

# Evaluación del riesgo cardiovascular a través de una red neuronal

## Utilizando datos de la composición corporal

Cardiovascular risk assessment through a neuronal network: Using body composition data



Aura Catalina **Zea Robles**  
Henry Humberto **León Ariza**  
Daniel Alfonso **Botero Rosas**



MCT Volumen 14 #2 Julio-Diciembre

# MCT

# Movimiento Científico

ISSN-I: 2011-7191 | e-ISSN: 2463-2236

Publicación Semestral

Title: Cardiovascular risk assessment through a neuronal network

Subtitle: Using body composition data

Título: Evaluación del riesgo cardiovascular a través de una red neuronal

Subtítulo: Utilizando datos de la composición corporal

Alt Title / Título alternativo:

[en]: Cardiovascular risk assessment through a neuronal network using body composition data

[es]: Evaluación del riesgo cardiovascular a través de una red neuronal utilizando datos de la composición corporal

Author (s) / Autor (es):

Zea Robles, León Ariza & Botero Rosas

Keywords / Palabras Clave:

[en]: Artificial Intelligence, Risk factors, Body composition, cardiovascular disease.

[es]: Inteligencia artificial, Factores de riesgo, Composición corporal, Enfermedad cardiovascular.

Submitted: 2020-10-05

Accepted: 2021-04-17

## Resumen

Introducción: La enfermedad cardiovascular (ECV), es la principal causa de morbimortalidad en el mundo, y de forma continua se buscan estrategias para su diagnóstico temprano, que sean lo suficientemente sensibles y específicas para utilizarse de forma masiva. Objetivo: Presentar una propuesta de red neuronal artificial (RNA), para la predicción del riesgo cardiovascular utilizando variables antropométricas, edad y hábitos. Métodos: Se analizaron 256 sujetos entre 16 y 60 años, la RNA se alimentó con las variables: edad, género, tabaquismo, % grasa, grasa visceral y % de masa muscular, el entrenamiento de la red se hizo con 183 sujetos (69%) teniendo en cuenta como variables de salida la probabilidad de ECV pronosticada a 10 años a través de la evaluación del riesgo cardiovascular utilizando las guías Intercolegiadas británicas (ASSIGN), clasificando esta como Riesgo alto > 10%, Riesgo moderado 5 – 10%, Riesgo bajo 1 – 4,9% y muy bajo < 1%. Resultados: El modelo demostró diferencias significativas en las características de química sanguínea y de composición corporal entre los grupos  $p < 0,0001$ . El área bajo la curva para la predicción fue: Riesgo alto = 0,999, Riesgo moderado = 0,967, Riesgo bajo = 0,986, riesgo muy bajo = 0,981. Con una sensibilidad que oscila según el riesgo entre 0,750 y 1,000 y una especificidad entre 0,833 y 1,000. Conclusión: Una RNA que utilice la composición corporal como variable de predicción de riesgo cardiovascular presenta un alto valor predictivo comparado con la escala ASSIGN, pudiendo ser una herramienta valiosa para la estimación del riesgo cardiovascular, aplicable al cribado en diversas poblaciones.

## Citar como:

Zea Robles, A. C., León Ariza, H. H., & Botero Rosas, D. A. (2020). Evaluación del riesgo cardiovascular a través de una red neuronal: Utilizando datos de la composición corporal. *Movimiento Científico*, 14 (2), 83-90. Obtenido de: <https://revmovimientocientifico.iberu.edu.co/article/view/mct.14209>

## Abstract

Introduction: The cardiovascular disease (CVD) is the main world cause of morbidity and mortality, continually, are searching early diagnostic strategies with enough sensibility and specificity to be used massively in the population. Objective: To develop a proposal of artificial neural network (ANN), to predict the cardiovascular risk using anthropometric variables, age, and habits. Methods: 256 subjects were analyze, aged 16 to 60 years old, the ANN was feed with the variables: age, gender, smoking, fat percentage, visceral fat and muscular percentage, the ANN training was made with 183 subjects (69%), the output variable was the CVD probability to ten years prognosticated using Assessing cardiovascular risk using SIGN guidelines (ASSIGN) scale, the classification was high risk > 10%, moderate risk 5 – 10%, low risk 1 – 4,9%, very low risk < 1%. Results: The model show significate differences in the blood chemical variables and the body composition between groups  $p < 0.0001$ . The Area under the curve for the prediction was: High risk = 0.999, Moderate risk = 0.967, low risk = 0.986, very low risk = 0.981. The sensitivity according to risk was between 0.750 y 1.000 and specificity was between 0.833 and 1.000. Conclusion: An ANN that uses as prediction body composition variables have a high predictive value, compared by ASSIGN scale, could be a good tool for the cardiovascular risk estimation applicable on the screening in different populations

Aura Catalina **Zea Robles**, MSc Ft.

