

Predicción de la Escala Montgomery-Asberg de Personas con Depresión Utilizando la Actividad Motriz y Técnicas de Aprendizaje Automático Supervisado.

Carlos H. Espino-Salinas¹, Pablo C. Rodríguez-Aguayo, Carlos E. Galván-Tejada^{1*}, Nubia M. Chávez-Lamas², Jorge I. Galván-Tejada¹, Hamurabi Gamboa-Rosales¹ y José M. Celaya-Padilla¹.

¹ Unidad Académica de Ingeniería Eléctrica, Universidad Autónoma de Zacatecas, Jardín Juárez 147, Centro, Zacatecas, Zac. México; dantecore2@gmail.com, js.pab.ces@gmail.com, ericgalvan@uaz.edu.mx, gatejo@uaz.edu.mx, hamurabigr@uaz.edu.mx, jose.celaya@uaz.edu.mx

² Unidad Académica de Odontología, Universidad Autónoma de Zacatecas, Jardín Juárez 147, Centro, Zacatecas, Zac. México; nubiachavez@uaz.edu.mx

La depresión constituye un problema importante de salud pública. En el mundo, representa la cuarta causa de discapacidad en cuanto a la pérdida de años de vida saludables. En México ocupa el primer lugar de discapacidad para las mujeres y el noveno para los hombres. La depresión tiene una alta co-ocurrencia con otros trastornos como la ansiedad, el consumo de sustancias, la diabetes y las enfermedades cardíacas. **Objetivo:** establecer un modelo basado en machine learning o aprendizaje automático capaz de predecir una escala de depresión en un paciente. **Materiales y métodos:** El conjunto de datos se recopiló para el estudio de la esquizofrenia y la depresión mayor a través de un reloj actigraph que mide los niveles de actividad motriz. Para generar un modelo de predicción de la escala Montgomery-Asberg fueron tomados estos mismos datos para el procesamiento y generación de un modelo de predicción. La escala Montgomery-Asberg usa puntuaciones inferiores a 10 que clasifican como ausencia de síntomas depresivos, y las puntuaciones superiores a 30 indican un estado depresivo grave, utilizando técnicas como la regresión lineal y bosques aleatorios se busca predecir estas puntuaciones que permitan prevenir estados graves de depresión. **Resultados:** se obtuvieron mediante métricas de validación como la **Raíz del Error Cuadrático Medio RECM = 3.577** y el **Error Absoluto Medio EAM = 2.857** respectivamente que indican un resultado significativamente aceptable para el caso de la regresión lineal para identificar niveles de depresión. **Conclusión:** El uso del aprendizaje automático supervisado permite tener una herramienta preventiva muy útil para casos de depresión en sus diferentes niveles, utilizando específicamente la regresión lineal para la predicción de la Escala de Clasificación de Depresión Montgomery-Asberg e implementar estas herramientas para el control de esta enfermedad.

Palabras clave: *depresión, predicción, aprendizaje automático, actividad motriz.*

1. Introducción

La escala de Montgomery-Asberg (MADRS por sus siglas en inglés) para distinguir pacientes con depresión leve, moderada, severa y extremadamente severa. Es un concepto ampliamente utilizado y tiene varias implicaciones para el tratamiento y el pronóstico. Los médicos califican diez elementos relevantes para la depresión (tristeza aparente, tristeza informada, tensión interna, sueño reducido, apetito reducido, concentración, dificultades, lasitud, incapacidad para sentir, pensamientos pesimistas, pensamientos suicidas) según la observación y la conversación con el paciente, y el puntaje de suma (0-60) indica la gravedad de la depresión. Los puntajes por debajo de 10 se clasifican como ausencia de síntomas depresivos, y los puntajes por encima de 30 indican un estado depresivo grave. MADRS (Montgomery-Asberg Depression Rating Scale) se usa para calificar la gravedad actual de una depresión en curso [1].

Existen trabajos de investigación que buscan crear herramientas automatizadas para especialistas que puedan dar un diagnóstico preliminar sobre las personas que pueden o no tener depresión en función de datos como la actividad motora del paciente, como en el caso de la extracción de características en la señal de actividad motora : Hacia la detección de episodios de depresión en pacientes unipolares y bipolares, el objetivo de este estudio fue detectar estados depresivos a través de la actividad motora de los pacientes, utilizando datos de una banda inteligente, aplicando un enfoque para la extracción de actividad, que permitirá el diagnóstico y tratamiento oportuno[8].

