

## Aprendizaje Automático en Aplicaciones Fisioterapéuticas

Juan-Carlos González-Islas<sup>a,b,1\*</sup>

<sup>a</sup>Área Electromecánica Industrial, Universidad Tecnológica de Tulancingo, Camino a Ahuehuetitla No. 301, Col. Las Presas, 43645, Tulancingo, Hidalgo, México.  
<sup>b</sup>Área Académica de Computación y Electrónica, Universidad Autónoma del Estado de Hidalgo, Carretera Pachuca-Tulancingo km 4.5, Carboneras, 42184 Pachuca de Soto, Hidalgo, México.

### Resumen

El aprendizaje automático (AA) o aprendizaje máquina se centra en el desarrollo de sistemas de análisis que aprenden de datos existentes para predecir o agrupar datos futuros. Recientemente, el AA se ha desarrollado sustancialmente en muchas áreas de la ciencia y de la ingeniería, siendo una de las de mayor interés el área de la medicina. En los ambientes médicos reales existe una gran cantidad de datos de naturaleza multivariable y multidimensional, que requieren analizarse para diagnóstico y tratamiento médico, lo que representa un área de oportunidad importante para el aprendizaje máquina. Este trabajo presenta una revisión de algunas de las aplicaciones más relevantes del aprendizaje automático, así como las tendencias y expectativas emergentes del mismo. Posteriormente, se hace una descripción de los trabajos más significativos del aprendizaje máquina aplicado a la medicina, haciendo especial énfasis en aplicaciones fisioterapéuticas. Finalmente, un tema de particular interés en el contexto de la medicina física es el análisis de la marcha, por lo que se hace una revisión de los trabajos desarrollados para dicho propósito.

*Palabras Clave:* Aprendizaje automático, medicina, fisioterapia, análisis de la marcha.

### 1. Introducción

El aprendizaje automático (AA), aprendizaje computacional o aprendizaje máquina se ha convertido en una disciplina novedosa y muy importante de la computación en ámbitos específicos, se relaciona con el análisis de grandes cantidades de datos y de naturaleza multivariable y multidimensional. La predicción o respuesta a datos futuros a partir de datos que realiza el AA ha sido usada comúnmente en ciencias sociales, en investigación de operaciones y en ciencias aplicadas (Cleophas and Zwinderman, 2013). Sin embargo, está área se ha vuelto muy importante en otras disciplinas como la ingeniería de vehículos autónomos, las finanzas para predecir el comportamiento del mercado, la ciberseguridad y en la medicina, se ha empleado para diagnóstico (Paluszek and Thomas, 2016).

Los algoritmos de AA son muy importantes, ya que el ser humano puede ser capaz de especificar pares de entradas salidas, más no puede establecer en muchos casos relaciones y correlaciones entre las entradas y salidas deseadas como si lo hace el AA. Además, la cantidad de datos disponible sobre diferentes tareas puede ser tan grande y provista por ambientes dinámicos reales, que se vuelve compleja su codificación por los humanos (Ayodele, 2010).

Los métodos de aprendizaje más empleados son los de aprendizaje supervisado y han sido usados en clasificadores de spam, reconocimiento de rostros, sistemas de diagnóstico médico para pacientes, entre otros. Este tipo de sistemas de aprendizaje generalmente forman sus predicciones a través de una función aprendida de los datos de entrenamiento, para producir una salida para cada entrada. Algunos de los diferentes algoritmos de este tipo son: Árboles de decisión, bosques de decisión, regresión logística, máquinas de soporte vectorial,

redes neuronales, máquinas basadas en *kernel*, y clasificadores bayesianos (Hastie et al., 2009).

El aprendizaje no supervisado, es otro tipo de aprendizaje, el cual involucra el análisis de datos no etiquetados bajo ciertas premisas sobre las propiedades estructurales algebraicas o probabilísticas de los datos. Se puede asumir que los datos se agrupan con cierta distribución y baja dimensión, y el objetivo es identificar esa variedad a partir de los datos (*clustering*) (Jordan & Mitchell, 2015).

El tercer gran paradigma del aprendizaje automático es el aprendizaje reforzado, en donde la información prevista en los datos de entrenamiento es el enlace entre el aprendizaje supervisado y el no supervisado. Los ejemplos de entrenamiento en vez de servir para indicar si una salida es correcta, se emplean para guiar si una acción es correcta o no (Sutton and Barto, 1998).

Han sido varias las disciplinas que han contribuido a lo largo de la historia al aprendizaje máquina. En estadística los primeros métodos para la estimación del valor de una función desconocida en un punto dados los valores muestra pueden considerarse instancias del Aprendizaje (Anderson, 1962). Otra aportación que ha enriquecido al AA, es el estudio de los modelos del cerebro para aproximar estas redes artificiales al aprendizaje de los seres vivos (Gluck and Rumelhart, 2013), (Dayan and Abbott, 2001). Los modelos psicológicos para estudiar el desempeño de los humanos en tareas de aprendizaje (Feigenbaum, 1961), la inteligencia artificial para aprender parámetros de una función (Samuel, 1988) y los modelos evolutivos como los algoritmos genéticos (Goldberg and Holland, 1988), también han coadyuvado al desarrollo de estos sistemas.

\* Autor en correspondencia.  
Correo electrónico: sack\_gi@yahoo.com.mx

Algunas de las áreas de aplicación en las que el aprendizaje automático ha sido aplicado exitosamente se describen a continuación.

Por ejemplo, las empresas siempre han buscado maximizar su producción, minimizando los costos, es factible proponer métodos de reglas de control de la producción basado en árboles de decisión (Evans and Fisher, 1994).