ORCID: [0000-0001-8690-8930](https://orcid.org/0000-0001-8690-8930)

Source | Filiación:  
Universidad Santo Tomás

BIO:  
Magister en Fisioterapia del Deporte y la Actividad Física  
Fisioterapeuta. Universidad Nacional de Colombia  
Profesional en ciencias del deporte.  
Universidad de Ciencias Aplicadas y Ambientales.

City | Ciudad:  
Bogotá DC [co]

e-mail:  
[aurazea@usantotomas.edu.co](mailto:aurazea@usantotomas.edu.co)

Henry Humberto **León Ariza**, Phd Md.

ORCID: [0000-0002-5557-2060](https://orcid.org/0000-0002-5557-2060)

Source | Filiación:  
Universidad de la Sabana

BIO:  
Docente. U. Sabana. Facultad de Medicina, médico, licenciado en Educación Física y doctor en Biociencias,

City | Ciudad:  
Bogotá DC [co]

e-mail:  
[henrylear@clinicaunisabana.edu.co](mailto:henrylear@clinicaunisabana.edu.co)

Daniel Alfonso **Botero Rosas**, Phd Msc Md.

ORCID: [0000-0002-2590-0756](https://orcid.org/0000-0002-2590-0756)

Source | Filiación:  
Universidad de la Sabana

BIO:  
Doctorado (UFRJ) Engenharia Biomédica  
Maestría/Magister (UFRJ) Engenharia Biomédica  
Especialización Universidad Estacio de Sa Anatomia Humana  
Pregrado/Universitario Escuela Colombiana De Medicina medicina

City | Ciudad:  
Bogotá DC [co]

e-mail:  
[Daniel.botero@unisabana.edu.co](mailto:Daniel.botero@unisabana.edu.co)

# Evaluación del riesgo cardiovascular a través de una red neuronal

## Utilizando datos de la composición corporal

Cardiovascular risk assessment through a neuronal network: Using body composition data

Aura Catalina **Zea Robles**

Henry Humberto **León Ariza**

Daniel Alfonso **Botero Rosas**

## Introducción

En la actualidad las enfermedades cardiovasculares (ECV) constituyen una de las causas más importantes de discapacidad y muerte prematura en todo el mundo, incluyen la cardiopatía coronaria (CC) y los accidentes cerebrovasculares (ACV) siendo su origen común la aterosclerosis (*Barquera, y otros, 2015*). En el año 2015, 17,7 millones de personas murieron por ECV, lo que es equivalente al 31% de todas las muertes registradas en el mundo, 7,4 millones de esas muertes se debieron a CC y 6,7 millones a ACV (*Al-Mawali, 2015*).

En Colombia, entre el año 2005 y 2013, la principal causa de mortalidad fue dada por las enfermedades del aparato circulatorio con una incidencia de 146,16 muertes/100.000 habitantes, superando a las de causa externa (homicidios, suicidios y accidentes de transporte) (*Piepoli, y otros, 2016*). Esta situación por lo tanto obliga a fortalecer los programas de detección y prevención temprana de la enfermedad.



Para determinar el riesgo cardiovascular se utilizan comúnmente métodos cualitativos, estos se basan en la suma de factores de riesgo o la medición de su nivel y clasifican al individuo en: riesgo leve, moderado, alto y muy alto; y los cuantitativos, por su parte, están basados en ecuaciones de predicción de riesgo dando un valor, que corresponde a la probabilidad de presentar un evento cardiovascular en un determinado tiempo. Las formas de cálculo utilizadas requieren de programas informáticos o de tablas de riesgo, las cuales constituyen una herramienta de enorme utilidad para la toma de decisiones en la práctica clínica (Amato, y otros, 2013). Se ha establecido que existen múltiples factores de riesgo para el desarrollo de ECV, dentro de los que se encuentran; dislipidemias, la hipertensión arterial, sedentarismo, tabaquismo, obesidad entre muchos otros (Piepoli, y otros, 2016).