Dado que los problemas de salud mental están relacionados con alteraciones en los sistemas biológicos internos, existe otro caso interesante de investigación que es la Clasificación de la depresión basada en la actividad motriz en pacientes unipolares y bipolares, cuyo objetivo principal es también clasificar a los pacientes deprimidos y no deprimidos a través de dos diferentes enfoques de aprendizaje automático y medir su rendimiento utilizando métricas de validación como el F1-Score [9].

Con el desarrollo de la tecnología de análisis de big data, se ha prestado más atención a la predicción de enfermedades desde la perspectiva del análisis de big data, se han realizado varias investigaciones seleccionando las características automáticamente de una gran cantidad de datos para mejorar la precisión [10]. En base a esto, se desarrolló este trabajo, incorporando una gran cantidad de datos y seleccionando características o variables específicas para comprender mejor cómo evitar enfermedades como la depresión con la ayuda de la tecnología aplicada a los datos.

Todas estas investigaciones aportan algo importante para entender cómo se comporta esta enfermedad o como prevenirla pero no está de más mencionar que existen otras investigaciones que pretenden realizar el diagnóstico de otras enfermedades haciendo uso de técnicas de aprendizaje automático. El aprendizaje automático no es nuevo en la investigación de enfermedades. Las redes neuronales

artificiales (ANN) y los árboles de decisión (DT) se han utilizado en la detección y diagnóstico de cáncer durante casi 20 años (Simes 1985; Maclin et al. 1991; Cicchetti 1992). Hoy en día, los métodos de aprendizaje automático se están utilizando en una amplia gama de aplicaciones. Según las últimas estadísticas de PubMed, se han publicado más de 1500 artículos sobre el tema del aprendizaje automático. Sin embargo, la gran mayoría de estos documentos están relacionados con el uso de métodos de aprendizaje automático para identificar, clasificar, detectar o distinguir tumores y otras neoplasias malignas. En otras palabras, el aprendizaje automático se ha utilizado principalmente como una ayuda para el diagnóstico y la detección de enfermedades (McCarthy et al. 2004). Recientemente, los investigadores del cáncer han intentado aplicar el aprendizaje automático a la predicción y el pronóstico del cáncer. Como consecuencia, el cuerpo de literatura en el campo del aprendizaje automático y la predicción / pronóstico del cáncer es relativamente pequeño [11].

Este trabajo tiene como objetivo generar un modelo capaz de predecir una escala de calificación de depresión de un paciente deprimido mediante la aplicación de técnicas de aprendizaje automático supervisado para el procesamiento de los datos, como la regresión lineal y bosques aleatorios e incluyendo métricas de validación como la raíz del error cuadrático medio y el error absoluto medio que permiten saber en qué medida que modelo es el más adecuado o tiene mejor desempeño para ser considerado un modelo predictor aceptable y así ayudar a prevenir casos en el aumento de esta escala.

2. Materiales y Métodos

La metodología propuesta en este trabajo de investigación consta de 4 pasos principales como se muestra en la Figura 1. Inicialmente, los datos se obtienen del conjunto de datos "depresjon". Luego, el pre-procesamiento que consiste en la generación de un millón de observaciones mediante la función `rnorm` que se utiliza para obtener valores aleatorios de los 23 casos obtenidos originalmente que presentan una condición de depresión, la verificación de la ausencia de Na's o campos vacíos para evitar problemas de procesamiento de los datos. Posteriormente, el procesamiento de los datos a través de regresión lineal (RL) y bosques aleatorios (BA). Finalmente, la validación que consiste en evaluar los resultados obtenidos midiendo la raíz del error cuadrático medio (RECM) y el error absoluto medio (EAM) de cada modelo aplicado.

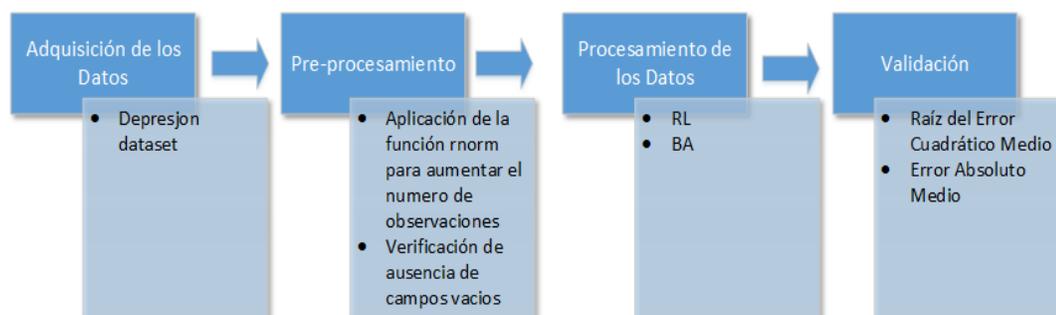


Figura 1. Diagrama de flujo de la metodología propuesta.