En términos de energía eléctrica Jabbour et al. en 1988 desarrollaron un asistente predictor automático de carga eléctrica empleando la técnica de k-vecinos más cercanos (KNN, por sus siglas en inglés). De igual manera con la misma técnica de aprendizaje, recientemente, Valgaev et al., en 2017 desarrollaron un predictor de demanda de energía para un demo de ciudad inteligente que minimiza el consumo eléctrico.

Por su parte, la clasificación de datos ha sido un área por excelencia del AA. Paluszek and Thomas en 2016, emplearon exitosamente árboles de decisión para la generación de datos de entrenamiento y de prueba para clasificación de datos. También, es posible clasificar texto mediante aprendizaje activo basado en máquinas de soporte vectorial (SVM, por sus siglas en inglés) (Tong and Koller, 2001). La clasificación números mediante redes neuronales también ha sido abordado ampliamente, donde la tarea principal es identificar correctamente los dígitos mostrados en una imagen digitalizada (Bishop, 2006), (Ahangar and Ahangar, 2009), (Ciresan et al., 2011).

De igual manera, la clasificación de asegurados en grupos de acuerdo al nivel de riesgo, para establecer una tarifa justa para la prima es una tarea muy importante en la industria de los seguros de cualquier ámbito y un área de oportunidad novedosa para los algoritmos de AA (Guillen and Pesantez-Narvaez, 2018). En los trabajos presentados por (Rodríguez-Piñero, 2007) y (Martínez et al., 2010) se hace una comparativa para este propósito, entre SVM y análisis discriminante; y SVM con un modelo logit, respectivamente.

Como se puede revisar en la literatura, existen muchas áreas de aplicación del aprendizaje automático, ya que este paradigma resuelve el problema de analizar y procesar grandes cantidades de datos multivariados. Otros desarrollos interesantes se han dado en el campo de la genética y la genómica para la determinación de secuencias (Libbrecht and Noble, 2015), en la informática con el análisis de malware en android® (Urcuqui and Navarro, 2016), o también en el diseño de antenas y procesamiento de señales de radar (Kim, 2018), o hasta aplicaciones poco usuales como la orientación vocacional (Bulbul and Unsal, 2011).

### 1.1 Tendencias y Expectativas del Aprendizaje Automático

Junto con la inteligencia artificial (AI, por sus siglas en inglés), el AA ha emergido como uno de los métodos más elegidos para desarrollar aplicaciones prácticas de visión por computadora, reconocimiento de voz, procesamiento natural de lenguaje, control de robots, detección de fraudes en tarjetas de crédito y otras aplicaciones (Obermeyer and Emanuel, 2016).

Pero a pesar de que existen muchos avances prácticos y comerciales en el aprendizaje automático, aún hay varios retos por resolver y áreas de investigación inexploradas. Es por ello que existe bastante interés por parte de la comunidad científica en mostrar las capacidades que se tienen para el manejo de datos de manera eficiente por esta rama de la computación. Dos de los retos más importantes al respecto son: la construcción de sistemas computacionales que mejoren automáticamente a

través de la experiencia y trabajo colaborativo humano-máquina, y estudio de las leyes fundamentales que rigen a los sistemas de aprendizaje, incluyendo humanos, computadoras y organizaciones.

Sin embargo, el progreso reciente del aprendizaje computacional se ha visto beneficiado por el desarrollo de nuevos algoritmos y teorías, por la alta disponibilidad de grandes cantidades de datos en línea, por el bajo costo y amplio desarrollo tecnológico computacional y de comunicaciones. Además, a diferencia de las primeras aplicaciones del aprendizaje máquina en donde se corría un solo programa en una sola computadora, hoy en día es común que sistemas de AA se implementen en arquitecturas con miles de procesadores, lo que demanda sistemas de cómputo y de comunicaciones muy eficientes. Aunado a lo anterior, uno de los requisitos en los sistemas de aprendizaje es la privacidad y la propiedad de los datos para análisis o toma de decisiones. El objetivo final es cumplir con los requisitos de tiempo, espacio, operatividad y precisión establecidos.

Cualquiera que sea el algoritmo de aprendizaje, un objetivo científico y práctico clave es caracterizar teóricamente las capacidades de algoritmos de aprendizaje específicos y la dificultad inherente de cualquier problema tratado. La precisión que tiene el algoritmo de aprender de un tipo y volumen particular de datos de entrenamiento, la robustez del algoritmo a errores relacionados a las consideraciones de modelado o datos de entrada erróneos, la factibilidad de aprender de datos de entrenamiento para resolver problemas intratables y la garantía de la privacidad y propiedad de los datos estudiados dependiendo el contexto son características importantes que tienen que ser determinadas en un sistema de aprendizaje máquina (Jordan and Mitchell, 2015).

## 2. Aprendizaje Automático en la Medicina

El aprendizaje automático puede ser definido como el conocimiento para realizar predicciones obtenidas del procesamiento de datos de entrenamiento a través de una computadora. Si los conjuntos de datos involucran múltiples variables como los son en los ambientes médicos, el análisis se vuelve complejo y los métodos computacionales novedosos para dicho propósito se vuelven muy importantes.

En la medicina el AA ha sido empleado para hacer diagnósticos clínicos, predecir la eficacia de tratamientos novedosos y para la toma de decisiones médicas derivadas de la identificación de patrones. Aunque, estos métodos han sido poco usados en aplicaciones médicas reales (Cleophas and Zwinderman, 2013), recientemente el interés de trabajar con estas herramientas ha incrementado, por ejemplo, para mejorar la observación de progresión de la enfermedad, la predicción de la enfermedad, la autogestión del paciente y la intervención clínica (Ahamed and Farid, 2018).

Aun y cuando el paradigma de *bigdata* está transformando la medicina, es importante tener en cuenta que los datos por sí solos no tienen un uso relevante, si no hasta que son analizados, interpretados y permiten tomar decisiones. Por lo tanto, son los algoritmos, no los datos los que resultan aplicables a la medicina. De ahí que se debe centrar la investigación en el desarrollo de nuevas herramientas de aprendizaje automático en las áreas de la salud. En biomedicina, por ejemplo, el aprendizaje computacional puede predecir estructuras

proteínicas y secuencias genéticas para determinar dietas de pacientes (Obermeyer et al., 2016).