Una alternativa de evaluación en múltiples ámbitos está dada por el desarrollo de redes neuronales artificiales (RNA), estas se basan en algoritmos de cálculo matemático que son denominados de esta forma porque su comportamiento se asemeja a la actividad del sistema nervioso, utilizan “neuronas” que se organizan a través de capas: un conjunto de neuronas de entrada, una serie de capas ocultas y un grupo de neuronas de salida que corresponden al resultado, una de las ventajas que representa una RNA es que tiene la capacidad de “aprender” a partir de patrones de asociación, los cuales son utilizados posteriormente en el proceso de validación (Amato, y otros, 2013).

Las RNA se utilizan en múltiples escenarios, de manera específica en Medicina cardiovascular se han desarrollado diversos trabajos que incluyen RNA para establecer el grado de disfunción cardiovascular autonómica (Tang, y otros, 2013), la predicción de mortalidad en cirugía cardíaca (Nilsson, y otros, 2006), la probabilidad de desarrollar enfermedades congénitas basadas en factores de riesgo (Li, y otros, 2017), y en el diagnóstico de Infarto agudo de miocardio a partir de cambios electrocardiográficos y enzimas (Sprockel, Diaztagle, Alzate, & González, 2014).

Dado el potencial de diagnóstico que representan en la actualidad las RNA, el objetivo de este trabajo es presentar una propuesta de evaluación y predicción de la ECV (prueba de concepto), que alimentada con datos de composición corporal, edad y tabaquismo, constituya una alternativa económica, rápida y confiable en el screening de poblaciones donde el acceso a pruebas de laboratorio sea limitado.

## Materiales y métodos

Este trabajo corresponde a un estudio descriptivo transversal, analítico y predictivo a partir de variables de riesgo cardiovascular y composición corporal, en el cual se utiliza para la predicción una RNA.

## Población de estudio

Entre 2013 y 2018 se desarrollaron evaluaciones clínicas y paraclínicas en una población de estudiantes y docentes de la Universidad Santo Tomás, se evaluaron 265 sujetos (153 hombres y 112 mujeres) con edades entre 16 y 60 años, en la población se evaluó: Antecedentes

familiares, farmacológicos y de enfermedad actual; evaluación antropométrica: Presión arterial (sistólica y diastólica), peso, talla, índice de masa corporal, y mediante bioimpedancia: porcentaje de grasa, porcentaje de masa muscular y grasa visceral. A través de una muestra de sangre venosa pre-prandial se evaluó la concentración plasmática de glucosa, Colesterol Total, Colesterol HDL, Colesterol LDL y Triglicéridos. A pesar de contar con múltiples variables especialmente asociadas a los antecedentes, el carácter transversal de la investigación limitó el estudio a los resultados encontrados el día de la evaluación.

La toma de la presión arterial sistólica (PAS) y diastólica (PAD), se realizó por parte de un médico luego de un periodo de descanso de 15 minutos, para este se utilizó un esfigmomanómetro aneróide (Modelo Dura shock DS44, Welch Allyn, New York, EEUU), para la evaluación de la composición corporal se utilizó un equipo de bioimpedancia tetrapolar (Modelo HBF-510, Omron, Tokyo, Japan) corriente de 500µA y frecuencia de 50kHz. Las muestras sanguíneas se tomaron tras un ayuno no inferior a 8 horas, para el análisis de las variables de química sanguínea se utilizó suero sanguíneo y el análisis se hizo mediante espectrofotometría.

## Evaluación del riesgo cardiovascular

La evaluación del riesgo cardiovascular se realizó mediante la evaluación de los signos (assessment sign – ASSIGN), el cual evalúa: la edad, antecedente familiar de enfermedad cardiovascular o accidente cerebro vascular, presencia de diabetes, tabaquismo, presión arterial sistólica, colesterol total y colesterol HDL, el resultado corresponde a la probabilidad expresada en porcentaje de sufrir de enfermedad cardiovascular en 10 años, de acuerdo a los resultados se generaron 4 categorías: Riesgo alto > 10%, Riesgo moderado 5 – 10%, Riesgo bajo 1 – 4,9% y muy bajo < 1% (Woodward, Brindle, & Tunstall-Pedoe, 2007).