El conjunto de datos se recopiló originalmente para el estudio de la actividad motriz en la esquizofrenia y la depresión mayor <https://bmcsresnotes.biomedcentral.com/articles/10.1186/1756-0500-3-149>. La actividad motriz se controló con un reloj actigraph usado en la muñeca derecha (Actiwatch, Cambridge Neurotechnology Ltd, Inglaterra, modelo AW4). El reloj actigraph mide los niveles de actividad motriz. La frecuencia de muestreo es de 32 Hz y se registran movimientos superiores a 0,05 g. Se produce un voltaje correspondiente y se almacena como un recuento de actividad en la unidad de memoria del reloj actigraph. El número de conteos es proporcional a la intensidad del movimiento. Los recuentos totales de actividad se registraron continuamente en intervalos de un minuto [2].

El pre-procesamiento y procesamiento de los datos se llevó a cabo utilizando la herramienta RStudio (versión 3.5.2) [3]. Las bibliotecas utilizadas fueron las siguientes: rpart (versión 4.1 -13) [4], caret (versión 6.0-84) [5] y e1071 (versión 1.7-2).

2.1 Descripción de los datos

El conjunto de datos original contiene datos de 55 pacientes, 23 de ellos son pacientes con depresión y 32 pacientes sin depresión en dos carpetas diferentes, para cada paciente se proporciona un archivo csv que contiene los datos de actigraph recopilados a lo largo del tiempo. En este trabajo de investigación, es utilizado además de los registros de actividad motriz el archivo adicional de las puntuaciones MADRS que contiene las siguientes columnas: número (identificador del paciente), días (número de días de mediciones), género (1 o 2 para mujeres o hombres), edad (edad en grupos de edad), afftype (1: bipolar II, 2: depresivo unipolar, 3: bipolar I), melanch (1: melancolía, 2: sin melancolía), hospitalizado (1: hospitalizado, 2: ambulatorio), edu (educación agrupada en años), matrimonio (1: casado o en convivencia, 2: soltero), trabajo (1: trabajando o estudiando, 2: licencia / pensión por desempleo / enfermedad), madrs1 (puntaje MADRS cuando comenzó la medición), madrs2 (MADRS cuando la medición se detuvo).

En base a estos datos se extrajo el promedio de la actividad motriz de cada paciente con depresión registrada por medio del reloj actigraph como variable de entrada y madrs2 como la variable a predecir o de salida.

2.2 Pre-procesamiento de los datos

El pre-procesamiento de los datos consta de dos pasos: el primero que se refiere a la generación de más observaciones ya que el conjunto de datos original se encuentra muy limitado a solo 23 pacientes a los cuales se les registro la escala Montgomery-Asberg debido a esto se vio en la necesidad de aumentar este número de observaciones a un millón utilizando una herramienta conocida como

norm que facilita este proceso, que se encuentra en el programa RStudio todo esto para obtener una mayor diversidad de datos, a fin de resaltar la solidez de los resultados.

Posteriormente, la verificación de ausencia de Na's es un proceso que se llevó a cabo para generar un gráfico que permitiría una confirmación visual de la ausencia de campos vacíos o elementos inexistentes conocidos como valores de Na's que dificultarían la aplicación de las técnicas aprendizaje automático de regresión lineal y bosques aleatorios arrojando resultados dudosos o errores que no faciliten la predicción de la escala utilizada para evaluar pacientes con depresión para esto se utilizó la biblioteca Amelia para programar datos faltantes [6].

2.3 Procesamiento de los datos

El procesamiento de los datos consisten en la predicción MADRS, la información se dividió en dos conjuntos: entrenamiento y pruebas. El conjunto de entrenamiento consiste en 70 \% de la información equivalente a 700,000 pacientes y el 30 \% restante que equivale a 300,000 pacientes como un conjunto de pruebas. Posteriormente, se aplicó 2 técnicas aprendizaje automático supervisado (Regresión Lineal y Bosques Aleatorios) la Figura 2. Muestra el diagrama de regresión lineal.