En un futuro, el aprendizaje automático realizará gran parte del trabajo de radiólogos y patólogos, basándose en la interpretación de imágenes digitalizadas. Estos sistemas pueden reemplazar superando la precisión humana a un radiólogo que lee mamografías (Gilbert, et al., 2008). La seguridad del paciente, se confiará cada vez más en el AA que en lo humanos, ya que estos sistemas pueden monitorear permanentemente, con el mismo rendimiento y en tiempo real los datos a diferencia del humano. Y aunado a esto, debido a que en estudios recientes se han reportado con frecuencia diagnósticos erróneos por parte de los médicos, es necesario que el AA ayude a mejorar la precisión de los diagnósticos, (Obermeyer and Emanuel, 2016). En la tabla 1 se describen algunos de los trabajos más significativos del aprendizaje máquina dentro del contexto médico y en la cual se resalta la aplicación, el porcentaje de precisión, el algoritmo empleado y los principales resultados.

En un ambiente clínico, los sistemas de intervención basados en rayos X (IXR, por sus siglas en inglés), son empleados para diferentes procedimientos en cardiología, neurología y angiología, en los cuales es sumamente importante clasificar correctamente cada examen del sistema IXR en los procedimientos respectivos y/o asignar la anatomía correcta, lo que representa un grado de oportunidad para la aplicación del aprendizaje máquina. Dicha clasificación mejora la calendarización y planeación de los tratamientos (Patil et al., 2016). En este trabajo se obtiene una exactitud mayor del 90% para la clasificación de exámenes, usando arboles de decisión, máquinas de soporte vectorial y k- vecinos más cercanos como plataformas de aprendizaje.

La complejidad del diagnóstico y terapia usadas en neurocirugía proveen una gran cantidad de datos. En 2017, Senders et al., realizaron una revisión sistemática del potencial para asistir y mejorar el diagnóstico neuroquirúrgico. En su trabajo describen varios sistemas para tratamiento de pacientes con epilepsia, tumores cerebrales, lesiones en la columna, patologías neurovasculares, Parkinson, traumatismos cerebrales, hidrocefalia, que mejoran el diagnóstico. Por su parte, la epilepsia es un problema neurológico típico. Las convulsiones de epilepsia son la consecuencia de la agravación eléctrica transitoria y sorprendente del cerebro, de ahí que es de suma importancia clasificar las señales electroencefalográficas (EEG, por sus siglas en inglés) epilépticas y no epilépticas (Kumar and Kumar, 2016). De ahí que, tratar la epilepsia mediante la implantación de neuroestimuladores es una aplicación terapéutica novedosa, sin embargo, la detección de convulsiones es un reto interesante debido a la variabilidad de las señales electroencefalográficas, aunque ha sido posible desarrollar un detector de convulsiones basado en SVM y EEG (Shoeb et al., 2009).

En aplicaciones médicas y de la vida diaria, el reconocimiento de patrones de señales mioeléctricas es muy útil. Dicho reconocimiento se hace generalmente con electrodos, aunque con un bajo rendimiento. Es por eso que (Anam and Al-Jumaily, 2015) desarrollaron una nueva propuesta para mejorar el desempeño de este tipo de sistemas empleando aprendizaje automático extremo secuencial en línea secuencial extremo en línea (OS-ELM, por sus siglas en inglés) con un rendimiento aproximado del 85% de exactitud.

En lo que respecta al síndrome de deficiencia respiratoria aguda (ARDS, por sus siglas en inglés), se trata de una

enfermedad crítica que por lo menos en 2005 afectó en Estados Unidos a 200,000 pacientes (Rubenfeld et al., 2005). Relacionado a este tema, existe un método mejorado para diagnóstico clínico de pacientes que desarrollan ARDS implementado con SVM, logrando una mejora en el algoritmo de la detección de pacientes con ARDS (Reamaroon et al., 2019).

Tabla 1: Aplicaciones médicas del aprendizaje automático

Referencia	Técnica de AA	Aplicación	% de exactitud	Resultados relevantes
Patil et al., 2016	SVM, KNN y Arboles de decisión	Análisis de rayos X	>90	Clasificación exámenes por tipo anatómico
Kumar and Kumar, 2016	SVM Análisis discriminante	Epilepsia	~70 ~93	Clasificación de señales epilépticas
Shoeb et al., 2009	SVM	Epilepsia	No dada	Fiabilidad de un detector embebido
Anam and Al-Jumaily, 2015	OS-ELM	Reconocimiento de movimiento	~85	Reconociendo EMG preciso
Reamaroon et al., 2019	SVM Regresión logística	Cardiología	~72 ~69	Detección ARDS
Chang et al., 2018	Bosque aleatorio Regresión logística Árboles de decisión	Cardiología	98 94 97	Predicción de paro cardíaco
Menéndez et al., 2010	SVM	Oncología	~80	Detección cáncer (seno)
Sweilam et al., 2010	SVM	Oncología	~93	Detección cáncer (seno)
Akay, 2009	SVM	Oncología	~95	Detección cáncer (seno)
Faisal et al., 2018	SVM Arboles de decisión Naive Bayes Redes Neuronales Ensamble de Clasificados	Oncología	~79 ~78 ~85 ~71 ~88	Detección cáncer (pulmón)
Plis et al., 2014	SVM	Diabetes	Precisión ~42	Monitoreo de niveles de glucosa

Por su parte, el cáncer ha sido caracterizado como una enfermedad heterogénea con muchos tipos y como una de las más mortíferas para la humanidad (Kourou et al., 2015). Los cánceres de seno y de pulmón son 2 de los tipos más peligrosos. De ahí que el diagnóstico temprano de cualquier tipo de cáncer y en particular el de pulmón y seno permite tomar mejores decisiones respecto a los tratamientos. Bajo esta consideración el aprendizaje automático para dicho propósito ha sido una buena propuesta para detectar los cánceres de seno (Menéndez et al., 2010), (Sweilam et al., 2010) y (Akay, 2009), y de pulmón (Faisal et al., 2018). En los tres primeros trabajos se usa SVM

como plataforma de aprendizaje y en el cuarto se emplea SVM, Árboles de decisión, Naive Bayes y Redes Neuronales Perceptrón y con el mejor rendimiento un ensamble de clasificadores para la detección de ese tipo de cáncer.

