

Clasificación del Riesgo de Cirugía Cardíaca Pediátrica mediante un Perceptron Multicapa (MLP)

A. Monsalve Torra, D. Ruiz Fernández, A. Soriano Payá

Tecnología Informática y Computación, Universidad de Alicante, España,

aemt@alu.ua.es, druz@dtic.ua.es, asoriano@dtic.ua.es

Resumen

Las cardiopatías congénitas son una de las causas más comunes de mortalidad en niños especialmente en neonatos. Identificar tempranamente los factores de riesgo en los tratamientos correctivos o paliativos de la cirugía cardíaca es primordial para reducir la mortalidad y las complicaciones derivadas de éstos. El desarrollo de aplicaciones basadas en redes neuronales puede ayudar en la clasificación de dicho riesgo con mayor precisión y prontitud. Las redes neuronales, han mostrado gran capacidad para ser aplicadas como instrumentos de clasificación en el sector médico. En este trabajo de investigación, se ha desarrollado una aplicación, basada en perceptron multicapa (MLP), que ha dado como resultado tres tipos de ajuste para el riesgo de la cirugía cardíaca congénita (CCC): bajo riesgo, riesgo medio y alto riesgo, con una precisión del 99%.

1. Introducción

Las cardiopatías congénitas (CC) son malformaciones en la estructura del corazón y/o de los grandes vasos presentes desde la vida uterina, suelen ser detectadas al momento del nacimiento o posteriormente según sus síntomas. Estas malformaciones cardíacas congénitas son muy comunes causando un aumento de la morbilidad y la mortalidad especialmente en neonatos [1]. Presenta una incidencia entre 0.5% a 1,25% de los nacidos vivos [2]. Se estima que cada año en la Unión Europea 36.000 niños nacen con CC y otros 3.000 son diagnosticados con CC, pero murieron como consecuencia de la interrupción del embarazo por una anomalía fetal [3].

El personal médico y asistencial tiene que tomar decisiones clínicas frente a los problemas que aquejan la salud de los pacientes, especialmente aquellas relacionadas con el diagnóstico y/o el tratamiento de los mismos. El avance de las nuevas tecnologías de computación ha hecho que la temprana toma de decisiones sea cada vez más eficaz, garantizando una mejora en la calidad de vida. En el proceso de toma de decisiones se han incluido diferentes herramientas de la inteligencia artificial, en especial el uso de las redes neuronales artificiales (RNAs).

Las RNAs son sistemas de computación en paralelo para el procesamiento de la información. Se inspiran en el modo de funcionamiento de las neuronas biológicas. Por sus características, éstas ofrecen grandes ventajas: la auto-organización, la tolerancia a fallos y el aprendizaje adaptativo [4]. Además, su habilidad como clasificador

ha hecho que estos modelos sean utilizados en múltiples aplicaciones médicas. Esta investigación tiene por objetivo desarrollar un clasificador que ajuste del riesgo de la CCC. Dicho clasificador está basado en redes neuronales con aprendizaje supervisado (Perceptron multicapa, MLP), que ayuden a la mejor estratificación del riesgo de cirugía cardíaca en niños con CC.

El trabajo está organizado de como sigue: en el segundo apartado, se hace una breve descripción de trabajos previos relacionados con nuestro tema; a continuación se describe el algoritmo de aprendizaje, basado en MLP y su funcionamiento; en la siguiente sección se detalla la experimentación y los resultados. Finalmente las conclusiones se realizan en el último apartado.

2. Antecedentes

Actualmente, existe un gran número de investigaciones en RNAs y su aplicación en medicina, especialmente los temas relacionados con el diagnóstico, predicción y tratamiento de enfermedades complejas. En el campo de la neurología se ha aplicado en predicción de mortalidad en pacientes con accidente cerebrovascular isquémico o hemorrágico [5]; además en la predicción de muerte cerebral enfocados en diferentes niveles de la escala Glasgow [6]. En urología, en el diagnóstico de disfunciones urinarias [7] y en la predicción de factores de riesgo para cáncer de próstata [8]. Asimismo, se encuentra un gran volumen de aplicaciones en cardiología; donde se analiza la variabilidad de la frecuencia cardíaca para evaluar la fatiga del conductor [9], en la enfermedad coronaria, donde se utilizó como seleccionador de características principales con un porcentaje de acierto del 89,4% [10]. En la predicción de resultados de diferentes enfermedades cardíacas como: la insuficiencia cardíaca [11], la clasificación de arritmias cardíacas, en la cual se aplicaron diferentes modelos y los resultados mostraron una precisión del 98.19% [12].