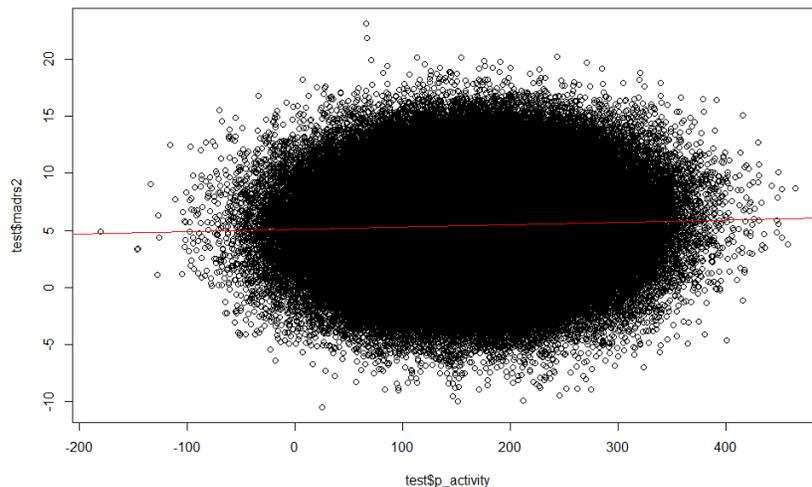


Figura 2. Distribución de los datos y recta generada para la regresión lineal.

2.4 Validación

Finalmente, los resultados se validaron utilizando métricas como la raíz del error cuadrático medio y el error absoluto medio. Cada una de estas medidas está "dimensionada" porque expresa un error promedio de predicción del modelo en las unidades de la variable de interés. Estas medidas también se han utilizado para representar la diferencia promedio (en lugar del error promedio) cuando no se conoce que un conjunto de estimaciones sea el más confiable [7]. Para obtener una

validación confiable, es importante tener en cuenta el uso de estas dos métricas y se obtenga una visión general de qué modelo de predicción es el más apropiado.

3. Resultados y Discusión

Inicialmente, se realizó un análisis del conjunto de datos final que permitiría verificar la ausencia de campos Na's para evitar errores al ejecutar el procesamiento de datos, esto se realizó mediante una función llamada mapa de errores que se encuentra en la biblioteca de Amelia que genera un gráfico que permite visualizar la ausencia de estos valores. Azul para los campos con registros y rojo para los campos de Na. La Figura 3. muestra en el lado izquierdo el gráfico de la información utilizada en este trabajo y en el lado derecho un ejemplo de un gráfico con algunos campos Na's.

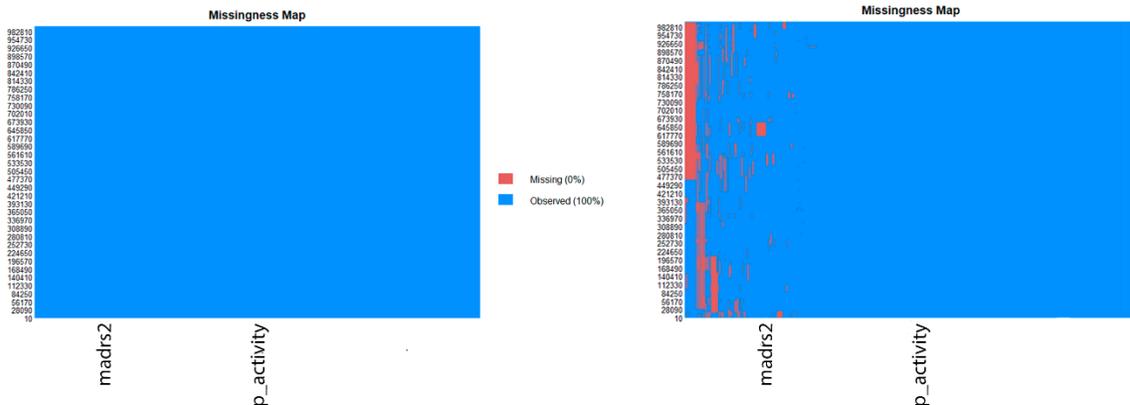


Figura 2. El grafico del lado izquierdo muestra la verificación de ausencia de Na's utilizada en esta investigación y del lado derecho el grafico que ejemplifica la existencia de campos vacíos en el conjunto de datos

Después de generar un número considerable de observaciones del promedio de la actividad motriz y su respectiva escala de Montgomery-Asberg de cada paciente se aplicaron las dos técnicas de aprendizaje automático propuestas en esta investigación y los resultados obtenidos en su validación se muestran en la tabla 1.

