstico de infarto y de SCA, con 40 variables	Antes: 4.492 pacientes Después: 432 pacientes	IAM: Sensibilidad: 95% Especificidad: 96% SCA: Sensibilidad: 88% Especificidad: 88%) No afectó la decisión del ingreso de pacientes	No evaluó el rendimiento de la ANN Uso en tiempo real De antes y después Evaluó la apreciación de los médicos
Harrison, 2005 ^{19,b}	ANN para diagnóstico de infarto, usando 13 variables (fue la mejor entre 8, 13, 20 y 40 variables evaluadas). No la describen muy bien	Entrenamiento: 1.253 pacientes (hospital 1). Pruebas 1.904 pacientes (de otros 2 hospitales)	Sensibilidad: 93% Especificidad: 93% VPP: 88% VPN: 96%	Participaron 3 hospitales No incorporaron biomarcadores Datos ingresados por enfermeras Comparó con clasificadores bayesianos
Bigi, 2005 ^{20,a}	ANN para pronóstico del infarto no complicado. Multicapa <i>feedforward</i> con BP. 5-40 neuronas, MACE a 200 días	496 pacientes en recuperación de un infarto	Precisión: 70% Sensibilidad: 38% Especificidad: 83%	Comparó con clasificadores bayesianos
Bulgiba, 2006 ^{21,b}	200 ANN tipo MLP probaron 2, 4, 8, 16, 32 y 64 neuronas en la capa oculta, con modelos de 9, 11, 23, 64 y 94 entradas. Dos algoritmos: gradiente descendente y Fletcher-Reeves	710 pacientes	La mejor ANN tuvo un área bajo la curva ROC de 0,79 con 9 entradas, igual que la regresión logística con 64 variables	Comparado con regresión logística
Eggers, 2007 ^{22,a}	Tres ANN: 2 para diagnóstico: un MLP con 2 capas ocultas y un SLP, y una para medir el tamaño del infarto: SLP	310 pacientes con dolor torácico	Sensibilidad: 86, 96, 94% Especificidad: 86, 94, 89% VPP: 85, 92, 85% VPN: 100, 99, 100%	Buscó aumentar la velocidad del diagnóstico del IAM en 3 centros diferentes
Al-Naima, 2008 ^{23,b}	ANN supervisada con algoritmo BP con 2 capas ocultas, para la interpretación de ondas del ECG en diagnóstico de infarto	43 ECG de pacientes sanos y con infarto	FT-ANN: precisión: 85%, sensibilidad: 80% WT-ANN: precisión: 90%, sensibilidad: 90%	Comparó 2 sistemas de procesamiento de señales: TF y WT

ANN: red neuronal artificial; BP: *back propagation*; CV: cardiovascular; ECG: electrocardiograma; IAM: infarto agudo de miocardio; MACE: eventos cardiovasculares mayores; MLP: perceptrón de múltiples capas; MSLP: múltiples perceptrones de una sola capa; RL: regresión logística; SLP: perceptrón de una sola capa; TF: transformada de Fourier; VPN: valor predictivo negativo; VPP: valor predictivo positivo; WT: transformada de ondas discretas.

^a Procedente de revista de Medicina.

^b Procedente de revista de Ingeniería.

