

Machine learning y el control de hipertensión arterial

Laura Alejandra Campos Rodríguez* / Daniel Julián Sánchez Álvarez** / Alexandra Abuchar Porras***

Resumen

El uso de la tecnología ha promovido la expansión digital y el crecimiento de herramientas que hacen posible la cuantificación, medición y análisis de los datos. También ha permitido que tecnologías como la inteligencia artificial desarrollen algoritmos y modelos para que las computadoras aprendan y mejoren sus procesos por medio de la experiencia. En este contexto, el *machine learning* se ha convertido en un aliado en el control de enfermedades crónicas como la hipertensión arterial (HTA), que causa el 63 % de las muertes de personas de tercera edad, debido a falencias en adherencia a tratamientos y a los estilos de vida de los pacientes. En este artículo se propone que implementar esta tecnología en el seguimiento del tratamiento de la HTA podrá suministrar pronósticos de la condición futura del paciente y evidenciar el avance o la necesidad de un nuevo diagnóstico para mejorar su calidad de vida.

Abstract

The use of technology has promoted digital expansion and the growth of tools that enable the quantification, measurement and analysis of data. It has also allowed technologies such as artificial intelligence to develop algorithms and models for computers to learn and improve their processes through experience. In this context, machine learning has become an ally in the control of chronic diseases such as hypertension (HTN), that causes 63 % of deaths of elderly people, due to shortcomings in adherence to treatments and patient lifestyles. In this article it is proposed that implementing this technology in the follow-up of the treatment of HTN may provide prognoses of the future condition of the patients, and show the progress or the need of new diagnosis to improve their quality of life.

Cómo citar este artículo

(APA): Campos, L., Sánchez, D. y Abuchar, A. (2019). Machine learning y el control de hipertensión arterial. *Hashtag*, (15), 47-58

> **Palabras clave:** aprendizaje autónomo, hipertensión arterial (HTA), *machine learning*, tensión arterial

> **Keywords:** Arterial Tension, Autonomous Teaching, High Blood Pressure (HTA), Machine Learning

* Estudiante de la especialización en Ingeniería de Software de la Universidad Distrital Francisco José de Caldas. Contacto: laacamposr@correo.udistrital.edu.co

** Estudiante de la especialización en Ingeniería de Software de la Universidad Distrital Francisco José de Caldas. Contacto: djsancheza@correo.udistrital.edu.co

*** Docente de la Universidad Distrital Francisco José de Caldas. Contacto: aabucharp@udistrital.edu.co

Introducción

Cada año se presentan millones de muertes a causa de diferentes enfermedades cardiovasculares; la más usual de ellas es la hipertensión arterial (HTA), una enfermedad silenciosa que afecta a personas adultas (mayores de 65 años). De quienes la padecen, al menos la mitad de los casos desconoce su condición. Además, se trata de una enfermedad que no tiene cura, pero que con cuidados especiales se puede prevenir. Estos hechos hacen evidente la importancia de aumentar los esfuerzos para concientizar, prevenir y vigilar la presencia de la HTA, así como para mejorar la eficiencia de su tratamiento.

A lo anterior se debe agregar que el desconocimiento o la desatención de esta enfermedad pone en un riesgo constante la vida de las personas hipertensas. A menudo, la mitad de los pacientes llevan un tratamiento en contra de la HTA, pero no siguen cabalmente las recomendaciones del profesional de la salud, entre ellas, seguir el régimen de medicación, cambiar de manera radical ciertas rutinas como la alimentación; realizar una medición periódica de la tensión y asistir constantemente a controles médicos.

HTA: una enfermedad silenciosa

La tensión arterial (TA) hace referencia a la presión ejercida por la sangre en el momento en que circula a través de las arterias; esta se mide en milímetros de mercurio (mmHg). Al realizar una medición, encontraremos dos datos: 1) presión sistólica: la presión con la que bombea el lado izquierdo del corazón (normalmente es mayor a la diastólica); y, 2) presión diastólica: la presión con la que bombea el lado derecho del corazón (Organización Mundial de la Salud, OMS, 2004).