Finalmente en cardiología pediátrica se encuentran trabajos como la clasificación de ruidos cardíacos [13] y un sistema basado en un MLP con algoritmo de retropropagación que toma el conjunto de signos, los síntomas y los resultados de evaluación física de un paciente, dando como resultado el diagnóstico consiguiendo una precisión de 90% [14].

3. Algoritmo de ayuda a la toma decisión.

Dadas las ventajas de las RNAs mencionadas con anterioridad, ha aumentado el uso de las mismas en el sector médico, especialmente como herramienta de ayuda al diagnóstico, predicción y la clasificación (*clustering*) de enfermedades cardiacas [15], [16], [17]. El historial médico del paciente ofrece gran cantidad de información tales como: edad, peso, diagnóstico, etc.; las cuales presentan una alta dimensionalidad. Esta información puede ser analizada por diferentes tipos de algoritmos de aprendizaje. En este trabajo de investigación se ha utilizado un algoritmo supervisado, concretamente el perceptron multicapas (Backpropagation).

3.1 Perceptron Multicapa (MLP)

El MLP se caracteriza por un proceso de aprendizaje que se lleva a cabo controlado por un agente externo (maestro) que determina que respuesta debe generar la red.

Una red MLP consta de tres o más capas de nodos de procesamiento: una capa de entrada que recibe la información, una o más capas ocultas y una capa de salida que corresponde a los resultados de la clasificación (Figura 1) [18]. La estructura de nuestra red MLP, presenta una capa de entrada que se encarga de recibir la información de las 87 variables del historial médico del paciente, las capas ocultas son 5, que según la experimentación son las adecuadas para nuestra investigación y la capa de salida con tres nodos correspondientes a la clasificación del ajuste para el riesgo de CCC.

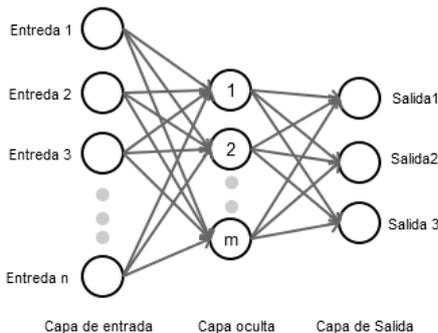


Figura 1. Estructura del Perceptron Multicapa

En esta investigación, el algoritmo utilizado para el aprendizaje es backpropagation (BP), desarrollado por Rumelhart [19]. El algoritmo BP entrena la red para un determinado conjunto de datos de entrada con salidas conocidas (clasificaciones). El algoritmo BP realiza su labor de actualización de pesos y con base en el error medio cuadrático (Regla delta) [20]. La red funciona bajo aprendizaje supervisado, por tanto necesita un grupo de datos de entrenamiento que le describa cada salida y el valor de salida deseada. A continuación, se muestra la fórmula estándar del algoritmo BP.

$$\Delta w_{ij}(t+1) = \eta \delta_j o_i \quad (1)$$

Donde $\Delta w_{ij}(t+1)$ es el ajuste de los pesos de las neuronas i y j , durante la interacción $(t+1)$; η es la tasa de aprendizaje; δ_j es el error para la unidad j y o_i es la salida de la unidad predecesora i .

Para la construcción de la arquitectura del MLP, se llevan a cabo los siguientes pasos.

1. Capa de entrada, que corresponde a la entrada de cada una de las variables necesarias para realizar la clasificación.
2. Capa oculta realiza un procesamiento no lineal de los datos de entrada.
3. Capa de salida con las clasificaciones correspondientes al ajuste para el riesgo de la CCC.