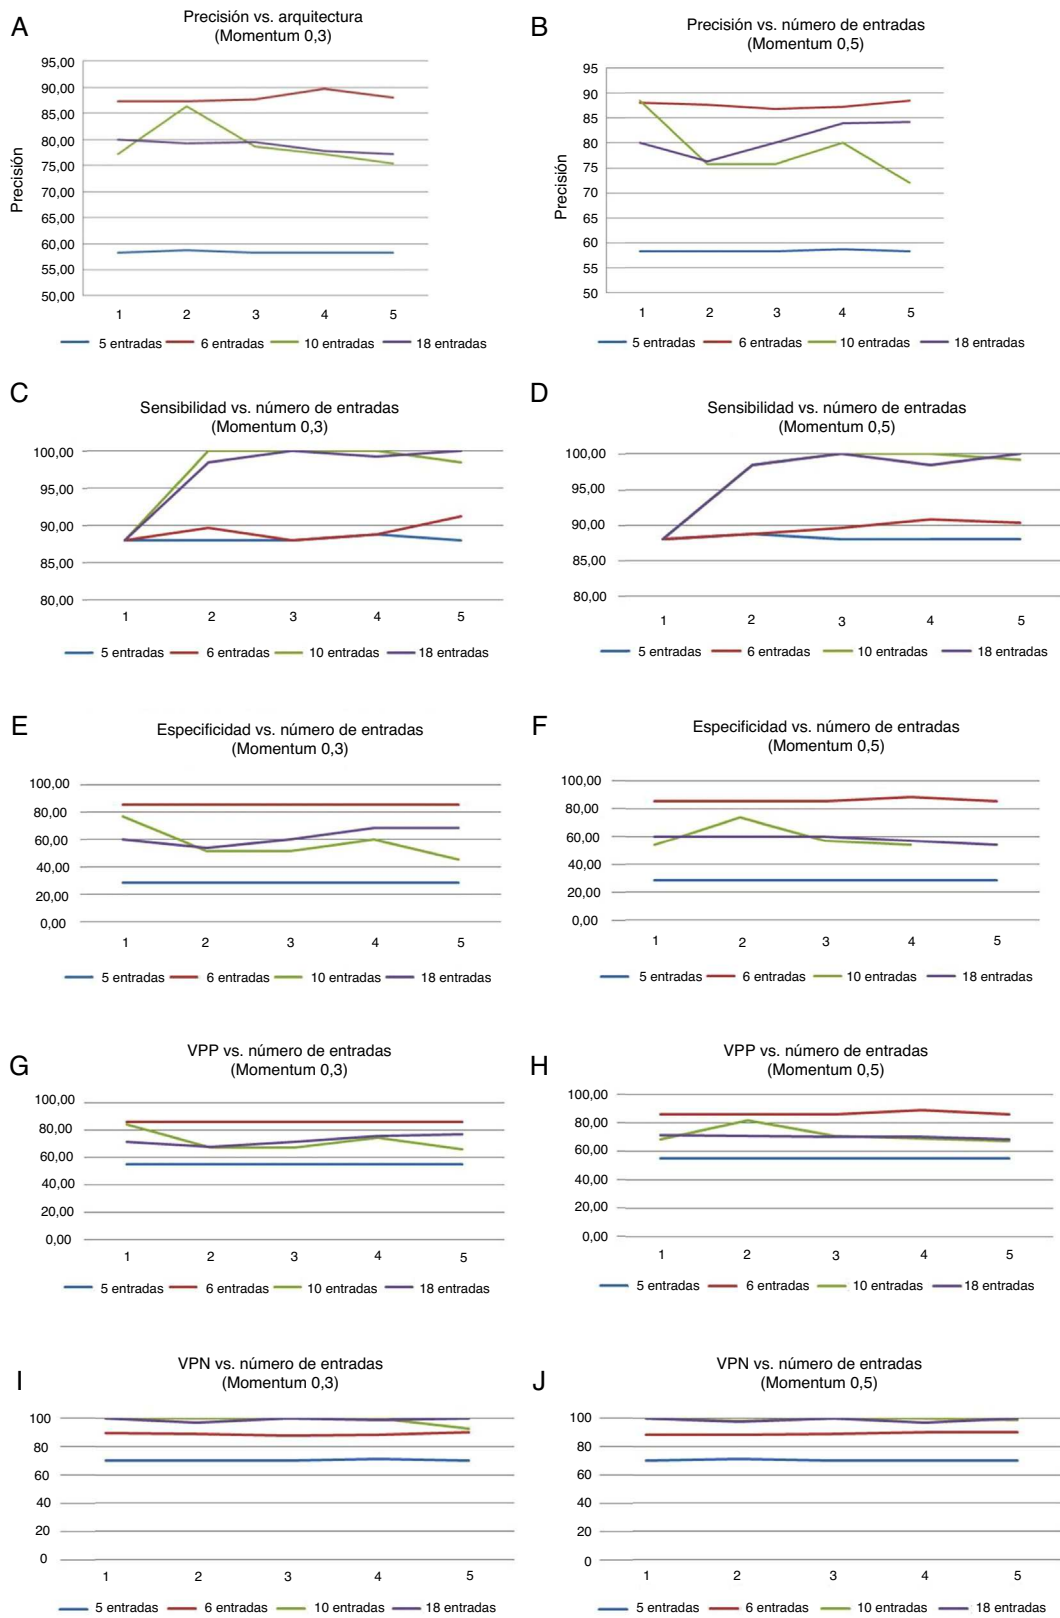


Figura 2 Desempeño de las redes neuronales diseñadas de acuerdo con el número de entradas consideradas y el número de neuronas en la capa oculta.

VPP: valor predictivo positivo; VPN: valor predictivo negativo.

*En las abscisas se plasman el número de neuronas en la capa oculta así: 1) dos, 2) tres, 3) cuatro, 4) seis, y 5) diez neuronas.

frecuente que se encuentren alteraciones inespecíficas del segmento ST y de la onda T, que dificultan la toma de decisiones en este contexto. Algunos reportes indican que pueden diagnosticarse erróneamente solo con base en el ECG hasta en el 12% de los casos²⁶.

La adición de troponina a los hallazgos electrocardiográficos incrementa la sensibilidad diagnóstica del infarto hasta en el 90%²⁵; las redes neuronales entrenadas con estos criterios demostraron rendimientos superiores. La adición de criterios clínicos basados en edad, género, historia del dolor y antecedentes no mejoraron la sensibilidad ni la especificidad, si bien se encontró ganancia en el valor predictivo negativo.

Los resultados muestran que las variables de la escala de probabilidad de Braunwald para el diagnóstico del infarto tienen un rendimiento adecuado para la clasificación diagnóstica al utilizarse como valores de entrada de una red neuronal. Tras un amplio número de experimentos realizados se alcanzó una topología apropiada creando una red neuronal con una excelente precisión diagnóstica del infarto. Estos resultados deben confirmarse mediante un ensayo clínico, preferiblemente multicéntrico, que efectúe la validación cruzada de esta herramienta y dé pistas a cerca de su comportamiento en el momento de la valoración del paciente en urgencias. Es conveniente tener en cuenta que la red con mejor rendimiento se encontró en el modelo de 10 neuronas de entrada, que sería la escogida para dicho propósito.