Ahora bien, gracias al constante avance tecnológico y científico, actualmente es posible proponer e implementar diferentes soluciones que aumentan la eficiencia o incluso automatizan procesos en los que hasta hace poco se presentaban dificultades en el campo de la medicina. En este caso, la inteligencia artificial, a través del *machine learning*, ofrece una alternativa novedosa. Aunque este método ha sido criticado y llamado peyorativamente *caja negra*, porque se ponen los datos en un lado y se obtienen respuestas –a menudo muy precisas– sin explicaciones por el otro, hace posible la creación de algoritmos que identifican diferentes patrones y realizan predicciones de comportamientos futuros sin intervención humana (Pérez y Grau, 2012).

En este artículo se mostrará la importancia que está cobrando el *machine learning* en el ámbito de la salud, a través de la revisión de algunas referencias bibliográficas de tesis o productos relativos al caso de estudio. Entre estos se encontraron varias técnicas de conocimiento que permiten identificar las herramientas y metodologías que se deben implementar para el desarrollo del modelo predictivo que se aspira conseguir.

Generalmente, cuando la presión arterial tiene un valor de medición confirmado de 140/90 mmHg o más, se diagnóstica a la persona con HTA (OMS, 2013), también conocida como tensión arterial alta o elevada. Es un trastorno en el que los vasos sanguíneos tienen una tensión persistentemente alta, lo que puede dañarlos. Cada vez que el corazón late, bombea sangre a los vasos, que deben irrigarla a todas las partes del cuerpo: cuanto más alta es la tensión, más esfuerzo tiene que realizar el corazón para bombear.

Una vez se ha encontrado una medición más alta de lo normal, es necesario realizar un seguimiento, porque en algunos pacientes la TA varía de acuerdo al estado en que se encuentra su cuerpo en el momento de la medición. Por ejemplo, algunos pacientes durante la consulta de seguimiento permanecen con la TA elevada, pero está controlada durante el resto del día; a este tipo de pacientes se les denomina 'falsos positivos'. Este fenómeno también es conocido como fenómeno de bata blanca (EnColombia, s. f.). En cambio, hay pacientes falsos negativos: son los que, mientras se encuentran en el consultorio, registran una TA normal, pero en la mayor parte del día está elevada. A esto se le denomina HTA enmascarada (EnColombia, s. f.).

Las características anteriores son las que llevaron a que se le adjudicara el nombre de 'enfermedad silenciosa', pues en algunos casos no produce síntomas y puede pasar inadvertida. Por este motivo, algunos profesionales de la salud acuden a métodos como la tamización, que consiste

en seleccionar individuos con alto riesgo de padecer hipertensión arterial de acuerdo a criterios como la edad (mayor de 35 años), antecedentes familiares de HTA, sobrepeso, sedentarismo e ingesta de alcohol y tabaquismo activo. Así mismo, suelen recomendar el método de auto-monitoreo en casa o AMC (EnColombia, s. f.), útil para descartar o confirmar la condición de hipertensión arterial, así como evitar el fenómeno de bata blanca y la HTA enmascarada, pues muchos pacientes se alteran y cambian su condición al estar en un entorno clínico.

Otro método muy común es el monitoreo ambulatorio de presión arterial (MAPA) (Álvarez, Ruso, Pérez y Fernández, 2006). Se trata de una técnica de control a la presión arterial que ha permitido la identificación de nuevos parámetros relevantes para la atención clínica en pacientes con hipertensión arterial, entre ellos, la hipertensión sistólica aislada, la hipotensión ortostática, la hipotensión nocturna y el fenómeno *dipper*.

Tratamiento y la importancia de adherirse a él

Una vez se ha logrado identificar a un paciente con HTA, es necesario iniciar tratamientos farmacológicos de acuerdo a cada caso, realizar cambios en el estilo de vida, la alimentación, el ejercicio físico, el consumo de alcohol y de tabaco; y finalmente completar el proceso de adherencia al tratamiento. Este último es muy importante para que el resultado sea óptimo, ya que hace referencia al grado de aceptación del paciente a la toma de medicamentos, la modificación del estilo de vida y la disposición para seguir la dieta y las indicaciones dadas por el profesional de la salud.

Otro factor importante para obtener buenos resultados es realizar un seguimiento al tratamiento o a la rapidez con la que se presenta un diagnóstico de una persona con HTA; a esto se le denomina inercia clínica. En algunas ocasiones, las fallas médicas a la hora de diagnosticar o cambiar el tratamiento cuando no se alcanzan las metas pueden presentarse en un 50 % de las veces por el médico, un 30 % por el paciente y un 20 % por situaciones asociadas al sistema de salud. Esto conlleva a obtener resultados no muy favorables como la muerte o severos trastornos cerebro-vasculares (Machado, 2013).