Otra de las enfermedades que afectan severamente la salud en todo el mundo es la diabetes mellitus (DM, por sus siglas en inglés), la cual se define como un grupo de desórdenes metabólicos que afectan la salud humana. El diagnóstico, la etiopatofisiología, la terapia, entre otras tareas relacionadas a la diabetes generan gran cantidad de datos, lo que las hace susceptibles para desarrollar sistemas de AA. En esta área las técnicas como SVM se han utilizado exitosamente en: predicción y diagnóstico, determinación del ambiente genético, cuidado y manejo de la salud (Kavakiotis et al., 2017). Mientras que los Modelos de regresión de soporte vectorial para monitorear los niveles de glucosa en la sangre y determinar los niveles de insulina requerida (Plis et al., 2014).

Por último, en el área de cardiología se propuso un sistema de predicción temprana de paro cardíaco empleando árboles de decisión, bosques aleatorios, regresión logística (Chang et al., 2018) y en términos de la nutrición se estimó la altura y el peso a partir de medidas antropométricas usando máquinas de aprendizaje basadas en regresión (Rativa et al., 2018).

### 2.1 Retos Inherentes del Aprendizaje Máquina en la Medicina

Como ya se ha mencionado, el aprendizaje automático ha tenido avances sustanciales en diferentes campos de aplicación, pero es la medicina uno en los que ha incrementado su interés por la aplicación de este tipo de algoritmos. Sin embargo, hacen falta más estudios comparativos sobre la efectividad de los sistemas de soporte de decisiones basados en AA (ML-DSS, por sus siglas en inglés), principalmente para evaluar los resultados en los efectos de la salud del paciente.

Uno de los problemas más grandes inherentes a los ML-DSS es la reducción de las habilidades de los médicos para reaccionar ante fallas en los sistemas automáticos o para derivar opiniones basadas en signos y síntomas detectables y datos disponibles. Además, el hecho de que las tecnologías de AA se pueden centrar más en la representación de los datos que en el contexto mismo representa un punto de cuidado, por lo que se requieren datos completos y confiables, situación que normalmente no ocurre en un escenario médico real. Por lo que es claro que para desarrollar sistemas expertos es necesario trabajar con expertos del área para contextualizar con precisión el problema e incluir el historial clínico del paciente, para no tener interpretaciones parciales o equivocadas del diagnóstico (Cabitza et al., 2017).

Los ML-DSS también presentan el problema de datos faltantes que condicionan el diagnóstico y tratamiento determinado. Las características de los datos como son la representación, heterogeneidad, disponibilidad e interoperabilidad supeditan el éxito de los ML-DSS y en el mundo real la toma de decisiones comúnmente se basa en información incompleta. Lo que representa un problema de investigación abierto, tal y como lo han hecho (Khan et al., 2012) al proponer un sistema de integración de aprendizaje automático para resolver el problema de datos faltantes en los ML-DSS.

Otro obstáculo relacionado con el empleo de sistemas automáticos de aprendizaje para la toma de decisiones, es la unión de datos empíricos a interpretaciones categóricas. De ahí

que los médicos muy a menudo no están de acuerdo en los diagnósticos y evaluación de resultados. La incertidumbre intrínseca de las observaciones e interpretaciones médicas que forman parte de la información en los modelos de aprendizaje no suele considerarse y por ello presenta un tema abierto a la investigación.

Los inconvenientes encontrados en la aplicación del AA a la medicina, también se relacionan con algoritmos que tienen grandes cantidades de variables y predictores; en algunas ocasiones más predictores que observaciones, combinados de una forma altamente interactiva y no lineal. Además, los algoritmos en ocasiones sobreajustan los pronósticos a correlaciones falsas en los datos, provocando estimaciones inestables, que pueden dirigir a predicciones muy optimistas del modelo o exageradas sobre el desempeño en el mundo real. Igualmente, los algoritmos aplicados requieren muchas observaciones para alcanzar un desempeño aceptable, por lo que es necesario tener poblaciones estadísticamente significativas y representativas.

Finalmente, todo lo anterior conlleva que hoy en día aún exista mucha resistencia de los sistemas de salud a confiar completamente a una máquina las tareas que un humano puede desempeñar con mayor precisión. Por ello aún persiste la necesidad de tener un médico tradicional con un criterio humano para equilibrar la aleatoriedad de los procesos e inferir el conocimiento a partir de nuevos datos (Deo, 2015). Así que el reto de desarrollar ML-DSS sigue abierto.

### 3. Aplicaciones del Aprendizaje Automático en la Medicina Física y Fisioterapia

La medicina física es un área de la medicina que se centra en el diagnóstico, tratamiento y evaluación de personas con una enfermedad, trastorno o lesión que limita sus capacidades para desarrollar sus actividades. Y cada día incrementa el número de personas con discapacidad en el mundo, debido al envejecimiento, enfermedades degenerativas, genéticas y accidentales.