El rendimiento diagnóstico de las redes neuronales desarrolladas fue similar al de las redes encontradas en la revisión bibliográfica. El grupo del doctor Baxt ha sido el que más ha evaluado esta técnica en el diagnóstico del infarto^{9,10,17,18}; de hecho, fueron los primeros en publicar sus resultados en 1991: comenzaron con 20 neuronas de entrada con 2 capas ocultas cada una de 10 neuronas, hasta 40 neuronas de entrada en 2004; hasta el momento esta última ha sido la única empleada en tiempo real con un buen desempeño (sensibilidad y especificidad del 88%). Con la disminución del número de neuronas de entrada no se alteraba la precisión diagnóstica, como lo demuestran los trabajos de Harrison¹⁹ y Bulgiba²¹. Tampoco hubo diferencias entre las arquitecturas que tenían una o 2 capas ocultas, hecho conocido ya por los expertos en el tema.

Pese a la extensa cantidad de estudios que demuestran la capacidad para clasificar de forma acertada los IAM generados durante los últimos 20 años, su uso no se ha extendido como se esperaba y, a excepción de las estrategias para la interpretación de las señales electrocardiográficas, existen muy pocos sistemas de soporte a las decisiones clínicas que estén en uso. Se ha propuesto que por tratarse de una caja negra, en la que se carece de una explicación de cómo se llega a tomar una decisión²⁷, los médicos se resisten a seguir sus recomendaciones, independiente de su éxito real o potencial²⁸.

