

Aplicabilidad de redes neuronales artificiales para la predicción de los resultados individuales de la cirugía cardíaca. Estudio preliminar

RAÚL A. BORRACCI*, MIGUEL RUBIO*

RESUMEN

Objetivos

Estudiar la aplicabilidad de redes neuronales artificiales (RNA) para pronosticar los resultados quirúrgicos individuales y por grupos de riesgo de la cirugía cardíaca.

Material y métodos

Se estudiaron 250 pacientes sometidos a cirugía cardíaca entre 1994 y 1997 con cuyos datos se evaluó la capacidad de distintas RNA para pronosticar la sobrevida inmediata poscirugía en base a 15 variables preoperatorias, 2 puntajes de riesgo (Parsonnet y PACCN) y a la aparición o no de complicaciones mayores posquirúrgicas (infarto, sepsis, accidente cerebrovascular y distrés), tomando como evento final la muerte. Las 6 RNA fueron del tipo perceptrón multicapa con aprendizaje de retropropagación y 15, 17 ó 19 neuronas de entrada, 15 neuronas en la capa oculta y 2 de salida, función de transferencia tangente hiperbólica, pesos iniciales aleatorios y aprendizaje por lotes.

Resultados

Las redes mostraron alta sensibilidad para predecir sobrevida postoperatoria inmediata y la especificidad creció a medida que se incorporaron los puntajes de riesgo (red N° 2 y N° 2E) y la presencia o no de complicaciones (red N° 3 y N° 3E).

Resultados de las pruebas de sensibilidad y especificidad para pronosticar sobrevida

	red N° 1	red N° 2	red N° 3	p
Sensibilidad	100,0%	91,7%	95,8%	
Especificidad	16,6%	50,0%	83,3%	< 0,06
	red N° 1E	red N° 2E	red N° 3E	
Sensibilidad	83,3%	87,5%	95,8%	
Especificidad	20,0%	30,0%	70,0%	< 0,07

Conclusiones

a) Las RNA resultaron modelos aplicables para predecir los resultados individuales poscirugía cardíaca, b) no fue posible predecir la sobrevida de pacientes en particular sobre la base exclusivamente de las variables preoperatorias incluidas aquí (red N° 1 y N° 1E), c) el agregado de los puntajes como el de Parsonnet mejoró la precisión de la predicción (red N° 2 y N° 2E), d) sólo el agregado de la condición de complicado o no poscirugía mejoró la especificidad para pronosticar sobrevida (red N° 3 y N° 3E) y e) el aporte de otras variables perioperatorias de bases de datos con grandes volúmenes de pacientes permitiría obtener niveles de predicción no alcanzados ahora.

REV ARGENT CARDIOL 2003; 71: 351-358.

Recibido: 11/2002

Aceptado: 3/2003

Dirección para separatas:

R. A. Borracci.

La Pampa 3030 1° B

(1428) Buenos Aires, Argentina

Palabras clave

> Cirugía cardíaca - Mortalidad - Redes neuronales artificiales

INTRODUCCIÓN

Los modelos de ajuste usados para ponderar el riesgo de morbilidad operatoria proporcionan una estimación de la probabilidad de presentar un resulta-

do para un conjunto de pacientes con un mismo nivel de riesgo y de ninguna forma son predictivos sobre pacientes en particular. (1-3) Aunque esta última podría ser una condición deseable, hasta el momento no es posible pronosticar los resultados individuales para

la cirugía cardíaca en base a variables perioperatorias. Los métodos de regresión lineal y logística múltiple, o los modelos probabilísticos bayesianos han sido hasta el momento las formas de aproximación y análisis usadas para determinar relaciones entre variables que eventualmente podrían predecir eventos postoperatorios.

Desde fines de la década de los cincuenta comenzaron a desarrollarse en el área de la Inteligencia Artificial un conjunto de herramientas relacionadas con la estadística que, homologando estructuras neuronales cerebrales, se han dado en llamar redes o sistemas neuronales artificiales (RNA o SNA). Su aplicación práctica en ámbitos diferentes de la medicina data de aquella época y recién a partir de los noventa comenzó el uso clínico de SNA para analizar patrones e imágenes (4-5) y fundamentalmente para clasificar o predecir resultados en resucitación cardiopulmonar, (6) trasplante hepático, (7) recuperación o rehabilitación ortopédica, neurológica o posquirúrgica (8) y en el pronóstico de cáncer de ovario, mama, próstata y pulmón. (9-10) La actual expansión y sustento teórico de las SNA, así como la capacidad de cómputo alcanzada por los sistemas de uso de rutina y la disponibilidad comercial de *software ad hoc*, ofrecen una alternativa de análisis adicional para los problemas de clasificación, *clustering* y predicción.

Este trabajo se realizó con el objetivo de estudiar la aplicabilidad de redes neuronales artificiales para

pronosticar los resultados quirúrgicos individuales y por grupos de riesgo de la cirugía cardíaca.