	REM	EAM
REGRESIÓN LINEAL	3.577	2.857
BOSQUES ALEATORIOS	3.580	2.860

Tabla 1. Resultados de las métricas de validación para cada modelo aplicado.

4. Conclusiones y Trabajos Futuros

La depresión puede volverse crónica o recurrente y obstaculizar significativamente el rendimiento laboral o la escuela y la capacidad para enfrentar la vida diaria. En su forma más grave, puede llevar al suicidio. Si es leve, se puede tratar sin medicamentos, pero cuando es moderado o severo, se pueden necesitar medicamentos y psicoterapia profesional. Como trabajo futuro, se propone aumentar el número de variables que pueden contribuir al aumento o disminución de la escala Montgomery-Asberg y aplicar algoritmos genéticos que dan como resultado los factores o variables más relevantes a considerar para comprender mejor esta enfermedad, que es más frecuente cada vez en la población y así crear modelos de predicción basados en técnicas de aprendizaje automático que combinados con hardware y software puedan ayudar evitar casos de depresión severa.

5. Bibliografía

- [1] Matthias J. Müller et al. “Differentiating moderate and severe depression using the Montgomery–Asberg depression rating scale (MADRS)”. In: *Journal of Affective Disorders* 77.3 (2003), pp. 255–260. issn: 0165-0327. doi: [https://doi.org/10.1016/S0165-0327\(02\)00120-9](https://doi.org/10.1016/S0165-0327(02)00120-9). url: <http://www.sciencedirect.com/science/article/pii/S0165032702001209>.
- [2] Enrique Garcia-Ceja et al. “Depresion: A Motor Activity Database of Depression Episodes in Unipolar and Bipolar Patients”. In: *Proceedings of the 9th ACM on Multimedia Systems Conference. MMSys’18*. Amsterdam, The Netherlands: ACM, 2018. doi:10.1145/3204949.3208125. url: <http://doi.acm.org/10.1145/3204949.3208125>.
- [6] James Honaker, Gary King, and Matthew Blackwell. “Amelia II: A Program for Missing Data”. In: *Journal of Statistical Software* 45.7 (2011), pp. 1–47. url: <http://www.jstatsoft.org/v45/i07/>.
- [7] Kenji Matsuura Cort J. Willmott. “Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance”. In: *Climate Research* 30.1 (2005). doi: 10.3354/cr030079. url: <https://www.int-res.com/abstracts/cr/v30/n1/p79-82/>.
- [3] R Core Team. The R Project for Statistical Computing. 2019. url: <https://www.r-project.org/>.
- [4] Terry Therneau and Beth Atkinson. *rpart: Recursive Partitioning and Regression Trees*. R package version 4.1-13. 2018. url: <https://CRAN.R-project.org/package=rpart>.
- [5] Max Kuhn. Contributions from Jed Wing et al. *caret: Classification and Regression Training*. R package version 6.0-84. 2019. url: <https://CRAN.R-project.org/package=caret>.
- [8] Laura A. Zanella-Calzada et al. “Feature Extraction in Motor Activity Signal: Towards a Depression Episodes Detection in Unipolar and Bipolar Patients”.

In:Diagnosics9.1 (2019).issn: 2075-4418.doi: 10.3390/diagnostics9010008.url:
<https://www.mdpi.com/2075-4418/9/1/8>.

[9] E. Garcia-Ceja et al. “Motor Activity Based Classification of Depression in Unipolar and Bipolar Patients”. In:2018 IEEE 31st International Symposium on Computer-Based Medical Systems (CBMS). June 2018, pp. 316–321.doi: 10.1109/CBMS.2018.00062.

[10] M. Chen et al. “Disease Prediction by Machine Learning Over Big Data From Healthcare Communities”. In:IEEE Access5 (2017), pp. 8869–8879.issn: 2169-3536.doi: 10.1109/ACCESS.2017.2694446.

[11] Joseph A. Cruz, David S. Wishart. Applications of Machine Learning in Cancer Prediction and Prognosis. Departments of Biological Science and Computing Science, University of Alberta Edmonton, AB, Canada T6G 2E8.
<https://doi.org/10.1177/117693510600200030>

Many of the e