Son posibles limitaciones de este trabajo el muestreo por conveniencia y la probabilidad de una falta de representación de otras entidades que se manifiesten con dolor torácico, lo que podría implicar un sesgo de selección. Se requiere la validación cruzada de los resultados y evaluar su funcionamiento en tiempo real. El número de ejemplos parece ser adecuado, ya que es posible lograr un entrenamiento apropiado de las redes neuronales si se logra que

entre los ejemplos se encuentren los casos más representativos de la entidad por evaluar.

Conclusiones

Es viable entrenar una red neuronal a partir de los parámetros de la escala de clasificación de probabilidad de Braunwald para el diagnóstico del IAM, con un desempeño tal que podría llegar a servir para el apoyo de la toma de decisiones de los médicos de urgencias que atienden pacientes que consultan por dolor torácico.

Conflicto de intereses

Los autores declaran no tener ningún conflicto de intereses.

Agradecimientos

A las doctoras María Teresa Fontalvo y Carolina Araque por su ayuda en la fase de recolección de la información.

Bibliografía

1. Erhardt L, Herlitz J, Bossaert L, Halinen M, Keltai M, Koster R, et al. Task force on the management of chest pain. *Eur Heart J*. 2002;23:1153-76.
2. Kohn LT, Corrigan JM, Donaldson MS, editores. To Err Is Human: Building a Safer Health System. Committee on Health Care in America. Washington: Institute of Medicine. National Academy Press; 1999.
3. Pope JH, Aufderheide TP, Ruthazer R, Woolard RH, Feldman JA, Beshansky JR, et al. Missed diagnoses of acute cardiac ischemia in the emergency department. *N Eng J Med*. 2000;342(16):1163-70.
4. Eagle KA, Goodman SG, Avezum A, Budaj A, Sullivan CM, López-Sendón J. Practice variation and missed opportunities for reperfusion in ST-segment-elevation myocardial infarction: findings from the Global Registry of Acute Coronary Events (GRACE). *Lancet*. 2002;359:373-7.
5. Lobach D, Sanders GD, Bright TJ, Wong A, Dhurjati R, Bristow E, et al. Enabling Health Care Decision Making Through Clinical Decision Support and Knowledge Management. Evidence Report No. 203. (Prepared by the Duke Evidence-based Practice Center under Contract No. 290-2007-10066-I.) AHRQ Publication No. 12-E001-EF. Rockville, MD: Agency for Healthcare Research and Quality; 2012.
6. Sordo M, Vaidya S, Jain L. An introduction to computational intelligence in healthcare: New directions. En: *Advanced computational intelligence paradigms in healthcare - 3*. 3rd ed. New York, Berlin, Heidelberg: Springer; 2008. p. 1-26.
7. Trujillano J, March J, Sorribas A. Aproximación metodológica al uso de redes neuronales artificiales para la predicción de resultados en medicina. *Med Clin (Barc)*. 2004;122 Supl 1:59-67.
8. Cross SS, Harrison RF, Kennedy RL. Introduction to neural networks. *Lancet*. 1995;346:1075-9.
9. Baxt WG. Use of an artificial neural network for the diagnosis of myocardial infarction. *Ann Intern Med*. 1991;115:843-8.
10. Baxt WG, Skora J. Prospective validation of artificial neural network trained to identify acute myocardial infarction. *Lancet*. 1996;347:12-5.
11. Ellenius J, Groth T, Lindahl B, Wallentin L. Early assessment of patients with suspected acute myocardial infarction by biochemical monitoring and neural network analysis. *Clin Chem*. 1997;43:1919-25.