MATERIAL Y MÉTODOS

Se estudiaron 250 pacientes sometidos a cirugía cardíaca en forma consecutiva entre 1994 y 1997 cuyos datos se habían recopilado en forma prospectiva en una base de datos *ad hoc*. Se evaluó la capacidad de distintas topologías de redes neuronales para pronosticar la sobrevida inmediata poscirugía cardíaca en base a 15 variables preoperatorias y a la aparición o no de complicaciones mayores posquirúrgicas inmediatas (infarto, sepsis, accidente cerebrovascular y distrés), tomando como evento final la muerte. Además se consideraron los valores preoperatorios de 2 puntajes (*scores*) de riesgo (Parsonnet (2) y PACCN (2)) también como variables independientes. Las variables preoperatorias se eligieron teniendo en cuenta aquellas seleccionadas en forma mayoritaria en 8 puntajes de riesgo clásicos (Tabla 1). El análisis se realizó calculando la sensibilidad, la especificidad, los falsos positivos, los falsos negativos, el valor predictivo positivo y el valor predictivo negativo de las redes para predecir sobrevida posquirúrgica inmediata. Los valores se expresan como proporciones y las comparaciones entre los resultados se realizaron con la prueba de *trend chi*². El nivel de significación se estableció en 5%.

Análisis con redes neuronales artificiales

Una red neuronal es un sistema artificial de computación compuesto por un número finito de unidades (neuronas) unidas por conectores (sinapsis) y que en conjunto son capaces de encontrar la relación que existe entre una serie de

Tabla 1
Factores de riesgo considerados en ocho estudios clásicos sobre puntajes de riesgo en cirugía cardíaca*

Factor de riesgo	Parsonnet (2)	Hannan (11)	O'Connor (12)	Higgins (13)	Tuman (3)	Edwards (14)	Tu (PACCN) (1)	CONAREC (15)
Edad > 70 años	X	X	X	X	X	X	X	X
Sexo femenino	X	X	X		X	X	X	
Deterioro moderado-severo del VI	X	X	X	X	X	X	X	X
Cirugía valvular	X	X		X	X		X	
Cirugía combinada	X				X		X	
Emergencia	X		X	X	X	X	X	X
Reoperación	X	X	X	X	X	X	X	X
Diabetes	X	X		X		X		
Disfunción renal	X	X		X	X			X
Obesidad	X					X		
Infarto previo		X			X	X		X
Enfermedad cerebrovascular periférica				X	X	X		
Insuficiencia cardíaca		X			X			X
Enfermedad pulmonar obstructiva crónica				X		X		X
Lesión de tronco		X				X		X

* Modificado de Tu y colaboradores. (1)

datos de entrada y un valor esperado en la salida de la red (Figura 1.a).

De acuerdo con su topología y con la dirección y sentido de sus conexiones, una red puede funcionar como un "aproximador universal de funciones", es decir que será capaz de encontrar cualquier tipo de relación no lineal múltiple entre las variables de entrada (en este caso las 15 variables de la Tabla 1) y el valor de la variable de salida (en este caso la condición de vivo - muerto). Una de las redes más usadas en la actualidad para resolver problemas de clasificación o regresión es la de perceptrones multi-capa (PMC) (*multi-layer perceptron, MLP*) que en este trabajo se implementó mediante el uso del *software* de simulación de redes neuronales Neurosolutions 4®. La primera red (red N° 1), usada para analizar la relación entre las variables de la Tabla 1 y la condición de sobrevida postoperatoria se esquematiza en la Figura 1.b. Ésta consistió en una PMC con aprendizaje de retropropagación (*backpropagation*) con 15 neuronas de entrada, 15 neuronas en la capa oculta y 2 en la de salida, todas con conexiones hacia adelante (*feedforward*), función de transferencia tipo tangente hiperbólica, pesos iniciales aleatorios y aprendizaje por lotes (*batch*). Los datos de los 250 pacientes se introdujeron con formato binario (1 - 0) para la presencia o no de cada condición.

El segundo modelo (red N° 2) incluyó como entrada a ellas 15 variables y los puntajes de cada paciente calculados con los puntajes de Parsonnet y PACCN y como salida a la misma condición de vivo - muerto. La topología fue del tipo 17 - 15 - 2 (neuronas de entradas - ocultas - salidas) y el resto de las características similares a las de la red N° 1. En la red N° 3 se