HTA y el *machine learning* (ML)

Recientemente se ha podido observar cómo aquello que antes era inimaginable, hoy se puede hacer; por ejemplo, el desarrollo y ampliación de la inteligencia artificial (IA). En 1965, Gordon Moore predijo el incremento continuado de la complejidad de los circuitos integrados y la reducción paulatina de su costo, a lo que se le conoce como la ley de Moore. Actualmente, además de los avances en electrónica e informática, uno de los factores más importantes para el desarrollo de la inteligencia artificial es la inversión de las grandes compañías tecnológicas en I+D (investigación + desarrollo) (Martín, Hernández y García, 2018).

En virtud de estos y otros factores, se ha logrado un crecimiento exponencial, por lo que hoy en

día es posible hablar de las aplicaciones de inteligencia artificial, que están cada vez más cerca de la vida cotidiana. Entre otras cosas, dichas aplicaciones brindan soluciones para mejorar la manera en que se ejecutan tareas repetitivas. Por ejemplo, Customer Engineer en Google Cloud es una de las ramas de la IA que el *machine learning* podría abordar de manera acertada. Sin duda, esta herramienta sería el aliado ideal para solucionar algunas de las dificultades del sector de la salud, en especial, si se tiene en cuenta que tiene a su cargo la responsabilidad de tomar decisiones referentes a la vida humana (Ortiz, 2017; Olalla, 2018). A continuación, se brindará información más detallada sobre el *machine learning* y sus aplicaciones.

¿Cómo funciona el *machine learning*?

El *machine learning* (ML) es una disciplina que hace parte de la inteligencia artificial y que se encarga de crear mecanismos capaces de aprender de manera autónoma. A partir de un conjunto de parámetros y el uso de muestras de entrenamiento, se busca que el algoritmo sea capaz de realizar una clasificación de las variables y tomar decisiones eficaces.

Así como la finalidad de cualquier aprendizaje humano es desarrollar conocimiento a través de la asociación y generalización, el ML tiene como objetivo que una máquina sea capaz de desempeñarse con exactitud en tareas repetitivas, así como también en tareas nuevas e inesperadas. En esencia, se busca que la máquina aprenda, tal como lo haría un humano, por medio de algoritmos que realizan la ejecución y procesamiento de dichas tareas.

¿Cómo se logra el *machine learning*?

Las máquinas deben replicar el conocimiento humano por medio de algoritmos que procesan la información de entrada para realizar las predicciones. Estas predicciones se logran gracias al entrenamiento previo que se hace al algoritmo, que consiste en un gran listado de ejemplos prácticos que relacionan una paleta diversa de datos de entrada y salida. Dependiendo del diseño del algoritmo, este se puede clasificar en 3 categorías: *supervised learning* (aprendizaje supervisado), *unsupervised learning* (aprendizaje no supervisado) y *reinforcement learning* (aprendizaje por refuerzo).

En la categoría de *aprendizaje supervisado*, se suministra el concepto (dato, etiqueta) que se espera que el sistema aprenda. Esto quiere decir que se usan unos datos previos de entrenamiento

(Ávila, 2015). En el *aprendizaje supervisado* existe un concepto importante: las etiquetas. Estas hacen referencia al valor verdadero que se está prediciendo; generalmente es representado por la letra y . Adicionalmente, se encuentran los atributos, que son las variables de entrada generalmente son representados con la letra x con un subíndice i , dependiendo de la cantidad de entradas. Ambas son usadas para realizar la predicción en ejemplos etiquetados. En algunos casos solamente se tiene el valor de x ; a estos se les llama *ejemplos no etiquetados*. Para lograr obtener una predicción, es necesario realizar el entrenamiento del algoritmo, que se realiza mediante ejemplos etiquetados en los que se le muestra al modelo las relaciones entre los atributos y la etiqueta. Una vez se tiene el modelo entrenado, este se debe aplicar a ejemplos sin etiqueta para probar el correcto funcionamiento, proceso al que se le conoce como *inferencia* (Developers Google, s. f.).