12. Hedén B, Öhlin H, Rittner R, Edenbrandt L. Acute myocardial infarction detected in the 12-Lead ECG by Artificial Neural Networks. *Circulation*. 1997;96:1798–802.
13. Ohno-Machado L, Fraser HS, Ohrn A. Improving machine learning performance by removing redundant cases in medical data sets. *Proc AMIA Symp*. 1998:523–7.
14. Chazaro A, Cravens G, Eberhart R. Myocardial infarction diagnosis by a neural network. *IEEE*; 1998, p. 1121-1124 [consultado 15 Feb 2013]. Disponible en: <http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=747068&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs.all.jsp%3Farnumber%3D747068>
15. Ellenius J, Groth T. Methods for selection of adequate neural network structures with application to early assessment of chest pain patients by biochemical monitoring. *Int J Med Inform*. 2000;57:181–202.
16. Ellenius J, Groth T. Transferability of neural network-based decision support algorithms for early assessment of chest-pain patients. *Int J Med Inform*. 2000;60:1–20.
17. Baxt WG, Shofer FS, Sites FD, Hollander JE. A neural computational aid to the diagnosis of acute myocardial infarction. *Ann Emerg Med*. 2002;39:366–73.
18. Hollander JE, Sease KL, Sparano DM, Sites FD, Shofer FS, Baxt WG. Effects of neural network feedback to physicians on admit/discharge decision for emergency department patients with chest pain. *Ann Emerg Med*. 2004;44:199–205.
19. Harrison RF, Kennedy RL. Artificial neural network models for prediction of acute coronary syndromes using clinical data from the time of presentation. *Ann Emerg Med*. 2005;46:431–9.
20. Bigi R, Gregori D, Cortigiani L, Desideri A, Chiarotto FA, Toffolo GM. Artificial neural networks and robust Bayesian classifiers for risk stratification following uncomplicated myocardial infarction. *Int J Cardiol*. 2005;101:481–7.
21. Bulgiba AM. Using neural networks and just nine patient-reportable factors of screen for AMI. *Health Informatics J*. 2006;12:213–25.
22. Eggers KM, Ellenius J, Dellborg M, Groth T, Oldgren J, Swahn E, et al. Artificial neural network algorithms for early diagnosis of acute myocardial infarction and prediction of infarct size in chest pain patients. *Int J Cardiol*. 2007;114:366–74.
23. Al-Naima FM, Ali AH, Mahdi SS. Data acquisition for myocardial infarction classification based on wavelets and Neural Networks. *IEEE*; 2008, p. 1-6 [consultado 9 Feb 2013]. Disponible en: <http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=4632817&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs.all.jsp%3Farnumber%3D4632817>
24. Braunwald E, Jones RH, Mark DB, Brown J, Brown L, Cheitlin MD, et al. Diagnosing and managing unstable angina. Agency for Health Care Policy and Research. *Circulation*. 1994;90:613–22.
25. Anderson JL, Adams CD, Antman EM, Bridges CR, Califf RM, Casey Jr DE, et al. ACC/AHA 2007 guidelines for the management of patients with unstable angina/non-ST-Elevation myocardial infarction: A report of the American College of Cardiology/American Heart Association Task Force on Practice Guidelines (Writing Committee to Revise the 2002 Guidelines for the Management of Patients With Unstable Angina/Non-ST-Elevation Myocardial Infarction) developed in collaboration with the American College of Emergency Physicians, the Society for Cardiovascular Angiography and Interventions, and the Society of Thoracic Surgeons endorsed by the American Association of Cardiovascular and Pulmonary Rehabilitation and the Society for Academic Emergency Medicine. *J Am Coll Cardiol*. 2007;50:e1–157.
26. Antman EM, Anbe DT, Armstrong PW, Bates ER, Green LA, Hand M, et al. ACC/AHA guidelines for the management of patients with ST-elevation myocardial infarction—executive summary. A report of the American College of Cardiology/American Heart Association Task Force on Practice Guidelines (Writing Committee to revise the 1999 guidelines for the management of patients with acute myocardial infarction). *J Am Coll Cardiol*. 2004;44:671–719.
27. Negnevitsky M. *Artificial Intelligence: A Guide to Intelligent Systems*. 2nd ed Tasmania, Australia: Pearson Education Limited; 2005. p. 259–98.
28. Awais MM, Awan SK. Gastro-intestinal tract inspired computational model for myocardial infarction diagnosis. *Expert Syst Appl*. 2011;38:5633–41.