Cada variables pasa a través de la estructura de la red activando cada neurona y generando las salidas, las salidas son multiplicadas por los pesos sinápticos y constituyen la entrada de las neuronas de la capa siguiente, así continuamente hasta llegar a la capa de salida donde el resultado final se compara con el salida esperada, generando un error el cual es propagado por toda la red (backpropagation) hasta llegar al comienzo, corrigiendo los valores sinápticos. Así sucede con cada variable hasta que todos hayan pasado a través de la red.

4. Experimentación

4.1 Descripción de los datos

La base de datos utilizada en este estudio consiste en 2.432 registros de niños que fueron sometidos a cirugía de corrección de CC. Los datos fueron recogidos en la unidad pediátrica de cuidados intensivos de la Fundación Cardiovascular de Colombia. Los atributos representan información tales como la edad, el género, el peso, antecedentes, el diagnóstico, la intervención quirúrgica y el estado de salud después de la cirugía

Las variables (72) se clasifican en cuatro tipos; de datos básicos, los antecedentes, intervención quirúrgica y post operatorio. Las variables de entrada fueron ochenta y siete; éstas presentan tipos de datos: números, texto, datos continuos y rangos (Tabla 1).

Tipos de variables	Variables	Valores
Datos básicos	Edad (rango)	1,2,3
	Género (booleano)	0, 1
	Seguridad social (rango)	1 – 7
	Peso (rango)	1 – 6
Antecedentes	Síndrome de Down,	0,1
	asplenia, falla	0,1
	Hipertensión Arterial.	0,1
	Diagnóstico	

Datos quirúrgicos	Numero de procedimientos (número)	1 – 6
	Tiempo de cirugía (rango)	0 – 3
	Circulación extracorporea ,	0, 1

Tabla 1. Ejemplo de variables de entradas

4.2 Resultados.

Se ha utilizado el clasificador con la herramienta WEKA descrito en el apartado anterior. WEKA, una herramienta desarrollada en la Universidad de Waikato (Nueva Zelanda) bajo licencia GPL [21]. Para validarlo se han empleado las variables mencionadas anteriormente (87).

En las pruebas realizadas, se utilizó el método de validación cruzada en 10 particiones. Una partición de los subconjuntos se utilizó como datos de prueba y el resto como datos de entrenamiento.. El proceso de entrenamiento del algoritmo se llevo a cabo con 29 variables que aportaban la información básica y los antecedentes. La ejecución de las redes dio como resultado un porcentaje de acierto del 99% para la clasificación del ajuste para el riesgo de la CCC.

Se obtuvieron como resultado tres categorías de riesgo: bajo riesgo, riesgo moderado y alto riesgo. Las diferencias de los riesgos esta dada por la complejidad de los procedimientos, por los índices de mortalidad y complicaciones presentadas durante la hospitalización.

Tabla 2. Precisión detalla por clase.

VP (%)	FP (%)	Precisión	ROC	Clase
0.999	0.002	0.998	0.999	Bajo riesgo
0.998	0	1	0.999	Riesgo moderado
1	0	0.986	1	Alto riesgo

Los resultados que se detallan en la tabla 2, muestran la capacidad de precisión para clasificar el riesgo de CCC del MLP. La precisión por cada clase esta dada por el porcentaje de verdaderos positivos (VP), falsos positivos (FP) y la precisión. Los VP son aquellos pacientes que fueron correctamente clasificados. El porcentaje de FP son aquellos pacientes incorrectamente clasificados; es decir que fueron clasificados como de una clase, pero pertenecen a otra. En esta investigación las instancias correctamente clasificadas son: 2429 (99.87%) y mal clasificados son: 3 (0.1234 %). Es decir, un paciente que pertenece a la clase bajo riesgo, fue clasificado como alto riesgo y dos pacientes pertenecientes a la clase riesgo moderado fueron clasificados como de riesgo bajo.

Las curvas ROC (*Receiver Operating Characteristic*) son otra forma de validar el funcionamiento del clasificador. Estas fueron introducidas en la investigación clínica por los radiólogos Hanley J.A., McNeil B.J [22]. La curva ROC, expresa de manera gráfica la capacidad de discriminar de un clasificador. En

esta investigación, se puede decir que el resultado es casi perfecto, dado que la curva ROC se dirige a la parte superior izquierda de la gráfica (figura 2), donde se muestra el resultado de clasificación para la clase tres o alto riesgo del ajuste del riesgo cardiovascular.