La segunda categoría hace referencia al *aprendizaje no supervisado*. Esta es un paradigma en el que los datos iniciales no contienen la salida esperada; antes bien, lo que se hace es entregarle una gran cantidad de datos con sus propias características, lo que le permite conocer el resultado a partir de la información suministrada (Ávila, 2015).

Por último, se encuentra la categoría denominada aprendizaje por refuerzo. Está basada en descubrir qué acciones se deben tomar para maximizar la recompensa. Dicho de otro modo, se basa en cómo determinar acciones que se centren en encontrar dicha recompensa. Al agente no se le especifica qué acciones tomar, sino que

debe experimentar para encontrar que acciones lo llevan a una mayor recompensa (Silva, 2019).

Algo de historia

El ML inició en la década de los cincuenta, cuando Alan Turing creó su famoso test de Turing para determinar si una máquina era inteligente. La máquina aprobaba el test si era capaz de hacerle creer al humano que era un humano en lugar de un computador. Otro suceso con el que se inició el ML se dio dos años más tarde, cuando Arthur Samuel escribió un programa de ordenador capaz de aprender. Se trató de un *software* que jugaba a las damas y mejoraba su juego partida a partida, aprendizaje que hacía posible y efectivo al estudiar e incorporar los movimientos que componían estrategias ganadoras (Serrano, Molina, Manrique y Baumela, 2017; Maté, 2014).

A medida que se invirtieron recursos en esta área de conocimiento, se lograron identificar dos de los mecanismos más importantes del ML, conocidos como los modelos ocultos de Markov (HMM) y las redes neuronales artificiales (ANN). Estas últimas están basadas en el comportamiento de las neuronas de cerebros biológicos y tomaron fuerza en 1975, cuando Paul Webos creó un algoritmo de *back-propagation*, que utiliza un proceso de cálculo gradiente para entrenar algoritmos de aprendizaje supervisado. Actualmente, esta técnica es empleada por empresas como Google o Facebook.

Por medio del ML se han logrado realizar muchas funciones complejas, capaces, por ejemplo, de realizar predicciones en el tráfico, detectar enfermedades, identificar rostros e incluso definir si dos personas son compatibles entre sí.

Modelos y técnicas

Actualmente, existe una gran cantidad de datos que son suministrados a partir de herramientas tecnológicas. Tan es así que solo entre 2013 y 2015 la humanidad generó más datos que en toda su historia previa (Serrano *et al.*, 2017). Un fenómeno como este hace necesario empezar a organizar, estudiar, analizar y depurar dichos datos, para obtener información y nuevo conocimiento, con el que se logra tomar decisiones en diferentes situaciones de nuestro entorno.

Por lo anterior, la ciencia de datos o *data science* ha tenido gran acogida en la industria 4.0, ya que es una rama que permite la extracción del conocimiento a partir de la captura de grandes volúmenes de datos (*big data*); realizar la limpieza, preparación y análisis de datos por medio de la aplicación de diversos métodos científicos y tecnologías –que se originan de ciencias como las matemáticas, estadística e informática–, entre los que se encuentran el análisis exploratorio, el aprendizaje automático (*machine learning*), el aprendizaje profundo (*deep learning*), el procesamiento del lenguaje natural, la visualización de datos y el diseño experimental. Además, por medio de esta rama se han logrado cambiar las estrategias con las que se desenvuelven los negocios, la política y la educación gracias a la exactitud de sus predicciones (Universidad de Alcalá, s. f.).

¿Cuándo utilizar el machine learning?

Para ello, se debe recordar que el aprendizaje automático no es una solución aplicable a todo tipo

de problemas; en algunos casos, es posible llegar a la solución sin necesidad de usar técnicas de aprendizaje automático, por ejemplo, cuando es posible determinar un valor de referencia a través de reglas, cálculos o pasos predeterminados que pueden programarse sin necesidad de ningún tipo de aprendizaje basado en datos. Por otra parte, es importante reconocer en qué situaciones es correcto usar el aprendizaje automático (Pérez, 2003):