incluyeron en la entrada las 15 variables preoperatorias, los puntajes de Parsonnet y del PACCN y si el paciente tuvo o no una complicación mayor en el postoperatorio inmediato, en tanto que la salida y el resto de las características fueron similares a las de la red N° 2 (en este caso la arquitectura fue 19 - 15 - 2). Dos redes se entrenaron con 220 casos (todas las variables de cada paciente) y se probaron con los 30 casos restantes (n = 250). Para evitar el sobreaprendizaje de la red, durante la etapa de entrenamiento se realizó una validación cruzada (*cross-validation*) que se muestra en la Figura 2.a, b y c. Adicionalmente se entrenaron y se probaron otras 3 redes con las mismas variables de entrada, pero en este caso, tanto el conjunto de entrenamiento como el de testeo fueron enriquecidos (E) con el agregado de pacientes que presentaron el evento "muerte" y así se generó un aumento artificial de la prevalencia de dicho evento (de 9,2% a 13,4%). Estas redes se denominaron N° 1E, N° 2E y N° 3E, respectivamente. Por último, se realizó un análisis de sensibilidad con respecto a la media de todas las variables para determinar la importancia o el peso relativo de cada una de ellas en el comportamiento predictivo de las redes.

RESULTADOS

En la Tabla 2 se muestran las frecuencias absolutas y relativas de presentación de los factores de riesgo en la población usada para entrenamiento y prueba de las redes, además de la tasa de complicaciones mayores. En la Tabla 3 se observa la distribución de la po-

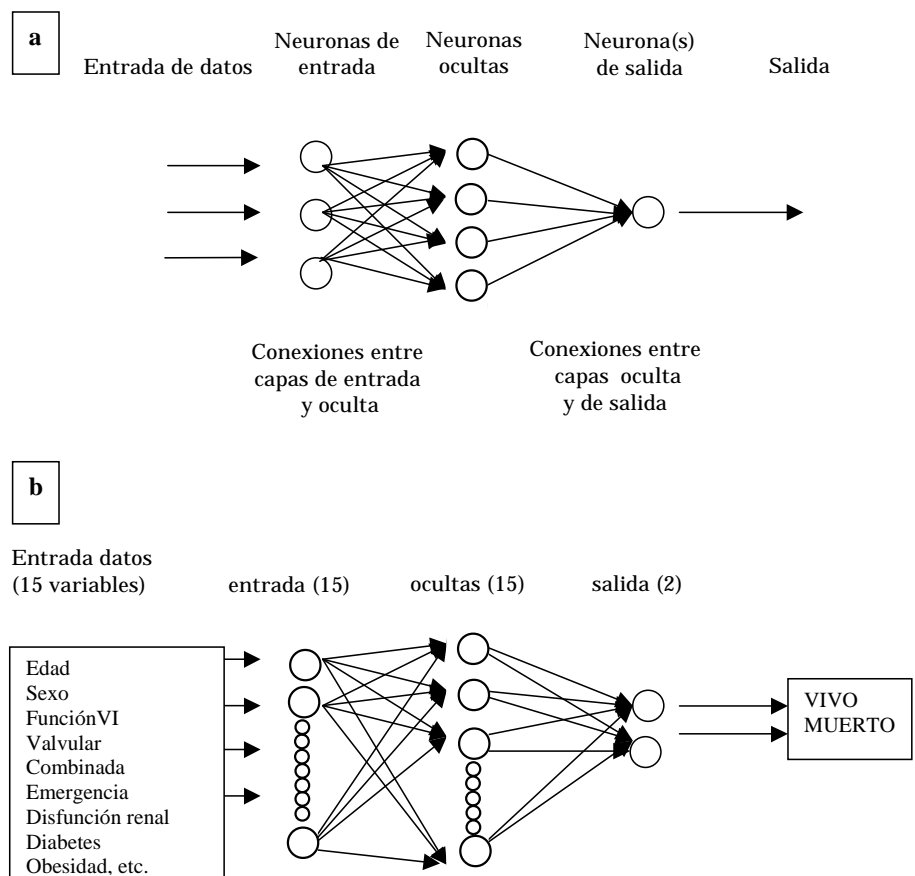


Fig. 1.a: Topología de una red neuronal de perceptrones multicapa (PMC). B. Red PMC para relacionar las 15 variables de la Tabla 1 con la condición vivo-muerto en el posoperatorio (red 1).