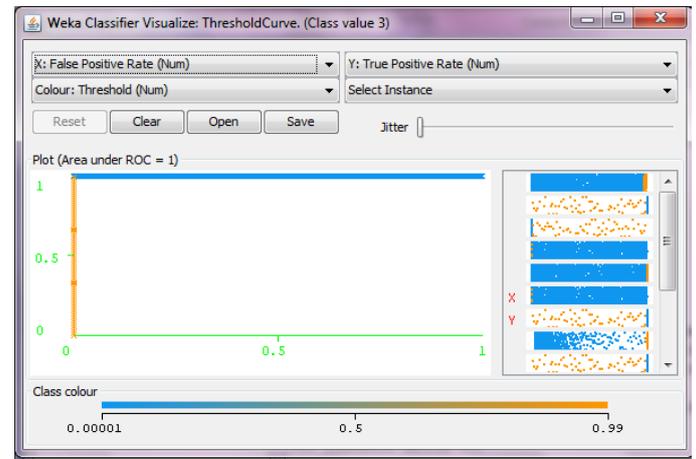


Figura 2. Área bajo de curva de la clase “alto riesgo”

La correcta clasificación del riesgo de CCC, permite al personal médico y asistencial hacer una mejor planificación de las actividades en el postoperatorio del paciente y anticipar posibles complicaciones.

5. Conclusiones

En este trabajo, se ha evaluado el algoritmo de aprendizaje supervisado (MLP), entrenado con backpropagation, para clasificar de riesgo de cirugía cardíaca en niños. Tres categorías fueron clasificadas (bajo, medio y alto riesgo). Los resultados de la clasificación fueron del 99,87% de acierto. Por lo tanto, se ha comprobado que el uso del clasificador MLP ofrece buenos resultados de clasificación del ajuste del riesgo para la CCC, con alta precisión.

Agradecimientos

Los autores quieren agradecer al Departamento de Cirugía Pediátrica de la Fundación Cardiovascular de Colombia por facilitar la información para esta investigación.

Referencias

- [1] Dos Santos GJ. Epidemiological characteristics of congenital heart diseases in londrina. *Arquivos Brasileiros De Cardiologia*, 74(5), 2000, pp 400-404. doi:10.1590/S0066-782X2000000500001.
- [2] Moquete de la Rosa, J. La investigación académica 71(1), *Revista Médica Dominicana*, 2010.
- [3] Burch, M., & Dedieu, N. Almanac 2012: Congenital heart disease. the national society journals present selected research that has driven recent advances in clinical cardiology. *The Egyptian Heart Journal*, 65(1), 2013, pp 21-29. doi:10.1016/j.ehj.2012.10.004