- Cuando no es posible la codificación de las reglas o se está asociado con muchas tareas humanas como, por ejemplo, reconocer si un mensaje de correo electrónico es *spam* o no. Estos problemas no pueden ser resueltos fácilmente con un algoritmo basado en reglas, ya que su respuesta puede estar influenciada por un gran número de factores. Esto hace que sea difícil para una persona codificarlas de manera precisa: para estos casos, el aprendizaje automático es la respuesta (Pérez, 2003).
- Cuando el problema que se intenta resolver es de difícil escalamiento. Por ejemplo, si tratáramos de reconocer de manera manual unos cientos de correos electrónicos y decidir si son o no *spam*, sería una tarea realizable; en cambio, si se trata de millones de correos electrónicos, esta tarea pasaría a ser tediosa y consumiría bastante tiempo. En este tipo de casos las soluciones del aprendizaje automático se convierten en aliados eficaces para la solución de problemas a gran escala, ya que permiten la creación de modelos adaptables a la problemática (Pérez, 2003).

Herramientas para implementar los modelos

A lo largo del tiempo se han desarrollado algunos de los lenguajes y herramientas que hoy en día son usados en la construcción de modelos de aprendizaje, entre ellos, Python, R, Matlab y Julia. A su vez, estos han propiciado un gran crecimiento en las tecnologías de IA.

Python es uno de los lenguajes más usados debido a su simplicidad y a las filosofías DRY (*don't repeat yourself*) y RAD (*rapid application development*) en las que se basa. Este lenguaje puede utilizarse tanto para estructurar datos, como para generar algoritmos de IA. Además, dispone de un catálogo de librerías muy extenso que permite hacer realidad cualquier tipo de proyecto, dentro de los cuales se encuentran aplicaciones para dispositivos móviles, aplicaciones web y aplicaciones enfocadas a la ciencia de datos o IA.

R es otro de los lenguajes que están encaminados; es uno de uno de los mejores para analizar y tratar con datos. Con él es posible crear muy buenas IA con finalidades estadísticas, debido a que dispone de paquetes de programación muy numerosos, algunos de los cuales se utilizan en el ámbito del *machine learning*, como RODBC, que permite establecer la conexión con muchos tipos de bases de datos como lo son PostgreSQL, MySQL, Microsoft SQL Server, IBM DB2, SQLite entre otros.

Matlab es una herramienta usada para el entrenamiento de modelos, ajuste en parámetros y despliegues en producción; su facilidad de uso proporciona a los ingenieros y otros expertos una herramienta rápida e intuitiva de usar. Por estos motivos, actualmente se han desplegado miles de aplicaciones de *machine learning*. Además posee ajustes automáticos de hiperparámetros y selección de funcionalidades para optimizar el rendimiento de los modelos, así como algoritmos de clasificación, regresión y

clustering de uso común para el aprendizaje supervisado y no supervisado, entre otros. Entre sus beneficios se cuenta el *machine learning* automatizado (AUTOML), que permite la generación de funcionalidad a partir de los datos de entrenamiento. Gracias a su interfaz gráfica, es posible utilizar técnicas especializadas de extracción de funcionalidades como la dispersión de *wavelets* para datos de señales o imágenes; y técnicas de selección de funcionalidades, como el análisis de componentes vecinos (NCA) o la selección de funcionalidades secuenciales.

Julia es otro de los grandes lenguajes de programación que es usado para el *machine learning*. Este nació en el año 2012, pero solo hasta el 2018 se posicionó como uno de los lenguajes de programación de más rápido crecimiento. Hoy en día ocupa el puesto 39 en el ranking de TIOBE, a gran distancia de sus grandes competidores como Python que se encuentra en el puesto 3. En todo caso, esto no es lo que realmente lo hace tan interesante. Este lenguaje de programación tiene una curva de aprendizaje bastante baja. Si en la actualidad se tiene conocimiento sobre C, Python o R, esto representa una ventaja, debido a que Julia fue construido con el objetivo de combinar lo mejor que tenían sus grandes rivales, lo que se traduce en: la velocidad de C, la usabilidad de Python, el dinamismo de Ruby, la destreza matemática de MatLab y la estadística de R.

Además de esto, Julia proporciona *flux*, que es un marco de trabajo o librería enfocada en el *machine learning* y la inteligencia artificial. Este provee una manera fácil e intuitiva de trabajar. Entre las bondades de Julia encontramos que posibilita la integración con otros *kernels* y librerías, tanto así que garantiza el soporte para otros *frameworks* de *machine learning*, como TensorFlow y MXNet.