El reconocimiento de movimientos humanos (gestos) es usado para entender un significado expresado a través de un gesto. Dicho reconocimiento puede ser aplicado al monitoreo de la evolución de pacientes y deportistas, a sistemas de seguridad, juegos o *exergaming* (Deboeverie et al., 2016) y (Patsadu et al., 2012). Redes neuronales, Bosques aleatorios, SVM. Árboles de decisión y Naive Bayes son los algoritmos que se han utilizado para dicho propósito con una exactitud promedio para estos clasificadores del 93.72%.

En la fisioterapia y fisioterapia, se han desarrollado sistemas automáticos de aprendizaje de bajo costo, estables y precisos para el reconocimiento de gestos empleando visión computacional, con el objetivo de reconocer ejercicios terapéuticos caseros (Ar and Akgul, 2012). En este trabajo se usaron Redes bayesianas, cuyas entradas consisten en una base de datos de videos RGB-D de ejercicios caseros aplicados para rehabilitar hombro y rodilla, una de las articulaciones que con mayor frecuencia se lesionan. En términos de exactitud del Sistema logra clasificar con un 82.50% y un 83.33% para datos RGB y RGB-D, respectivamente.

Definitivamente es muy importante evaluar la evolución de los tratamientos durante el proceso de rehabilitación para determinar el éxito del tratamiento de hombro y rodilla. Sin embargo, el seguimiento de estos protocolos es a menudo

deficiente, y más aún en los programas de ejercicio en casa, ya que las herramientas para dicha tarea son muy limitadas y carecen de supervisión. Una opción, es el desarrollo de un sistema de monitoreo de la terapia de hombro usando un reloj inteligente como dispositivo de adquisición de datos (Burns et al., 2018). Los algoritmos empleados para clasificar los ejercicios de hombro son: k-vecinos más cercanos, bosques aleatorios, SVM y con el mejor desempeño Redes Neuronales Recurrentes (CRNN, por sus siglas en inglés), logrando una exactitud del 99.4%. Los resultados de este trabajo demuestran la factibilidad de aplicar el aprendizaje automático a los datos de sensores inerciales que se usan en la muñeca para el reconocimiento de ejercicios de fisioterapia del hombro y así determinar los avances de los ejercicios en casa para rehabilitar esta articulación.

Así como el uso de teléfonos y relojes inteligentes se ha incrementado en aplicaciones médicas, el uso de sensores vestibles también ha sido tratado para clasificar información relacionada a actividades humanas empleando modelos ocultos de Márkov (Mannini and Sabatini, 2010).

De acuerdo a la Organización mundial de la salud OMS, en 2015 se estimaba que cerca de 15 millones de personas morían a causa de enfermedades cardiovasculares, de las cuales 6.24 millones a causa de derrames cerebrales. Las características faciales más comunes del derrame cerebral son la asimetría y la boca torcida. (Chang et al., 2018) proponen un sistema de reconocimiento de parálisis facial para asistir a los pacientes por sus propios medios. Los clasificadores empleados para desarrollar esa tarea con más de un 95% de exactitud promedio a partir de imágenes de los pacientes son: SVM, Bosques aleatorios y Bayes.

Las interfaces Cerebro-Computadora (BCI, por sus siglas en inglés) por su parte, se han convertido en una de las tecnologías de interfaz con mayor atención en la actualidad. Dichas interfaces han procesado señales EEG en los dispositivos de rehabilitación en forma de Estimulación Eléctrica Funcional (FES, por sus siglas en inglés). Sin embargo, la formación provista en dichas señales es vasta, por lo que se requieren modelos computacionales para su análisis preciso. Recientemente se ha planteado una terapia de brazo para rehabilitación después del accidente empleando señales EEG en una red neuronal probabilística (PNN, por sus siglas en inglés) con una exactitud promedio mayor al 82% en la etapa de prueba (Fatmawati and Wijaya, 2017). La herramienta desarrollada para el modelado de terapia post derrame puede reducir la dependencia de fisioterapeutas.

Relacionado a lo anterior, SOPHIA (Soft Orthotic Physiotherapy Hand Interactive Aid) es un sistema de rehabilitación mediante extensión asistida, que monitorea los ejercicios del paciente y guía pasivamente el procedimiento, el cual puede ser usado de manera eficiente en pruebas clínicas futuras (McConnell et al., 2017).

### 3.1 Aprendizaje Máquina en el Análisis de la Marcha

En el contexto fisiátrico y fisioterapéutico el análisis de marcha es uno de los temas más relevantes y se basa en la comparación de medidas derivadas del análisis de la cinemática, cinética y fisiología muscular del aparato locomotor del ser humano. La marcha inicial es una de las tareas en la estimulación temprana en las que hay que poner especial interés para desarrollar sistemas que coadyuven a mejorar los procesos terapéuticos para mejorar la calidad de vida de las personas con

esta condición, particularmente los niños (Gonzalez-Islas et al., 2018). En el trabajo presentado por los autores se ha desarrollado una andadera motorizada para asistencia motriz para niños con discapacidad.

El envejecimiento de las personas, alteraciones genéticas o accidentes provocan problemas en el sistema de locomoción, alterando sus patrones de marcha. La identificación automática de cambios en la marcha provee muchas ventajas incluyendo identificación de riesgos y el monitoreo del progreso de tratamientos para problemas relacionados. Uno de los primeros trabajos para la identificación automática de la marcha fue presentado por Begg en 2005, mediante SVM para el reconocimiento automático de tipos de marcha en adultos y jóvenes, obteniendo más de un 80% de exactitud en el desempeño del algoritmo y dejando oportunidad para futuras aplicaciones para la detección de patrones de marcha patológicos y normales, que permitan minimizar los riesgos y mejorar la calidad de vida en la vejez.