- [4] Basheer, I. A., & Hajmeer, M. Artificial neural networks: Fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 2000, 43(1), pp 3-31. doi:10.1016/S0167-7012(00)00201-3.
- [5] Çelik, G., Baykan, Ö., Kara, Y., & Tireli, H. Predicting 10-day mortality in patients with strokes using neural networks and multivariate statistical methods. *Journal of Stroke and Cerebrovascular Diseases*, 23(6), 2014, pp 1506-1512, doi:10.1016/j.jstrokecerebrovasdis.2013.12.018.
- [6] Liu, Q., Cui, X., Abbod, M., Huang, S., Han, Y., & Shieh, J. Brain death prediction based on ensembled artificial neural networks in neurosurgical intensive care unit. *Journal of the Taiwan Institute of Chemical Engineers*, 42(1), 2011, pp 97-107, doi:10.1016/j.jtice.2010.05.006.
- [7] Gil, D., Johnsson, M., Garcia C, J., Soriano P, A., & Ruiz F, D. Application of artificial neural networks in the diagnosis of urological dysfunctions. *Expert Systems with Applications*, 36(3, Part 2), 2009, pp 5754-5760. doi:10.1016/j.eswa.2008.06.065.
- [8] Dombi, GW., Rosbolt, JP., & Severson, RK.. Neural network analysis of employment history as a risk factor for prostate cancer. *Computers in Biology and Medicine*, 40(9), 2010, pp 751-757. doi:10.1016/j.combiomed.2010.07.002.
- [9] Patel, M., Lal, S. K. L., Kavanagh, D., & Rossiter, P. Applying neural network analysis on heart rate variability data to assess driver fatigue. *Expert Systems with Applications*, 38(6), 2011, pp 7235-7242. doi:10.1016/j.eswa.2010.12.028.
- [10] Rajeswari, K., Vaithyanathan, V., & Neelakantan, T. R. Feature selection in ischemic heart disease identification using feed forward neural networks. *Procedia Engineering*, 41(0), 2012, pp 1818-1823. doi:10.1016/j.proeng.2012.08.109.
- [11] Arena, R., Myers, J., de Souza, C., Borghi, A., Guazzi, M., Chase, P., Forman, D. A neural network approach to predicting outcomes in heart failure using cardiopulmonary exercise testing. *Journal of the American College of Cardiology*, 61(10, Supplement), 2013, E1415. doi:10.1016/S0735-1097(13)61415-1.
- [12] Özbay, Y., & Tezel, G. A new method for classification of ECG arrhythmias using neural network with adaptive activation function. *Digital Signal Processing*, 20(4), 2010, pp 1040-1049. doi:10.1016/j.dsp.2009.10.016.
- [13] Bhatikar, S., DeGross, C., & Mahajan, R. A classifier based on the artificial neural network approach for cardiologic auscultation in pediatrics. *Artificial Intelligence in Medicine*, 33(3), 2005, pp 251-260. doi:10.1016/j.artmed.2004.07.008.
- [14] Vanisree K, Jyothi, S. Decision Support System for Congenital Heart Disease, Diagnosis based on Signs and Symptoms using, Neural Networks. *International Journal of Computer Applications*, 2011, (0975 8887), Volume 19.
- [15] Al-Milly, N. Backpropagation neural network for prediction of heart disease. *Journal of Theoretical and Applied Information Technology*, 56(1), 2013, pp 131-135.
- [16] Das, R., Turkoglu, I., & Sengur, A. Effective diagnosis of heart disease through neural networks ensembles. *Expert Systems with Applications*, 36(4), 2009, pp 7675-7680. doi:10.1016/j.eswa.2008.09.013
- [17] Eggers, K., Ellenius, J., Dellborg, M., Groth, T., Oldgren, J., Swahn, E., & Lindahl, B. Artificial neural network algorithms for early diagnosis of acute myocardial infarction and prediction of infarct size in chest pain patients. *International Journal of Cardiology*, 114(3), (2007), pp 366-374. doi:10.1016/j.ijcard.2005.12.019
- [18] Dietzel, M., Baltzer P, A., Dietzel, A., Zoubi, R., Gröschel, T., Burmeister, H., Kaiser, W. Artificial neural networks for differential diagnosis of breast lesions in MR-mammography: A systematic approach addressing the influence of network architecture on diagnostic performance using a large clinical database. *European Journal of Radiology*, 81(7), 2012, pp 1508-1513. doi:10.1016/j.ejrad.2011.03.024.
- [19] Rumelhart, DE. Hinton, GE, & Williams, RJ. In Rumelhart DE, McClelland JL. (Eds.), *Learning internal representations by error propagation* (1st ed.). Cambridge: MIT press. 1986.
- [20] Ince, T., Kiranyaz, S., Pulkkinen, J., & Gabbouj, M. Evaluation of global and local training techniques over feed-forward neural network architecture spaces for computer-aided medical diagnosis. *Expert Systems with Applications*, 37(12), 2010, pp 8450-8461. doi:10.1016/j.eswa.2010.05.033.
- [21] Witten, I., & Frank, E. *Data mining: Practical machine learning tools and technique*, In Morgan K. (Ed.), 2nd ed, 2005, London: Elsevier.
- [22] Hanley J.A., McNeil B.J. A method of comparing the areas under receiver operating characteristic curves derived from the same cases. *Radiology*, 1983, 148: pp 839-43.