Herramientas de desarrollo IDE

JupyterLab es un entorno de desarrollo interactivo basado en la web. Su gran flexibilidad permite la configuración y organización de la interfaz de usuario para admitir una amplia gama de flujos de trabajo en ciencia de datos, informática científica y aprendizaje automático. Adicionalmente, es extensible y modular, por lo que con unos cuantos clics se pueden añadir complementos que agreguen nuevos componentes y se integren con los existentes (Jupyter, s.f.).

Spyder es un entorno de desarrollo integrado y multiplataforma de código abierto (IDE) para

programación científica en el lenguaje Python bajo la licencia del MIT. Al igual que los otros IDE mencionados, es extensible por medio de complementos. Incluye soporte de herramientas interactivas para la inspección de datos e incorpora controles de calidad específicos de Python e instrumentos como Pyflakes, Pylint y Rope. Esta herramienta es multiplataforma a través de Anaconda, por medio de WinPython y Python en Windows; en MacOs a través de MacPorts y en Linux por medio de las principales de Gnu/Linux como Arch Linux, Debian, Fedora, OpenSUSE y Ubuntu.

Ejemplo de aplicación

En la actualidad, se han desarrollado diversos trabajos enfocados en hacer el seguimiento de la hipertensión arterial a través de técnicas inteligentes. A continuación, se describirán 5 trabajos de investigaciones relevantes. El primer trabajo realiza el procesamiento de la señal eléctrica del corazón (SECG) y las técnicas estadísticas para identificar la presión arterial. Se tomaron muestras de SECG a 22 pacientes, 18 sanos entre los 17-26 años; y 4 con presión arterial alterada de 50-78 años. Este modelo predictivo en ocasiones identifica valores altos mientras que el profesional detecta valores bajos y viceversa, por lo que se espera realizar un ajuste en la metodología que les permita aumentar la efectividad del 97,09 % al 99 % (Mendoza, 2016).

El segundo modelo hace referencia a una investigación publicada por la revista *Medwave*, bajo el título "Modelo predictivo para el desarrollo de la cardiopatía hipertensiva: cohorte prospectiva". Los investigadores desarrollaron un modelo de regresión logística binaria final por medio del método "paso a paso hacia atrás" y

con variables como la edad, el consumo de alcohol y el tabaquismo. A partir de este, se obtuvo un instrumento de vigilancia clínica y epidemiológica para la identificación de personas con altas probabilidades de presentar enfermedades cardiovasculares (Álvarez, González, Maceo, y Suárez, 2017).

Un tercer ejemplo de la aplicación de IA es una investigación realizada por estudiantes de la Universidad Distrital, quienes implementaron dos modelos predictivos de redes neuronales que ayudan al profesional de la salud a diagnosticar y priorizar a los pacientes, mediante dos metodologías:

- El aprendizaje supervisado, con perceptrones multicapa. Este permite resolver problemas que no son linealmente separables. Para usar este método se definió un 60 % de la muestra para hacer el entrenamiento y 40 % para probar el modelo. Finalmente, se obtuvieron los mejores resultados con una tasa de aprendizaje de 0,75.

- El aprendizaje no supervisado, con redes ART2. Con este modelo se soluciona la estabilidad por medio de patrones de clases existentes; si no encuentra la asociación, crea una nueva clase. Este logró mejores resultados, con una tasa de aprendizaje de 1. De lo anterior se puede concluir que este es el mejor método de predicción para este caso, a pesar de que, con algunas observaciones específicas, resulta más exacto el perceptrón multicapa (García, 2018).

Por último, hay que mencionar la investigación publicada en el artículo “Diseño de un modelo predictivo de pesquisa cardiovascular utilizando árboles de decisión: propensión de pacientes a

presentar diabetes tipo II, hipertensión arterial o dislipidemia: Estudio piloto, comuna de Quellón, Chiloé”. En este se obtuvieron avances significativos respecto a la toma de acciones de prevención y el diagnóstico anticipado, a través de un modelo predictivo compuesto por árboles de decisión. El modelo permite descubrir pacientes que son propensos a desarrollar diabetes tipo II (DM II), hipertensión arterial (HTA) o dislipidemia (DLP). Durante la indagación se comprobó que la edad y la circunferencia de cintura fueron las variables con mayor porcentaje de precisión, donde, de los 4 algoritmos que se desarrollaron, el C5 obtuvo el mayor, con una precisión del 83,01 % (Cárdenas, 2018).