Es posible identificar problemas de salud relacionados a la hemiplejía, al mal de Parkinson, al dolor en la espalda y al dolor en la pierna al relacionarlos con sus patrones de marcha. Las técnicas empleadas para dicho reconocimiento se han basado en captura de movimiento humano, k-vecinos más cercanos y redes neuronales, con una exactitud promedio del 100% (Pogorelc et al., 2011). Los resultados logrados por dicha propuesta logran una alta exactitud de clasificación y pueden ser usados como una guía para estudios más exhaustivos en asistencia de ambientes para vivir. Y derivado que esta propuesta utiliza información semántica, es posible que la propuesta haga una interpretación del estado de salud del paciente. Y para la detección de mal de Parkinson identificable con el patrón de marcha además de utilizar SVM lineal se ha trabajado con Redes Neuronales Artificiales, con una exactitud de 78% y 68%, respectivamente (Tahir and Manap, 2012).

El congelamiento es uno de los déficits de la marcha más comunes cuando el mal de Parkinson esta en una etapa avanzada. Dicho congelamiento interfiere en las actividades y calidad de la vida diaria y debido a que esta patología es resistente a medicación, es necesario asistencia no farmacológica. (Mazilu et al., 2012) proponen un sistema con sensores vestibles compuesto de teléfono inteligente y acelerómetros para detección de congelamiento de la marcha en línea usando diferentes técnicas de aprendizaje automático. De las cuales, Bosques aleatorios y Naive Bayes obtienen el mejor desempeño, 99% y 93% de exactitud, respectivamente.

A pesar de los buenos resultados alcanzados en estos trabajos, es posible que al usar sensores inerciales y sistemas de captura de movimiento más sofisticados se puedan reconocer con mayor precisión y en otros ambientes. Además, la mayoría de trabajos descritos se centran en el contexto computacional, por ello que existe una gran necesidad de realizar más estudios para determinar las mejoras en la salud del paciente resultado de la aplicación de los algoritmos.

## 4. Conclusiones

En la actualidad el aprendizaje automático ha sido empleado de manera exitosa en varias disciplinas. La medicina ha sido una de las áreas en las que se han centrado algunas aplicaciones del aprendizaje máquina y cada día se vuelve más frecuente. Sin embargo, aún existen muchas áreas de oportunidad y problemas de investigación abiertos. Es importante desarrollar sistemas de

toma de decisiones basados en aprendizaje automático en estrecha colaboración con los expertos médicos, para que sean confiables, contextualizados en el ámbito clínico y susceptibles de compararse con los sistemas tradicionales. Se requiere desarrollar algoritmos de aprendizaje que mejoren sus prestaciones ante la falta de datos de los pacientes, la alta dimensionalidad de los mismos, la incertidumbre inherente a los ambientes médicos y que integren la mayor cantidad de información proveniente de diferentes fuentes.

Aunque en este trabajo, se han descrito algunos de los trabajos más significativos de aplicaciones particulares del aprendizaje máquina a cuestiones médicas y en particular a la fisioterapia, es necesario desarrollar más trabajos de investigación en este sentido para aumentar la confiabilidad de los expertos médicos para soportar sus decisiones en estos sistemas y hacer un análisis exhaustivo de los resultados en la salud de los pacientes. Para que con ello se incremente el uso y aplicación de estos sistemas a tareas cotidianas en el contexto fisioterapéutico con los beneficios que esto conlleva.

Finalmente, aunque el análisis de la marcha ha sido uno de los temas con mayor inferencia y estudio en la medicina física, hace falta desarrollar sistemas computacionales de aprendizaje que mejoren los procesos y análisis de resultados en este tema. Es posible desarrollar sistemas médicos automáticos de diagnóstico y toma de decisiones en el tratado de la marcha empleando aprendizaje máquina.

## English Summary

### Machine Learning for Physiotherapeutic Applications

#### Abstract

Machine learning (ML) focuses on the development of analysis systems that learn from existing data to predict or cluster future data. Recently, the ML has been developed substantially in many areas of science and engineering, being medicine one of the most interesting. In real medical environments there is a large amount of multivariable and multidimensional data, which needs to be analyzed for making decisions for diagnosis and treatments, which represents a key opportunity for ML techniques. This paper addresses a review of some of the most relevant applications of machine learning, as well as emerging trends and expectations. Subsequently, a survey is made of the most significant works of ML in medicine, with special emphasis on physiotherapeutic applications. Finally, an issue of particular interest in the context of physiotherapy is the analysis of the progress to make early diagnoses and establish efficient treatments, so a review of the work done for that purpose is made.

#### Keywords:

Machine learning, Medicine, Physiotherapy, gait analysis.

#### Agradecimientos

Este trabajo ha sido realizado gracias a la colaboración de los miembros de los cuerpos académicos de Electromecánica Industrial de la Universidad Tecnológica de Tulancingo y de

Electrónica y Control del Área Académica de Computación y Electrónica de la Universidad Autónoma del Estado de Hidalgo.