## Red Neuronal

Un conjunto de redes neuronales (RN) supervisadas fueron implementadas, a partir de seis entradas (género, tabaquismo, edad, grasa total, porcentaje de grasa visceral y porcentaje de músculo), se utilizó un ensayo de tipo prueba – error para establecer el número de capas ocultas. Se probaron redes con 6, 8, 10 y 12 capas ocultas, evitando un número pequeño de capas por el riesgo de subajuste de los datos (underfitting) y un número elevado de estas por el riesgo de sobreajuste de los datos (overfitting), encontrándose el mejor rendimiento de la red a partir de un perceptrón multi-capas (multi-layer perceptron, MLP) con aprendizaje por retropropagación del error (Backpropagation), con seis entradas y ocho neuronas (H1 hasta H8) con función tangente hiperbólica en la capa oculta. Una neurona con la función de activación Softmax para cada estadio de la clasificación ASSIGN (alto, moderado, bajo y muy bajo) fue implementada en la capa de salida (Gráfico 1). El entrenamiento de la RN fue realizado con 183 sujetos (69%) y su validación con los 82 restantes (31%). Seguidamente, la sensibilidad, la especificidad, el valor predictivo positivo (VPP) y el valor predictivo negativo (VPN) fueron obtenidos para evaluar la eficiencia de la RN.




Gráfico 1 Esquema de la red desarrollada para evaluar el riesgo cardiovascular (Elaboración propia).

## Análisis estadístico

Para el análisis estadístico se utilizó el paquete estadístico IBM SPSS 23.0, la diferencia entre los grupos se determinó mediante un análisis de varianzas ANOVA y la red neuronal se implementó utilizando la opción de perceptrón multicapa del paquete estadístico referenciado. La significancia fue considerada a partir de un valor  $p < 0,05$ . Los valores de sensibilidad, especificidad, VPP y VPN se obtuvieron a partir de tablas de contingencia 2 x 2.

El proceso de recolección de la información fue autorizado por el Comité de Ética institucional para la investigación de la Universidad Santo Tomás, mediante el acta 07 del 2018 expedida el 23 de mayo, para el inicio formal de la investigación.

El diseño e implementación de la investigación se basó en las consideraciones éticas de la Declaración de Helsinki y la Resolución No. 008430 del Ministerio de Salud de Colombia, de 1993. Esta investigación, es considerada de mínimo riesgo para la población

evaluada, debido a que empleó registros de datos descriptivos, además de no realizar algún tipo de intervención clínica. Sin embargo, se solicitó consentimiento informado a cada uno de los participantes en el estudio.

## Resultados

La composición corporal y los factores de riesgo cardiovascular de 265 sujetos fueron obtenidos para posterior clasificación de acuerdo con el porcentaje de riesgo a 10 años según el ASSIGN. Se encontraron diferencias significativas entre los grupos de análisis para las variables relacionadas con el riesgo cardiovascular. Los datos de edad, concentración de triglicéridos y el porcentaje de tejido adiposo visceral fueron directamente proporcionales a la clasificación de riesgo; otras variables como la PAS y LDL fueron más altas en la población clasificada como moderada (Tabla 1).

Tabla 1. Características generales de la población, clasificados por el nivel de riesgo cardiovascular. Datos expresados en promedio  $\pm$  Desviación Estándar.