Prospectiva

En este artículo se presentó una introducción a los modelos y tecnologías de aprendizaje automático, que buscaba despejar algunas incógnitas acerca de su aplicación en el ámbito de la salud, específicamente en el tratamiento de la hipertensión arterial. Sin embargo, se entiende que, de forma simultánea, surgen nuevas ideas y preguntas que abren camino a nuevas líneas de investigación. Por ello, en esta sección se muestran algunas de las que podrían ser abordadas en el futuro.

En relación con el modelado de sistemas de aprendizaje automático, la tecnología descrita puede aplicarse a todo tipo de ámbitos. Por lo que puede ser interesante la creación de modelos integrados a otras aplicaciones que brinden más beneficios a partir del procesamiento de datos etiquetados, como el análisis de las mediciones de presión arterial, género, edad, hábitos como el consumo del licor y tabaco, entre otros.

Es posible decir que, una vez se implementen estas tecnologías y se logren modelos con un alto

nivel de precisión, será mucho más factible enfocar los esfuerzos en la implementación de herramientas que ayuden al médico en la lectura, el seguimiento, el pronóstico y la asignación del tratamiento. Estas herramientas podrían integrarse al sistema de información usado por el centro médico.

También podrían incluirse en una aplicación móvil que permita que tanto el médico como el paciente realicen el seguimiento al tratamiento y que la toma de decisiones clínicas sea oportuna. Además, permitirá brindar información al paciente sobre su estado de salud futuro, conocer el momento en que debe acudir al médico o reforzar sus hábitos, y concientizarse acerca de los cuidados que debe tener, promover el autocontrol y minimizar los riesgos de que se produzca un accidente cardiovascular.

Adicionalmente, es posible generar un repositorio de información a partir de la consolidación de todos los casos de los pacientes, la evolución en el tratamiento y la predicción del modelo

utilizado. Esto ayudaría a crear un nuevo conjunto de datos que podría ser analizado y estudiado por los profesionales de la salud, para

determinar nuevos patrones en el desarrollo de esta enfermedad y descubrir nuevos tratamientos para remediarla.

Conclusiones

Debido al continuo avance de la tecnología, el *machine learning*, a través de la inteligencia artificial, ha tomado fuerza y es una buena alternativa para solucionar problemas en distintos campos, entre ellos la medicina, ya que garantiza un porcentaje alto de precisión en sus predicciones. Asimismo, es una herramienta que proporciona métodos de diagnóstico más rápidos gracias a las redes neuronales, que son capaces de procesar, analizar y clasificar una gran variedad de datos en un menor tiempo.

Para el caso de algoritmos que ayuden en la predicción del estado de salud en pacientes con HTA, se establece que la categoría más adecuada para implementar sería el aprendizaje supervisado, porque con ayuda de un profesional de la salud

experto en esta enfermedad se puede garantizar que las decisiones tomadas por el algoritmo sean las más acertadas.

El *machine learning* y las ciencias de datos se han convertido en un recurso creciente que ayuda a agilizar procesos y tareas que en el pasado tomaban mucho tiempo. Esta es una de las razones que explica la ampliación sustancial de la nueva era de la tecnología y la industria 4.0. Sin lugar a duda, las tecnologías y herramientas con las que se pueden desarrollar algoritmos de *machine learning* son muy amplias y contienen gran documentación, ventaja con la que se podrá estudiar y definir cuáles son las adecuadas para el algoritmo que se requiere desarrollar.

Referencias

- Álvarez, A., González, J., Maceo, L. y Suárez, A. (2017). Modelo predictivo para el desarrollo de la cardiopatía hipertensiva: cohorte prospectiva. *Medwave Revista Biomédica Revisada por Pares*, 17(4).
- Álvarez, G., Ruso, R., Pérez, M. y Fernández, M. (2006). Manual clínico del monitoreo ambulatorio de la presión arterial. *Revista Cubana de Medicina*, 45(4).
- Ávila, J. (2015). *Herramientas de los sistemas gestores de las bases de datos. Pasarelas y medios de conexión*. Madrid: Editorial Elearning.
- Cárdenas, C. (2018). Diseño de un modelo predictivo de pesquisa cardiovascular utilizando Árboles de Decisión: propensión de pacientes a presentar diabetes tipo 2, hipertensión arterial o dislipidemia: Estudio piloto, comuna de Quellón, Chiloé. *Revista Chilena de Cardiología*, 37(2), 126-133.