## Referencias

- Ahamed, F., & Farid, F. (2018). Applying Internet of Things and Machine-Learning for Personalized Healthcare: Issues and Challenges. *IEEE. International Conference on Machine Learning and Data Engineering (iCMLDE)* (págs. 19-21). IEEE.
- Ahangar, R. G., & Ahangar, M. F. (2009). Handwritten farsi character recognition using artificial neural network. *International Journal of computer Science and Information security*, 4(1 & 2), 1-3.
- Akay, M. F. (2009). Support vector machines combined with feature selection for breast cancer diagnosis. *Expert systems with applications*, 36(2), 3240-3247., 36(2), 3240-3247.
- Anam, K., & Al-Jumaily, A. (2015). A robust myoelectric pattern recognition using online sequential extreme learning machine for finger movement classification. *37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (págs. 7266-7269). IEEE.
- Anderson, T. W. (1962). *An introduction to multivariate statistical analysis*. New York: Wiley.
- Ar, I., & Akgul, Y. S. (2012). A computerized recognition system for the home-based physiotherapy exercises using an RGBD camera. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 22(6), 1160-1171.
- Ayodele, T. O. (2010). Introduction to machine learning. In *New Advances in Machine Learning*. IntechOpen.
- Begg, K., Palaniswami, M., & Owen, B. (2005). Support Vector Machines for Automated Gait Classification. *IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING*, 52(5), 828-838.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Singapore : Springer .
- Bulbul, H. I., & Unsal, Ö. (2011). Comparison of classification techniques used in machine learning as applied on vocational guidance data. *2011 10th International Conference on Machine Learning and Applications and Workshops*. 2, págs. 298-301. IEEE.
- Burns, D. M., Leung, N., Hardisty, M., Whyne, C. M., Henry, P., & McLachlin, S. (2018). Shoulder physiotherapy exercise recognition: machine learning the inertial signals from a smartwatch. *Physiological measurement*, 7, 075007.
- Cabitz, F., Rasoini, R., & Gensini, G. F. (2017). Unintended consequences of machine learning in medicine. *Jama*, 318(6), 517-518.
- Chang, C. V., Cheng, M. J., & Ma, M. H. (2018). Application of Machine Learning for Facial Stroke Detection. *IEEE 23rd International Conference on Digital Signal Processing (DSP)* (págs. 1-5). IEEE.
- Chang, H. K., Wu, C. T., Liu, J. H., & Jang, J. S. (2018). Using Machine Learning Algorithms in Medication for Cardiac Arrest Early Warning System Construction and Forecasting. *Conference on Technologies and Applications of Artificial Intelligence (TAAI)* (págs. 1-4). IEEE.
- Ciresan, D. C., Meier, U., Gambardella, L. M., & Schmidhuber, J. (2011). Convolutional neural network committees for handwritten character classification. *International Conference on Document Analysis and Recognition* (págs. 1315-1319). IEEE.
- Cleophas, T. J., & Zwinderman, A. H. (2013). *Machine Learning in Medicine*. New York: Springer.
- Dayan, P., & Abbott, L. F. (2001). *Theoretical neuroscience: computational and mathematical modeling of neural systems*. Cambridge: MIT Press.
- Deboeverie, F., Roegiers, S., Allebosch, G., Veela, P., & Philips, W. (2016). Human gesture classification by brute-force machine learning for exergaming in physiotherapy. *IEEE Conference on Computational Intelligence and Games (CIG)* (págs. 1-7). IEEE.
- Deo, R. C. (2015). Machine learning in medicine. *Circulation*, 132(20), 1920-1930. *Circulation*, 132(20), 1920-1930.
- Evans, B., & Fisher, D. (1994). Overcoming process delays with decision tree induction. *IEEE expert*, 9(1), 60-66. *IEEE expert*, 1, 60-66.
- Faisal, M. I., Bashir, S., Khan, Z. S., & Khan, F. (2018). An Evaluation of Machine Learning Classifiers and Ensembles for Early Stage Prediction of Lung Cancer. *3rd International Conference on Emerging Trends in Engineering, Sciences* (págs. 1-4). IEEE.