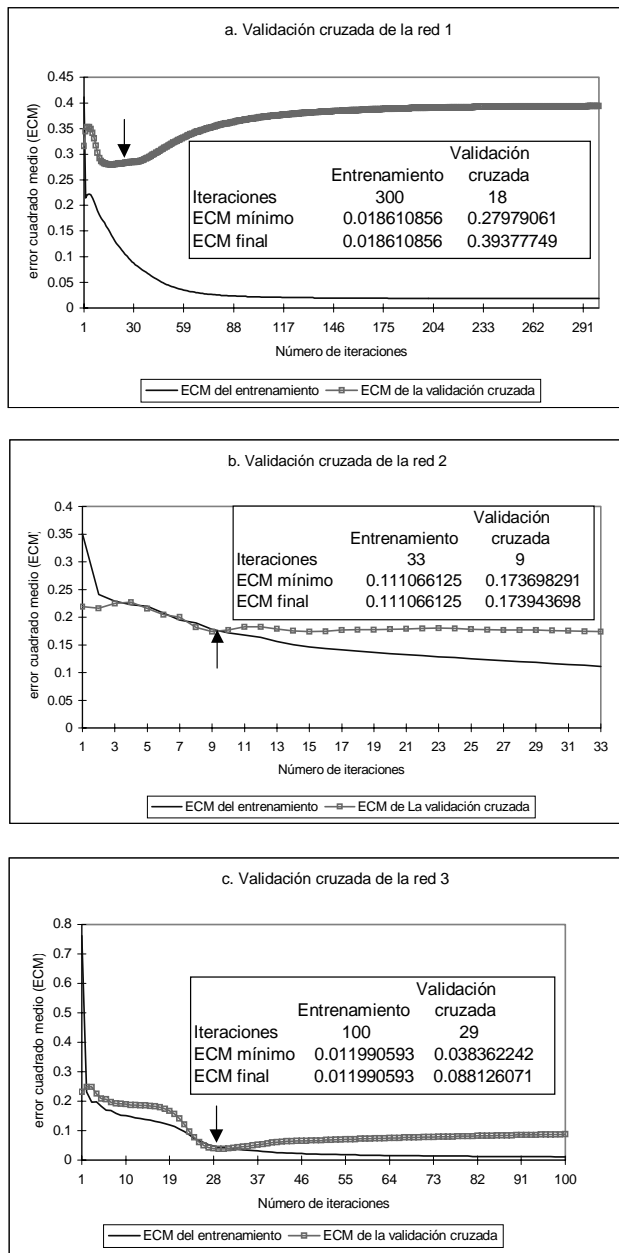


Fig. 2 a, b y c: Validación cruzada que relaciona la cantidad de iteraciones y el error cuadrado medio (ECM) obtenido para el conjunto de entrenamiento óptimo que se relaciona con el error de generalización mínimo, se corresponde en cada gráfico con el valle más profundo (flecha) de las líneas marcadas como ECM de la validación cruzada. A partir de este punto el error de aprendizaje puede hacerse más pequeño pero el error de generalización o testeo suele aumentar, deteriorando así la capacidad de predicción de la red.

blación de acuerdo con el puntaje de Parsonnet y la mortalidad observada. Los resultados de las pruebas de las 6 redes se resumen en la Tabla 4. Se observan el porcentaje creciente de la especificidad de las redes y la disminución de los falsos positivos a medida que se van incluyendo en las entradas los puntajes de Parsonnet y del PACCN (redes N° 2 y N° 2E) y la tasa

Tabla 2
Frecuencia de aparición de los distintos factores de riesgo

Factor de riesgo	n	%
Edad > 70 años	58	23,2
Sexo femenino	61	24,4
Deterioro moderado-severo de VI	52	20,8
Cirugía valvular	54	21,6
Cirugía combinada	8	3,2
Emergencia	3	1,2
Reoperación	2	0,8
Diabetes	32	12,8
Disfunción renal	8	3,2
Obesidad	20	8,0
Infarto previo	45	18,0
Enfermedad cerebrovascular o periférica	9	3,6
Insuficiencia cardíaca	22	8,8
Enfermedad pulmonar obstructiva crónica	14	5,6
Lesión de tronco	14	5,6
Complicaciones mayores	29	11,6

Tabla 3
Distribución de la población de acuerdo con el puntaje de Parsonnet

Puntaje	n	frecuencia (%)	mortalidad observada (%)
0-4	60	24	3,3
5-9	87	35	4,5
10-14	53	21	9,4
15-19	30	12	16,6
> 19	20	8	35,0


de complicaciones (redes N° 3 y N° 3E). El enriquecimiento de los datos de entrada en las redes N° 1E, N° 2E y N° 3E no demostró que mejore el desempeño de éstas con respecto a las redes entrenadas con el conjunto original. El resultado del análisis de sensibilidad con respecto a la media de todas las variables de entrada se muestra en la Figura 3. Los picos de esta distribución señalan las variables más prevalentes en el conjunto de datos y las diferencias entre "vivos y muertos" muestran la importancia relativa de cada rasgo para predecir o no el evento.

DISCUSIÓN

El uso de redes neuronales artificiales para la predicción de los resultados individuales poscirugía cardíaca constituyó una alternativa de fácil aplicación al estudio de múltiples variables perioperatorias. Aunque el análisis basado únicamente en variables preoperatorias no fue suficiente para obtener un buen nivel de predicción, la inclusión de variables posquirúrgicas como la presentación o no de complicaciones mejoró significativamente el nivel de predicción de la red. Podría considerarse en forma intuitiva que la apari-