- EnColombia. (s. f.). Hipertensión arterial primaria (HTA): módulo de seguimiento [recurso en línea]. Recuperado de <https://encolombia.com/medicina/guiasmed/guia-hta/hipertension-arterial-primaria-seguimiento/>
- García, Y. (2018). *Red neuronal para diagnóstico de hipertensión arterial* (tesis de grado) Universidad internacional de la Rioja, Madrid, España.
- Developers Google. (s. f.). Framing: Key ML Terminology. Recuperado de <https://developers.google.com/machine-learning/crash-course/framing/ml-terminology>
- Jupyter. (s. f.). Jupyter [main]. Recuperado de <https://jupyter.org>
- Machado, J. (2013). ¿Inercia clínica, qué tanto nos afecta?, *Revista Médica de Risaralda*, 19(1), 94-96.
- Martín, D., Hernández, E. y García, V. (2018). *Detector predictivo de conexiones fraudulentas* (tesis de maestría). Universidad Oberta de Catalunya, Barcelona, España.
- Maté, C. (2014). Big data. Un nuevo paradigma de análisis de datos, *Anales de Mecánica y Electricidad*, 91(6), 10-16.
- Mendoza, L. (2016). Procesamiento de la señal eléctrica del corazón. *Revista Latinoamericana de Hipertensión*, 11(2), 1-6. Recuperado de <https://www.redalyc.org/pdf/1702/170250835001.pdf>
- Olalla, I. (2018). El *machine learning*, una necesidad para abordar los problemas a gran escala [entrada de blog]. MD. Marketing Directo. Recuperado de <https://www.marketingdirecto.com/marketing-general/business-intelligence-powered-by-neural-one/el-machine-learning-una-necesidad-para-abordar-los-problemas-a-gran-escala>
- Organización Mundial de la Salud (OMS). (27 de octubre del 2004). *Responsables de salud de todo el mundo se unen a la Organización Mundial de la Salud en el anuncio de un redoblado esfuerzo para mejorar la seguridad del paciente*. Recuperado de <https://www.who.int/mediacentre/news/releases/2004/pr74/es/>
- Organización Mundial de la Salud (OMS). (2013). *A Global Brief on Hypertension*. Génova: WHO. Recuperado de https://apps.who.int/iris/bitstream/handle/10665/79059/WHO_DCO_WHD_2013.2_eng.pdf?sequence=1
- Ortiz, J. (22 de marzo del 2017). El *machine learning* y sus aplicaciones. 20 ejemplos [entrada de blog]. Joanybel Ortiz. Recuperado de <http://www.joanybelortiz.com/aplicaciones-machine-learning-ejemplos/>
- Pérez, S. (2003). Introducción a la regresión logística. Recuperado de: <http://halweb.uc3m.es/esp/Personal/personas/amalonso/esp/bstat-tema9.pdf>

- Pérez, G. y Grau, R. (2012). Predicción de la evolución hacia la hipertensión arterial en la adultez desde la adolescencia, *Revista Cubana de Informática Médica*, 4(1), 46-64.
- Serrano, E., Molina, M., Manrique, D. y Baumela, L. (2017). *Aprendizaje experiencial en ciencia de datos: satisfacción de los estudiantes para tres modelos de enseñanza y aprendizaje*. Conferencia presentada en el Congreso Internacional Sobre Aprendizaje, Innovación y Competitividad. Zaragoza
- Silva, M: (abril 2019). Aprendizaje por Refuerzo: Introducción al mundo del RL. Recuperado de <https://medium.com/aprendizaje-por-refuerzo-introducci%C3%B3n-al-mundo-del/aprendizaje-por-refuerzo-introducci%C3%B3n-al-mundo-del-rl-1fcbaa1c87>
- Spyder. (s. f.). Spyder: The Scientific Python Development Environment [main]. Recuperado de <https://docs.spyder-ide.org/>
- Universidad de Alcalá. (s. f.). Diferencias entre *big data* y *data science* [entrada de blog]. *Universidad de Alcalá*. Recuperado de <https://www.master-data-scientist.com/diferencias-entre-master-big-data-y-data-science/>