	Alto > 10% Mujeres = 1 Hombres = 7	Moderado 5 - 10% Mujeres = 3 Hombres = 15	Bajo 1 - 4,9% Mujeres = 10 Hombres = 83	Muy bajo < 1% Mujeres = 98 Hombres = 48	p
Edad (años)	60,0 $\pm$ (2,6)	48,7 $\pm$ (5,4)	28,7 $\pm$ (9,0)	19,0 $\pm$ (3,1)	<0,001b
PAS (mmHg)	108,8 $\pm$ (7,9)	111,0 $\pm$ (13,9)	105,9 $\pm$ (11,0)	98,0 $\pm$ (8,8)	<0,001 b
PAD (mmHg)	67,5 $\pm$ (11,6)	67,0 $\pm$ (11,4)	69,3 $\pm$ (12,0)	64,2 $\pm$ (7,8)	0,001 b
Glucosa (mg/dl)	82,9 $\pm$ (11,3)	82,3 $\pm$ (7,4)	87,7 $\pm$ (11,4)	93,8 $\pm$ (8,7)	<0,001 b
C-total (mg/dl)	208,5 $\pm$ (37,2)	246,1 $\pm$ (42,6)	190,6 $\pm$ (29,7)	156,1 $\pm$ (30,7)	<0,001 b
Trig (mg/dl)	248,1 $\pm$ (146,6)	218,3 $\pm$ (102,4)	142,5 $\pm$ (50,4)	124,3 $\pm$ (29,3)	<0,001 b
C-HDL (mg/dl)	48,6 $\pm$ (10,9)	51,3 $\pm$ (8,7)	45,6 $\pm$ (10,5)	43,3 $\pm$ (9,4)	0,005 b
C-LDL (mg/dl)	110,3 $\pm$ (35,6)	151,1 $\pm$ (45,7)	118,1 $\pm$ (25,3)	92,7 $\pm$ (28,1)	<0,001 b
Tabaquismo (%)	25,0%	33,3%	33,3%	16,4%	0,019a
ASSIGN (%)	11,3 $\pm$ (1,2)	7,1 $\pm$ (1,3)	2,0 $\pm$ (1,0)	0,5 $\pm$ (0,2)	<0,001 b
Grasa (%)	28,9 $\pm$ (9,0)	29,2 $\pm$ (7,4)	25,4 $\pm$ (7,4)	29,5 $\pm$ (10,4)	0,011a
Visceral (%)	12,9 $\pm$ (6,2)	10,9 $\pm$ (2,9)	7,3 $\pm$ (3,0)	4,1 $\pm$ (1,6)	<0,001 b
Músculo (%)	31,4 $\pm$ (4,5)	32,2 $\pm$ (4,1)	36,1 $\pm$ (5,1)	30,7 $\pm$ (8,1)	<0,001 b

a =  $p < 0,05$ , b =  $p < 0,01$ , PAS = Presión Arterial Sistólica, PAD = Presión Arterial Diastólica, C-total = Colesterol Total, Trig = Triglicéridos, C-HDL = Colesterol HDL, C-LDL = Colesterol LDL.

Fuente: Elaboración propia.

## Evaluación del riesgo cardiovascular a través de una red neuronal

Utilizando datos de la composición corporal

Para el desarrollo del modelo éste se entrenó con el 69% de los datos, y la validación del modelo se desarrolló en el restante 31%, la RNA demostró una alta Sensibilidad y Especificidad para la predicción de riesgo cardiovascular alto, valores ligeramente

inferiores para la predicción de riesgo moderado, bajo y muy bajo. La sensibilidad, especificidad, Valor Predictivo Positivo (VPP), Valor Predictivo Negativo (VPN) y Área bajo la curva ROC (ABC-ROC), se encuentran en la Tabla 2 y la curva ROC en la Gráfico 2.

Tabla 2. Resultados de la Validación del modelo.

	ALTO	MODERADO	BAJO	MUY BAJO
Sensibilidad	1,000	1,000	0,750	0,885
Especificidad	1,000	0,987	1,000	0,833
VPP	1,000	0,750	1,000	0,902
VPN	1,000	1,000	0,929	0,806
ABC-ROC	0,999	0,967	0,986	0,981

VPP = Valor Predictivo Positivo, VPN = Valor Predictivo Negativo, ABC = Área bajo la curva de la curva ROC.

Fuente:Elaboración propia.

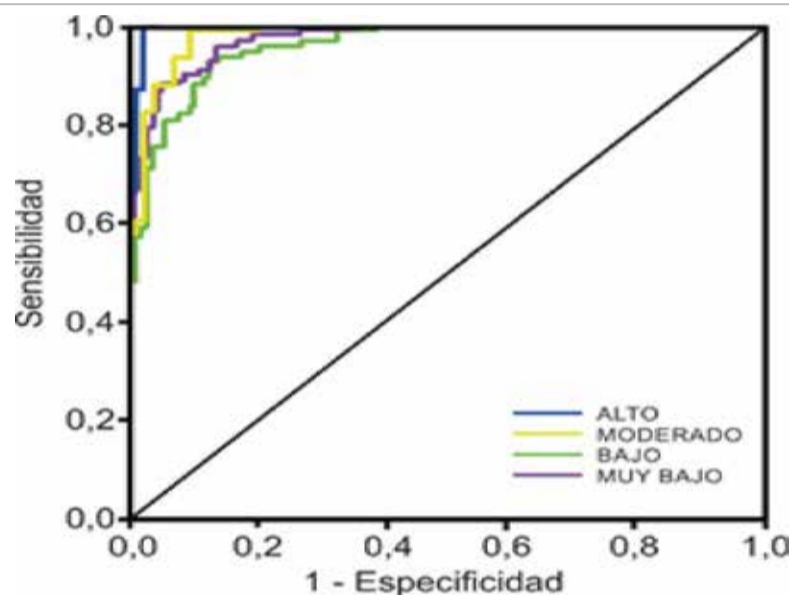


Gráfico 2 Curva ROC (Receiver Operating Characteristic) de la evaluación del modelo. (Elaboración propia).