Tabla 4
Resultados de las pruebas de sensibilidad y especificidad de las 6 redes probadas para pronosticar sobrevida

	red N° 1	red N° 2	red N° 3	P _{trend chi²}
Sensibilidad	100,0%	91,7%	95,8%	
Especificidad	16,6%	50,0%	83,3%	< 0,06
Falsos positivos	83,3%	50,0%	16,6%	< 0,06
Falsos negativos	0,0%	8,3%	4,2%	
Valor predictivo positivo	82,8%	8,0%	95,5%	
Valor predictivo negativo	100,0%	60,0%	83,3%	
	red N° 1E	red N° 2E	red N°3E	
Sensibilidad	83,3%	87,5%	95,8%	
Especificidad	20,0%	30,0%	70,0%	< 0,07



Sensibilidad	Vivo	Muerto
Edad > 70 años	0,003456433	0,002490284
Sexo femen.	0,021775667	0,01836638
Función VI mod-sev	0,027984444	0,018843694
Cirugía valvular	0,04620114	0,039407197
Cirugía combinada	0,030043399	0,023117905
Cirugía urgencia	0,016109589	0,017037222
Reoperación	0,000683515	0,000645666
Diabetes	0,001983692	0,002188697
Infarto previo	0,001326742	0,001061587
Enfermedad CV o		
Arteriopatía	0,018904801	0,011765658
Obesidad	0,006359011	0,008427431
Disfunción renal	0,00457654	0,005027034
EPOC	0,019412043	0,014615406
ICC	0,013397032	0,01758275
Lesión torácica	0,016668789	0,014843252
Parsonnet	0,000657748	0,000397061
PACCN	0,003278191	0,002624281
No complicado	0,032253273	0,026372392
Complicado	0,029017955	0,027848521

Fig. 3: Análisis de sensibilidad con respecto a la media de todas las variables de entrada

ción de complicaciones mayores en el postoperatorio inmediato determinarían una mortalidad mayor de estos pacientes. Sin duda esto fue cierto para el infarto postoperatorio y para la infección mediastínica, pero no para el caso del distrés y del accidente cerebrovascular, todos ellos eventos considerados en este estudio.

La aplicación de SNA para la clasificación o predicción en el ámbito de la medicina clínica se ha explorado en particular en el área de la oncología, fundamentalmente para determinar el pronóstico de estas enfermedades. (16) En el caso de las enfermedades cardiovasculares, los trabajos con redes neuronales han incluido la predicción de complicaciones de válvulas bioprotésicas, (17) el diagnóstico diferencial de la angina de pecho (18) y de la embolia pulmonar (19) y la predicción de la sobrevida tras resucitación cardiopulmonar, (6) *bypass* coronario (20) o muerte intrahospitalaria posterior a angioplastia coronaria. (21) Otros tipos de redes neuronales se usaron también para el análisis de ondas electrocardiográficas (22) o de electrogramas durante el implante de cardiodesfibriladores. (23)

Las redes PMC como las empleadas en este estudio tienen la particularidad de ser sistemas que aprenden a partir de un conjunto de datos de entrenamiento que les aportan las variables de entrada y los resultados esperados, en este caso vivo-muerto. Si se le da un número suficiente de casos de entrenamiento y se repite varias veces (iteraciones), este aprendizaje supervisado capacita a la red para clasificar cualquier nueva entrada no usada en el entrenamiento en una salida esperada (vivo-muerto, o complicado-no complicado si éste fuera el evento final evaluado). La principal ventaja de los SNA estaría dada por el procesamiento no lineal que éstas realizan y por su habilidad para identificar relaciones o patrones multidimensionales no aparentes en los datos clínicos lo cual mejoraría el poder predictivo de otras formas de aproximación al problema. La capacidad de entrenarse de una

red PMC depende fundamentalmente de su arquitectura, de la cantidad de ejemplos usados para el entrenamiento y de la prevalencia del evento que se pretende predecir. Es por ello que el número de casos de entrenamiento debe estar necesariamente relacionado con la dimensión de la red. Esta relación se hace aún más evidente cuando la prevalencia del evento que se pretende predecir es baja, ya que la red tendrá poca probabilidad de encontrarlo dentro de los patrones de aprendizaje. Para subsanar esta limitación se podrían separar todos los casos en los que el evento esté presente y asignar la mitad de éstos a la etapa de entrenamiento junto con una cantidad igual de casos que no presentaron el evento, sin necesidad de mantener la proporción original en todo el conjunto de aprendizaje y testeo. (17) De esta forma se enriquece con el evento al grupo de patrones de aprendizaje. Sin embargo, en el trabajo que aquí se presenta, las redes N° 1E, N° 2E y N° 3E no mejoraron el desempeño de las redes originales. Esta falta de mejora al enriquecer las redes con eventos adicionales puede deberse a una cantidad insuficiente de casos o más probablemente a la ausencia de otras relaciones no lineales más complejas que podrían haberse escapado en el conjunto original.