- Fatmawati, E., & Wijaya, S. K. (2017). Development Prototype System of Arm's Motor Imagery Utilizing Electroencephalography Signals (EEG) from Emotiv with Probabilistic Neural Network (PNN) as Signal Analysis. 5th International Conference on Instrumentation, Communications, Information Technology, and Biomedical Engineering (ICICI-BME) (págs. 179-183). IEEE.
- Feigenbaum, E. A. (1961). The simulation of verbal learning behavior. Western join IRE-AIEE-ACM computer conference (pág. 121.132). ACM.
- Gilbert, F. J., Astley, S. M., Gillan, M. G., Agba, O. F., Wallis, M. G., James, J., & Duffy, S. W. (2008). Single reading with computer-aided detection for screening mammography. *New England Journal of Medicine*, 359(16), 1675-1684.
- Gluck, M. A., & Rumelhart, D. E. (2013). Neuroscience and connectionist theory. Psychology Press.
- Goldberg, D. E., & Holland, J. H. (1988). Genetic algorithms and machine learning. *Machine learning*, 3(2), 95-99. *Machine learning*, 3(2), 95-99.
- Gonzalez-Islas, J. C., Godinez-Garrido, G., & Gonzalez-Rosas, A. (2018). Sistema mecatrónico para asistencia motriz a niños con discapacidad psicomotriz. *Revista de Tecnología y Educación*, 2(6), 1-9.
- Guillen, M., & Pesantez-Narvaez, J. (2018). Machine Learning and Predictive Modeling for Automobile Insurance Pricing. *Anales del Instituto de Actuarios Españoles*. (págs. 123-147).
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). The elements of statistical learning: data mining, inference, and prediction. Springer Series in Statistics.
- Jabbour, K., Riveros, J. F., Landsbergen, D., & Meyer, W. (1988). ALFA: Automated load forecasting assistant. *IEEE Transactions on Power Systems*, 3, 908-914.
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260.
- Kavakiotis, I., Tsave, O., Salifoglou, A., Maglave, N., Vlahavas, I., & Chouvarda, I. (2017). Machine learning and data mining methods in diabetes research. *Computational and structural biotechnology journal*, 15, 104-116.
- Khan, A., Doucette, J. A., Cohen, R., & Lizotte, D. (2012). Integrating machine learning into a medical decision support system to address the problem of missing patient data. *International Conference on Machine Learning and Appl.* 1, págs. 454-457. IEEE.
- Kim, Y. (2018). Application of Machine Learning to Antenna Design and Radar Signal Processing: A Review. 2018 International Symposium on Antennas and Propagation (ISAP) (págs. 1-2). IEEE.
- Kourou, K., Exarchos, T. P., Exarchos, K. P., Karamouzis, M. V., & Fotiadis, D. I. (2015). Machine learning applications in cancer prognosis and prediction. *Computational and structural biotechnology journal*, 13, 18-17.
- Kumar, S., & Kumar, D. (2016). Classification of Epileptic & Non Epileptic EEG Signal Using Matlab. *International Journal of Scientific Research in Science and Technology*, 2(4), 203-207.
- Libbrecht, M. W., & Noble, W. S. (2015). Machine learning applications in genetics and genomics. *Nature Reviews Genetics*, 321-332.
- Mannini, A., & Sabatini, A. M. (2010). Machine learning methods for classifying human physical activity from on-body accelerometers. *Sensors*, 2, 1154-1175.
- Martínez, A. J., Rodríguez-Piñero, P. T., & March, J. H. (2010). Un análisis comparativo de una svm y un modelo logit en un problema de clasificación de asegurados. In *Anales del Instituto de Actuarios Españoles*, 16, 85-110.
- Mazilu, S., Hardegger, M., Zhu, Z., Roggen, D., Tröster, G., Plotnik, M., & Hausdorff, J. M. (2012). Online detection of freezing of gait with smartphones and machine learning techniques. 6th International Conference on Pervasive Computing Technologies for Healthcare (PervasiveHealth) and Workshops (págs. 123-130). IEEE.
- McConnell, A. C., Vallejo, M., Moiola, R. C., Brasil, F. L., Secciani, N., Nemitz, M. P., & Stokes, A. A. (2017). SOPHIA: soft orthotic physiotherapy hand interactive aid. *Frontiers in Mechanical Engineering*, 3, 3.
- Menéndez, L. A., De Cos Juez, F. J., Lasheras, F., & Riesgo, J. A. (2010). Artificial neural networks applied to cancer detection in a breast screening programme. *Mathematical and Computer Modelling*, 52(7-8), 983-991., 52(7,8), 983-991.
- Obermeyer, Z., & Emanuel, E. J. (2016). Predicting the future—big data, machine learning, and clinical medicine. *The New England journal of medicine*, 375(13), 1216-1219.
- Paluszek, M., & Thomas, S. (2016). MATLAB machine learning. Apress.
- Patil, M. A., Patil, R. B., Krishnamoorthy, P., & Jhon, J. (2016). A machine learning framework for auto classification of imaging system exams in hospital setting for utilization optimization. 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) (págs. 2423-2426). IEEE.
- Patsadu, O., Nukoolkit, C., & Watanapa, B. (2012). Human gesture recognition using Kinect camera. Ninth International Conference on Computer Science and Software Engineering (JCSSE) (págs. 28-32). IEEE.
- Plis, K., Bunescu, R., Marling, C., Shubrook, J., & Schwartz, F. (2014). A machine learning approach to predicting blood glucose levels for diabetes management. Twenty-Eighth AAAI Conference on Artificial Intelligence., (págs. 35-39).
- Pogorelc, B., Bosnić, Z., & Gams, M. (2011). Automatic recognition of gait-related health problems in the elderly using machine learning. *Multimed Tools Appl*, 334-354.
- Rativa, D., Fernandes, B. J., & Roque, A. (2018). Height and Weight Estimation From Anthropometric Measurements Using Machine Learning Regressions. *IEEE journal of translational engineering in health and medicine*, 6, 1-9.
- Reamaroon, N., Sjoding, M. W., Lin, K., Iwashyna, T. J., & Najarian, K. (2019). Accounting for label uncertainty in machine learning for detection of acute respiratory distress syndrome. *IEEE journal of biomedical and health informatics*, 23(1), 407-415.
- Rodríguez-Piñero, P. T. (2007). SVM para la clasificación de asegurados en el seguro del automóvil. In *Empresa global y mercados locales: XXI Congreso Anual AEDEM* (pág. 70). Madrid: ESIC.
- Rubenfeld, G. D., Caldwell, E., Peabody, E., Weave, J., Martin, D. P., Neff, M., & Hudson, L. (2005). Incidence and outcomes of acute lung injury. *New England Journal of Medicine*, 353(16), 685-1693.
- Samuel, A. L. (1988). Some Studies in Machine Learning Using the Game of Checkers. II. Recent Progress. In *Computer Games*, 366-400.
- Senders, J. T., Zaki, M. M., Karhade, A. V., Chang, B., Gormley, W. B., Broekman, M. L., & Arnaout, O. (2018). An introduction and overview of machine learning in neurosurgical care. *Acta neurochirurgica*, 160(1), 29-30.
- Shoeb, A., Carlson, D., Panken, E., & Denison, T. (2009). A micropower support vector machine based seizure detection architecture for embedded medical devices. 2009 Annual International Conference of the IEEE Engineering in Medicine and Biology society (págs. 4202-4205). IEEE.
- Sutton, R. S., & Barto, A. G. (1998). Reinforcement learning: an introduction. Cambridge, MA.: MIT Press.
- Sweilam, N. H., Tharwat, A. A., & Moniem, A. A. (2010). Support vector machine for diagnosis cancer disease: A comparative study. *Egyptian Informatics Journal*, 2, 81-92.
- Tahir, N. M., & Manap, H. H. (2012). Parkinson Disease Gait Classification based on Machine Learning Approach. *Journal of Applied Sciences*, 12(2), 180-185.
- Tong, S., & Koller, D. (2001). Support vector machine active learning with applications to text classification. *Journal of machine learning research*, 2, 45-66.
- Urcuqui, C., & Navarro, A. (2016). Machine Learning Classifiers for Android Malware Analysis. *IEEE Colombian Conference on Communications and Computing 2016*. IEEE.
- Valgaev, O., Kupzog, F., & Schmeck, H. (2017). Building power demand forecasting using K-nearest neighbours model—practical application in Smart City Demo Aspern project. *CIREOpen Access Proceedings Journal*, 1, 1601-1604.