## Discusión y conclusiones

La evaluación del riesgo cardiovascular tiene como propósito fundamental la prevención. De forma que a partir de datos de probabilidad se puedan tomar las medidas necesarias para evitar la enfermedad y las implicaciones patológicas, económicas y sociales entre otras que de estas se puedan derivar (Sanz, 2007). En la actualidad se desarrollan múltiples investigaciones con el objetivo de descubrir marcadores bioquímicos con los cuales hacer un diagnóstico lo más prematuro posible y a la vez que sea lo suficientemente sensible y específico para detectar casos de enfermedad cardiovascular durante la fase subclínica (Thomas & Lip, 2017).

Hay varias razones por las cuales la evaluación de riesgo cardiovascular no es masivamente utilizada, entre ellos están: muchas de las escalas de evaluación han sido desarrolladas en poblaciones específicas, con resultados que no siempre se relacionan con la realidad del país, la dificultad para evaluar variables bioquímicas en grandes grupos poblacionales y el difícil acceso especialmente por costos de las pruebas más sensibles (Lobos Bejarano & Brotons Cuixart, 2011).

De otra parte la evaluación del riesgo cardiovascular usualmente se ha planteado para adultos, sin embargo, en la actualidad se ha sugerido la necesidad de la evaluación de factores de riesgo como la presión arterial elevada, dislipidemia, diabetes y hábitos como el tabaquismo en niños y jóvenes con miras a evitar la Enfermedad cerebro vascular en adultos (Bloetzer, y otros, 2015).

Estudios previos han demostrado la presencia de factores de

riesgo en población adolescente, Khoury y colaboradores evaluaron más de 4000 niños entre 14 y 15 años en Canadá encontrando dislipidemia 4,7%, 9,5% obesidad, y 3,5% Hipertensión (Khoury, y otros, 2016), en Colombia nuestro grupo de investigación encontró que en una población joven (16 a 26 años) existen criterios para el diagnóstico de síndrome metabólico en 12,1% de los hombres y 21,3% de las mujeres (Zea-Robles, León-Ariza, Botero-Rosas, Afanador-Castañeda, & Pinzón-Bravo, 2014).

Existen varias escalas para la evaluación del riesgo cardiovascular que se basan en factores como la edad, el género, el comportamiento de lípidos sanguíneos, presión arterial; factores de riesgo no modificables como los antecedentes patológicos y familiares, algunos modificables como el tabaquismo, el sedentarismo y el estrés entre otros (Cooney, Dudina, & Graham, 2009), dentro de estas escalas el ASSING ha demostrado tener una mejor sensibilidad comparado con el Framingham (Tunstall-Pedoe & Woodward, 2006).

A pesar de que la composición corporal, especialmente el porcentaje de grasa total y la grasa visceral se han relacionado con un mayor riesgo cardiovascular (Liu, y otros, 2010), y que de manera reciente también el porcentaje de masa muscular especialmente en hombres también está asociado a un mayor riesgo a 10 años (Lee, 2017), estos parámetros de composición corporal no hacen parte de las escalas de riesgo cardiovascular.

En la actualidad los modelos de predicción de riesgo basados en sistemas entrenables computarizados como las redes neuronales artificiales (RNA) han demostrado mejorar en una alta proporción la evaluación del riesgo cardiovascular (Weng, Reys, Kai, Garibaldi, & Qureshi, 2017), trabajos previos han utilizado las variables clásicas para la predicción de enfermedad cardíaca utilizando una RNA