Una condición clara que se desprende del análisis de los SNA es la necesidad de contar con grandes volúmenes de datos. El incumplimiento de este requisito en muchos trabajos publicados en la década pasada ha generado en algunos casos inconsistencia en sus resultados y ha favorecido la reevaluación crítica de esta técnica. (24-26) De cualquier forma es importante destacar que la determinación del tamaño de la muestra cuando se trabaja con redes neuronales difiere de la usada en la estadística clásica. Como se ha señalado, la dimensión de la muestra depende en especial del número de entradas a la red, pero se debe recordar que el conjunto de datos de entrada ya contiene en su haber las variables que han resultado tener mayor importancia predictiva en análisis univariados previos (Tabla 1). De la misma manera, el enriquecimiento con casos que presenten el evento en estudio más allá de la proporción original del conjunto incrementa en la muestra la probabilidad de encontrar dicho evento.

A lo sumo, todos los puntajes de riesgo de morbimortalidad publicados pronostican la probabilidad de que eventos como la muerte o las complicaciones se presenten en determinado grupo de riesgo. Así, la posibilidad de que un SNA alcance un nivel de desempeño capaz de determinar en un intervalo acotado –los resultados individuales de un paciente en particular– constituye un atractivo mayor. (27) En una red entrenada y validada adecuadamente, la presentación de un caso problema individual podría dar por resultado la predicción del evento con un margen de certidumbre razonable. En el caso de la red N° 3 de este trabajo, ésta podría pronosticar la sobrevida de un paciente tras una cirugía cardíaca, con una sensibilidad cercana al 96% y una especificidad del 83%. De todas for-

mas, este nivel de precisión requirió la inclusión de la condición de complicado o no en el postoperatorio inmediato, lo que lo convierte en un método impropio para determinar un pronóstico en la consulta prequirúrgica. En forma más amplia, la construcción de redes que incluyan otras variables perioperatorias o datos de los eventos intraquirúrgicos podrían servir para mejorar la exactitud de la predicción.

Lejos de competir con los métodos estadísticos de regresión múltiple, los SNA derivan de éstos y a su vez complementan el complejo análisis de regresión y correlación no lineal. Sargent (28) comparó los SNA con técnicas estadísticas y concluyó que aunque ambos métodos ofrecen resultados similares en el análisis de predicción, los SNA tendrían ventajas cuando el conjunto de datos de entrenamiento se encuentra entre 200 y 2.000 casos. Por su parte, Lippman RP y colaboradores (20) compararon SNA con las técnicas de regresión logística y análisis bayesiano para clasificar pacientes sometidos a *bypass* coronario en distintas categorías de riesgo. Usando 36 variables de 80.000 pacientes de la base de datos de la Sociedad de Cirujanos Torácicos de los Estados Unidos determinaron que las redes PMC mostraron igual desempeño que las técnicas estadísticas y en el mejor de los casos sirvieron en conjunto con estas últimas para mejorar la predicción final de mortalidad esperada de estos pacientes.

Los datos masivos de variables predictoras deberán extraerse de grandes bases de datos, como lo son las del ESMUCICA (29) o CONAREC (15) en nuestro medio, lo cual permitirá entrenar redes con un número mayor de entradas. El campo de aplicación de SNA podría extenderse también a otras áreas de predicción en cardiología y, como método de análisis no lineal, complementar la búsqueda de factores predictores en insuficiencia cardíaca por ejemplo, pronosticar eventos después de intervenciones diagnósticas o terapéuticas, o prever tiempos de estadía hospitalaria.

Limitaciones del método

Existe una amplia base teórica que avala el uso de SNA como instrumentos de análisis de datos. White H. (30, 31) ha estudiado las bases estadísticas de las redes neuronales y ha señalado las ventajas y desventajas de

Tabla 5
Relaciones entre redes neuronales y técnicas estadísticas

Perceptrón simple	Regresión logística
Adalina	Regresión lineal
Perceptrón multicapa	Regresión no lineal
Cuantificación de vectores	Análisis discriminante
Funciones de base radial RBF	Métodos de <i>kernnel regression</i>
Mapas de Kohonen	Análisis multidimensional
Redes de contrapropagación	?
Redes ART (teoría de resonancia adaptativa)	?
Modelos de Hopfield	?

su uso. Entre estas últimas se encuentra que los SNA son métodos que requieren cierta creatividad para la resolución de problemas, ya que la arquitectura de una red se debe ensayar mediante prueba y error. Además, los modelos neuronales precisan elevados requisitos de cómputo para la etapa de entrenamiento. Por último, la aparente flexibilidad de las redes neuronales se contrapone en la aplicación clínica por el hecho de que aquéllas trabajan como "cajas negras", es decir que no dan explicaciones acerca de cómo alcanzaron determinado resultado, condición que podría tener implicaciones negativas en las decisiones médicas. Es por eso que la investigación y el desarrollo teórico de los SNA es fundamental para aceptar su uso. (32)

CONCLUSIONES

a) las redes de retropropagación (PMC) resultaron modelos aplicables para el análisis de predicción de resultados individuales poscirugía cardíaca, b) no fue posible predecir la sobrevida de un paciente en particular basándose exclusivamente en las variables preoperatorias incluidas en este estudio, c) el agregado de los puntajes obtenidos para cada paciente con puntajes de riesgo como el de Parsonnet mejoró significativamente la precisión (especificidad) de la predicción, d) sólo la inclusión de la condición de complicado o no después de la cirugía mejoró la especificidad de la red para pronosticar sobrevida y e) el aporte de otras variables perioperatorias y el aprovechamiento de bases de datos con grandes volúmenes de pacientes seguramente permitiría obtener niveles de predicción no alcanzados hasta el momento.

SUMMARY

Applicability of artificial neural networks to predict individual outcomes in cardiac surgery

Study objective

The aim of this study was to assess the applicability of artificial neural networks (RNA) to forecast individual as well as risk-grouped cardiac surgical outcomes.

Research design and methods

Data from 250 patients who underwent cardiac surgery between 1994 and 1997, including 15 different preoperative variables, 2 risk scores (Parsonnet and PACCN) and major postoperative events, such as myocardial infarction, sepsis, stroke and distress, considering death as the final event, were fed to six topologically different RNA (multi-layer Perceptron type, with back-propagated learning; 15, 17 or 19 neurons in the input layer, 15 nodes in the hidden layer and 2 in the output layer; hyperbolic tangent transference function; random initial weights and batch learning).

Results

The networks showed high sensitivity in the prediction of immediate postoperative survival, and an increasing specificity with the addition of risk scores data (net2 and 2E) and postoperative event data (net3 and 3E).

Sensitivity and specificity test results in the prediction on survival

	net1	net2	net3	p ^{trend chi2}
sensitivity	100.0%	91.7%	95.8%	
specificity	16.6%	50.0%	83.3%	< .06
	net1E	net2E	net3E	
sensitivity	83.3%	87.5%	95.8%	
specificity	20.0%	30.0%	70.0%	< .07

Conclusions

a) RNA were found to be an applicable model in the forecast of individual immediate heart surgery outcomes. b) Prediction was unreliable on the single basis of the preoperative variables used here (net1 and 1E). c) The addition of risk scores such as Parsonnet greatly improved precision (net2 and 2E). d) Specificity in the prediction of immediate survival only improved after the addition of postoperative event data (net3 and 3E). e) Inclusion of other perioperative variables from large patient databases will probably improve current levels of prediction.

Keywords: Cardiac surgery - Mortality - Artificial neural networks

BIBLIOGRAFÍA

1. Tu JV, Jaglal SB, Naylor CD. Multicenter validation of a risk index for mortality, intensive care unit stay, and overall hospital length of stay after cardiac surgery. Steering Committee of the Provincial Adult Cardiac Care Network of Ontario. *Circulation* 1995;91:677-84.
2. Parsonnet V, Dean D, Bernstein AD. A method of uniform stratification of risk for evaluating the results of surgery in acquired adult heart disease. *Circulation* 1989;79:I-3-I-12.
3. Tuman KJ, McCarthy RJ, Mareh RJ, Najafi H, Ivankovich AD. Morbidity and duration of ICU day after cardiac surgery: a model for preoperative risk assessment. *Chest* 1992;102:36-44.
4. Reinus WR. Diagnosis of focal bone lesions using neural networks. *Invest Radiol* 1994;29:606-11.
5. Hare BJ, Prestegard JH. Application of neural networks to automated assignment of NMR spectra of proteins. *J Biomol NMR* 1994;4:35-46.
6. Ebell MH. Artificial neural networks for predicting failure to survive following in-hospital cardiopulmonary resuscitation. *J Fam Pract* 1993;36:297-303.
7. Doyle HR. Predicting outcomes after liver transplantation: a connectionist approach. *Ann Surg* 1994;219:408-15.
8. Tu JV, Guerriere MR. Use of a neural network as a predictive instrument for length of stay in the intensive care unit following cardiac surgery. *Proc Ann Symp on Comput Appl Med Care* 1992: 666-72.
9. Snow PB, Smith DS, Catalona WJ. Artificial neural networks in the diagnosis and prognosis of prostate cancer: a pilot study. *J Urol* 1994;152:1923-6.
10. Esteva H, Marchevsky A, Núñez T, Luna C, Esteva M. Neural networks as a prognostic tool of surgical risk in lung resections. *Ann Thorac Surg* 2002;73:1576-81.
11. Hannan EL, Kilburn HJr, O'Donnell JF, Lukacic G, Shields EP. Adult open heart surgery in New York State: an analysis of risk factors and hospital mortality rates. *JAMA* 1990;264:2768-74.
12. O'Connor GT, Plume SK, Olmstead EM, Coffin LH, Horton JR, Maloney CR, et al. Multivariate prediction of in-hospital mortality associated with coronary artery bypass graft surgery. *Circulation* 1992;85:2110-18.