## REFERENCIAS

- Al-Mawali, A. (2015). Non-Communicable Diseases: Shining a Light on Cardiovascular Disease, Oman's Biggest Killer. (4), 227-228. doi:<https://doi.org/10.5001/omj.2015.47>
- Amato, F., López, A., Peña-Méndez, E. M., Vañhara, P., Hampl, A., & Havel, J. (2013). Artificial neural networks in medical diagnosis. (2), 47-58. doi:<https://doi.org/10.2478/v10136-012-0031-x>
- Awang, M. K., Siraj, F., & Terengganu, K. (2013). Utilization of an Artificial Neural Network in the Prediction of Heart Disease 2 . Literature Review. (4), 159-166. Obtenido de [https://www.researchgate.net/publication/298468496\\_Utilization\\_of\\_an\\_artificial\\_neural\\_network\\_in\\_the\\_prediction\\_of\\_heart\\_disease](https://www.researchgate.net/publication/298468496_Utilization_of_an_artificial_neural_network_in_the_prediction_of_heart_disease)
- Barquera, S., Pedroza-Tobías, A., Medina, C., Hernández-Barrera, L., Bibbins-Domingo, K., Lozano, R., & Moran, A. E. (2015). Global Overview of the Epidemiology of Atherosclerotic Cardiovascular Disease. (5), 328-338. doi:<https://doi.org/10.1016/j.arcmed.2015.06.006>
- Bloetzer, C., Bovet, P., Suris, J.-C., Simeoni, U., Paradis, G., & Chiolero, A. (2015). Screening for cardiovascular disease risk factors beginning in childhood. (9). doi:<https://doi.org/10.1186/s40985-015-0011-2>
- Cooney, M. T., Dudina, A. L., & Graham, I. M. (29 de Septiembre de 2009). Value and Limitations of Existing Scores for the Assessment of Cardiovascular Risk: A Review for Clinicians. (14), 1209-1227. doi:<https://doi.org/10.1016/j.jacc.2009.07.020>
- Khoury, M., Manliot, C., Gibson, D., Chahal, N., Stearne, K., Dobbin, S., & McCrindle, B. W. (Enero de 2016). Universal screening for cardiovascular disease risk factors in adolescents to identify high-risk families: a population-based cross-sectional study. (11). doi:<https://doi.org/10.1186/s12887-016-0548-3>
- Lee, K. (2017). Muscle Mass and Body Fat in Relation to Cardiovascular Risk Estimation and Lipid-Lowering Eligibility. (2), 247-255. doi:<https://doi.org/10.1016/j.jocd.2016.07.009>
- Li, H., Luo, M., Zheng, J., Luo, J., Zeng, R., Feng, N., . . . Fang, J. (Febrero de 2017). An artificial neural network prediction model of congenital heart disease based on risk factors. A hospital-based case-control study. (6), e6090. doi:<https://doi.org/10.1097/MD.0000000000006090>
- Liu, J., Fox, C. S., Hickson, D. A., May, W. D., Hairston, K. G., Carr, J. J., & Taylor, H. A. (Diciembre de 2010). Impact of Abdominal Visceral and Subcutaneous Adipose Tissue on Cardiometabolic Risk Factors: The Jackson Heart Study. (12), 5419-5426. doi:<https://doi.org/10.1210/jc.2010-1378>
- Liu, J., Tang, Z.-H., Zeng, F., Li, Z., & Zhou, L. (2013). Artificial neural network models for prediction of cardiovascular autonomic dysfunction in general Chinese population. (80). doi:<https://doi.org/10.1186/1472-6947-13-80>
- Lobos Bejarano, J. M., & Brotons Cuixart, C. (Diciembre de 2011). Factores de riesgo cardiovascular y atención primaria: evaluación e intervención. (12), 668-677. doi:<https://doi.org/10.1016/j.aprim.2011.10.002>
- Narain, R., Saxena, S., & Goyal, A. K. (2016). Cardiovascular risk prediction: a comparative study of Framingham and quantum neural network based approach. , 1259-1270. doi:<https://doi.org/10.2147/PPA.S108203>
- Nilsson, J., Ohlsson, M., Thulin, L., Höglund, P., Nashef, S. A., & Brandt, J. (Julio de 2006). Risk factor identification and mortality prediction in cardiac surgery using artificial neural networks. (1), 12-19. doi:<https://doi.org/10.1016/j.jtcvs.2005.12.055>
- Piepoli, M. F., Hoes, A. W., Agewall, S., Albus, C., Brotons, C., Catapano, A. L., . . . ESC Scientific Document Group. (Agosto de 2016). 2016 European Guidelines on cardiovascular disease prevention in clinical practice: The Sixth Joint Task Force of the European Society of Cardiology and Other Societies on Cardiovascular Disease Prevention in Clinical Practice. (29), 2315-2381. doi:<https://doi.org/10.1093/eurheartj/ehw106>
- Sanz, G. A. (Octubre de 2007). Estratificación del riesgo en los síndromes coronarios agudos: un problema no resuelto. (Supl. 3), 23-30. Obtenido de <http://www.revespcardiolog.es/content/articulo/13113980/>
- Sprockel, J. J., Diaztagle, J. J., Alzate, W., & González, E. (2014). Redes neuronales en el diagnóstico del infarto agudo de miocardio. (4), 215-223. doi: <https://doi.org/10.1016/j.rccar.2013.10.001>
- Tang, Z.-H., Liu, J., Zeng, F., Li, Z., Yu, X., & Zhou, L. (2013). Comparison of Prediction Model for Cardiovascular Autonomic Dysfunction Using Artificial Neural Network and Logistic Regression Analysis. (8), e70571. doi:<https://doi.org/10.1371/journal.pone.0070571>