13. Higgins TL, Estafanous FG, Loop FD, Beck GJ, Blum JM, Paranandi L. Stratification of morbidity and mortality outcome by preoperative risk factors in coronary artery bypass patients: a clinical severity score. *JAMA* 1992;267:2344-8.
14. Edwards FH, Clark RE, Schwartz M. Coronary artery bypass grafting: the Society of Thoracic Surgeons National Database experience. *Ann Thorac Surg* 1994;57:12-19.
15. Ciruzzi M, Aranda G, Bozovich G, Henquin R, Vallejos J, Chevo A, et al. CONAREC III. Predicción del riesgo de mortalidad intrahospitalaria en pacientes sometidos a cirugía coronaria. *Rev Argent Cardiol* 1996;64:79-90.
16. Dayhoff JE, DeLeo JM. Artificial neural networks. Opening the black box. *Cancer* 2001;91:1615-35.
17. Katz AS, Katz S, Wickham E, Quijano RC. Prediction of valve-related complications for artificial heart valves using adaptive neural networks: a preliminary study. *J Heart Valve Dis* 1993;2:504-8.
18. Baxt WG. Use of an artificial neural network for the diagnosis of myocardial infarction. *Ann Intern Med* 1991;115:843-8.
19. Patil S, Henry JW, Rubenfire M, Stein PD. Neural network in the clinical diagnosis of acute pulmonary embolism. *Chest* 1993;104:1685-9.
20. Lippman RP, Shahian DM. Coronary artery bypass risk prediction using neural networks. *Ann Thorac Surg* 1997;63:1635-43.
21. Freeman RV, Eagle KA, Bates ER, Werns SW, Kline-Rogers E, Karavite D, et al. Comparison of artificial neural networks with logistic regression in prediction of in-hospital death after percutaneous transluminal coronary angioplasty. *Am Heart J* 2000;140:511-20.
22. Bortolan G, Willems JL. Diagnostic ECG classification based on neural networks. *J Electrocardiol* 1993;26:75-9.
23. Farrugia S, Yee H, Nickolls P. Implantable cardioverter defibrillator electrogram recognition with a multilayer perceptron. *Pacing Clin Electrophysiol* 1993;16:228-34.
24. Gurney JW. Neural networks at the crossroads: caution ahead. *Radiology* 1994;193:27-8.
25. Jefferson MF, Pendleton N, Lucas S, Horan MA. Neural networks (editorial). *Lancet* 1995;346:1712.
26. Tarassenko L, Hayton P, Cerneaz N, et al. Novelty detection for the identification of masses in mammograms. Proceedings of 4th IEE International Conference on Artificial Neural Networks; Cambridge; 1995. p. 442-7.
27. Kattan M. Statistical prediction models, artificial neural networks, and the sophism "I am a patient, not a statistic". *J Clin Oncol* 2002;20:885-7.
28. Sargent DJ. Comparison of artificial neural networks with other statistical approaches. Results from medical data sets. *Cancer* 2001;91:1636-42.
29. Investigadores ESMUCICA. Estudio multicéntrico de cirugía cardíaca. Pacientes coronarios. *Rev Argent Cardiol* 1999;67:605-16.
30. White H. Neural-network learning and statistics. *AI Expert* 1989; Dec. p. 48-52.
31. White H. Learning in artificial neural networks: a statistical perspective. *Neural Computation* 1989;1:425-64.
32. Hart A, Wyatt J. Evaluating black-boxes as medical decision aids: issues arising from a study of neural networks. *Med Inform (Lond)* 1990;15:229-36.

EDUCACIÓN CONTINUA

Highlights del XXXº Congreso Argentino de Cardiología en CD-ROM.

Contiene las principales conferencias y Mesas redondas. Diapositivas y audio. Cuestionario de evaluación con puntaje para Recertificación. Valor \$ 30 Socios SAC.

Curso BIANUAL de Actualización en Cardiología 2003-2004 en CD-ROM.

Contiene 17 conferencias (Módulos 1 a 4). Diapositivas, audio, videos. Cuestionario de evaluación con puntaje para Recertificación. Valor \$ 30 Socios SAC.

Disponibles en Tesorería. Consultas: Área de Recursos Instruccionales. ari@sac.org.ar www.sac.org.ar

FE DE ERRATA

En el artículo "Un nuevo método para estimar la presión de fin de diástole del VI utilizando la rigidez de cámara derivada del tiempo de desaceleración", publicado en la Revista N° 3, vol. 71 del año 2003, página 171 (resumen) y 174:

$$\text{donde dice: } K_{VI} = ([TD - 0,02]/0,07)-2 \text{ (mm Hg/ml)}$$

$$\text{debe decir: } K_{VI} = ([TD - 0,02]/0,07)^{-2} \text{ (mm Hg/ml)}$$

Se aclara además que el TD debe ser expresado en segundos y no en milisegundos.