que incluía variables como edad, historia familiar, tabaquismo, Colesterol, Hipertensión y diabetes, encontrando una predicción del 88.89% (Awang, Siraj, & Terengganu, 2013), de forma reciente un estudio realizado con pacientes con ECV, validado a través de la escala de Framingham demostró una exactitud del 98.57% utilizando la edad, sexo, tabaquismo C-HDL PAS C-Total y el consumo de medicamentos (Narain, Saxena, & Goyal, 2016).

En relación con la composición corporal, una RNA además de variables clásicas de riesgo cardiovascular utilizó el índice de masa corporal y perímetro abdominal, alcanzando una sensibilidad del 75,51% y una especificidad del 66,50% (Liu, Tang, Zeng, Li, & Zhou, 2013), lo cual sugiere que efectivamente la composición corporal está asociada a la predicción de riesgo.

Aunque el modelo desarrollado es altamente sensible y específico para la predicción del riesgo cardiovascular, este se contrastó con una escala que de igual manera permite un margen de error, lo que sugiere que dicho error de la escala se traslada a la red, sin embargo, el aporte principal de este trabajo está en el hecho de que es posible obtener el mismo resultado de la escala sin tener en cuenta variables como las originadas a partir de la química sanguínea.

A corto plazo la red neuronal va a ser utilizada para el desarrollo de una aplicación con la cual se espera evaluar el RCV en un grupo amplio de personas, a mediano plazo se espera ampliar la población con miras a mejorar aún más la sensibilidad y la especificidad de la RNA y a largo plazo alimentar la red con el desenlace real.

## Agradecimientos

A la unidad de investigación y al Departamento de Humanidades y formación Integral de la Universidad Santo Tomás. A los docentes; Astrid Yamile Rodríguez, Diana Paola Sáenz y Fredy Camilo Triana, por su colaboración en la toma de datos y tabulación de las variables.

## Declaración de Fuentes de Financiación

Este proyecto se desarrolló con la ayuda económica del fondo para el desarrollo de la Investigación de la Universidad Santo Tomás, (FODEIN convocatoria interna 2018 - 2019).

## Declaración de conflictos de intereses

Los autores no tienen conflicto de intereses.

## Evaluación del riesgo cardiovascular a través de una red neuronal

Utilizando datos de la composición corporal

Thomas, M. R., & Lip, G. Y. (2017). Novel Risk Markers and Risk Assessments for Cardiovascular Disease. (1), 133–149. doi:<https://doi.org/10.1161/CIRCRESAHA.116.309955>

Tunstall-Pedoe, H., & Woodward, M. (2006). By neglecting deprivation, cardiovascular risk scoring will exacerbate social gradients in disease. (3), 307-310. doi: <https://doi.org/10.1136/hrt.2005.077289>

Weng, S. F., Reys, J., Kai, J., Garibaldi, J. M., & Qureshi, N. (Abril de 2017). Can machine-learning improve cardiovascular risk prediction using routine clinical data? (4), e0174944. doi:<https://doi.org/10.1371/journal.pone.0174944>

Woodward, M., Brindle, P., & Tunstall-Pedoe, H. (Febrero de 2007). Adding social deprivation and family history to cardiovascular risk assessment: the ASSIGN score from the Scottish Heart Health Extended Cohort (SHHEC). (2), 172-176. doi:<https://doi.org/10.1136/hrt.2006.108167>

Zea-Robles, A. C., León-Ariza, H. H., Botero-Rosas, D. A., Afanador-Castañeda, H. D., & Pinzón-Bravo, L. A. (2014). Factores de riesgo cardiovascular y su relación con la composición corporal en estudiantes universitarios. (4), 505-515. doi:<https://doi.org/10.15446/rsap.v16n4.38878>