

# Comparación entre Modelos de Regresión Lineal Múltiple Vs Redes Neuronales Artificiales Supervisadas en la Predicción de Calificaciones Ser Bachiller 2018-2019 del Ecuador

Comparison between Multiple Linear Regression Models Vs Supervised Artificial Neural Networks in the Prediction of Ecuadorian Ser Bachiller 2018-2019 Grades

Comparação entre Modelos de Regressão Linear Múltipla Vs Supervisão de Redes Neurais Artificiais na Predição de Ser Bachiller 2018-2019 do Equador

Sandra Viviana Guamán Luna\*  
Héctor Salomón Mullo Guaminga\*\*  
Jessica Alexandra Marcatoma Tixi\*\*\*

## Resumen

El artículo trata sobre la comparación entre modelos de Regresión Lineal Múltiple vs Redes Neuronales Artificiales supervisadas en la predicción del rendimiento académico en forma de calificaciones de la evaluación Ser-Bachiller del Ecuador, periodo 2018-2019. Esto mediante la comprobación de supuestos y el cálculo de medidas de adecuación para identificar el mejor método de predicción. Para cumplir con el objetivo se utilizó información de los resultados de las pruebas Ser-Bachiller del Ecuador en el ciclo 2018-2019 cuya base de datos se encuentra en la página oficial del Instituto Nacional de Evaluación Educativa. Se contó con 514852 estudiantes evaluados de todo el país. Con esta información se compararon modelos que predicen las calificaciones en el dominio de Matemática, Lingüístico, Científico y Ciencias Sociales, mediante factores asociados al rendimiento académico de tipo Institucional, Pedagógico, Psicosocial y sociodemográfico.

**Palabras clave** : Ser Bachiller, Calificaciones, Rendimiento Académico, Regresión Lineal, Redes Neuronales.

## Abstract

The article deals with the comparison between Multiple Linear Regression models vs supervised Artificial Neural Networks in the

### How to cite:

Guamán, S., Mullo, H., Marcatoma, J. (2023) Comparación entre Modelos de Regresión Lineal Múltiple Vs Redes Neuronales Artificiales Supervisadas en la Predicción de Calificaciones Ser Bachiller 2018-2019 del Ecuador. *Revista Iberoamericana De educación*, 7(2).

Received: October, 2022  
Approved: January, 2023

DOI:  
<https://doi.org/10.31876/ri.e.v6i4.238>

<http://www.revista-iberoamericana.org/index.php/es>

\* Universidad Nacional de Chimborazo, Facultad de Ciencias, Ecuador.

sandraguaman2190@gmail.com  
<https://orcid.org/0009-0005-5285-2867>

\*\* Master, "Escuela Superior Politécnica de Chimborazo, Facultad de Ciencias, Ecuador, hmullo@epoch.edu.ec; Instituto Nacional de Evaluación Educativa, Ecuador,

hector.mullo@evaluacion.gob.ec", <https://orcid.org/0000-0001-8448-4652>

\*\*\* Universidad Nacional de Chimborazo, Facultad de Ingeniería, Ecuador.

jessica.marcatoma@unach.edu.ec  
<https://orcid.org/0000-0001-9531-3234>

prediction of academic performance in the form of grades of the Ser-Bachiller evaluation of Ecuador, period 2018-2019. This by testing assumptions and calculating adequacy measures to identify the best prediction method. To meet the objective, information from the results of the Ser-Bachiller tests of Ecuador in the 2018-2019 cycle whose database is located on the official website of the National Institute of Educational Evaluation was used. There were 514852 students evaluated from all over the country. With this information we compared models that predict the scores in the domains of Mathematics, Linguistics, Science and Social Sciences, through factors associated with academic performance of Institutional, Pedagogical, Psychosocial and sociodemographic type.

**Key words:** : Ser Bachiller, Grades, Academic Performance, Linear Regression, Neural Networks.

### **Abstrato**

O artigo trata da comparação entre os modelos de Regressão Linear Múltipla vs Redes Neurais Artificiais supervisionadas na previsão do desempenho acadêmico sob a forma de notas da avaliação Ser-Bachiller do Equador, período 2018-2019. Isto é feito testando pressupostos e calculando medidas de adequação para identificar o melhor método de previsão. Para cumprir o objectivo, foram utilizadas informações dos resultados dos testes Ser-Bachiller do Equador no ciclo 2018-2019, cuja base de dados pode ser encontrada no site oficial do Instituto Nacional de Avaliação Educacional. Foram avaliados 514852 estudantes de todo o país. Com esta informação comparamos modelos que prevêem notas nos domínios da Matemática, Linguística, Ciência e Ciências Sociais, através de factores associados ao desempenho académico de tipo Institucional, Pedagógico, Psicossocial e Sociodemográfico.

**Palavras-chave:** : Ser Bachiller, Notas, Desempenho Académico, Regressão Linear, Redes Neurais.

### **INTRODUCCIÓN**

La Ley Orgánica de Educación Intercultural (LOEI) del Ecuador en sus articulados establece que el Instituto Nacional de Evaluación Educativa (Ineval) tiene la competencia para realizar las evaluaciones del Sistema Nacional de Educación, tanto internas como externas. En este sentido Ineval desarrolla la Prueba Nacional de Evaluación Educativa Ser Bachiller (SBAC), que examina el rendimiento académico (INEVAL, 2019), que los sustentantes deben lograr al culminar la educación secundaria en los dominios de Matemática,

Lingüística, Científica y Estudios Sociales (Edel Navarro , 2003). Esto es importante, ya que la prueba SBAC evalúa básicamente el rendimiento académico mínimo que los estudiantes deben tener para, por un lado, enfrentar estudios de educación superior (Waples & Darayseh, 2005) y, por otro lado, tener un buen desarrollo como ciudadanos (Elola & Toranzos, 2000).

Las investigaciones sobre el rendimiento académico de los estudiantes de educación secundaria han demostrado la influencia de las variables del entorno estudiante, aula y/o escuela en el rendimiento académico (Marsh et al., 2018; Rossi et al., 2020; Cheng & Kaplowitz, 2016; Zamudio et al., 2019). Existen varios estudios que se clasifican en dos enfoques, los primeros, consideran el entorno alumno, aula, escuela, etc., es decir, realizan estudios Multinivel (Correa, 2004). En el segundo enfoque, se realizan estudios de regresión sin considerar los entornos jerárquicos donde se encuentran los estudiantes, en otras palabras, son estudios de tipo No Multinivel. En general dentro de los estudios de tipo Multinivel y No Multinivel se han considerado factores de tipo INSTITUCIONAL (como los horarios de los cursos, los tamaños de los grupos, número de libros en la biblioteca del centro educativo, los tamaños de los grupos, número de libros en la biblioteca del centro educativo, aspectos relacionados con la carrera que sigue el estudiante, el ambiente institucional, etc.); PEDAGÓGICOS (capacidad del docente para comunicarse, las relaciones que establece con el alumno y las actitudes que adopta hacia el estudiante, etc.); PSICOSOCIALES (la motivación, la ansiedad, la autoestima en contextos académicos y la percepción que el estudiante tiene del clima académico, etc.) (Valle Arias y otros, 1998); SOCIODEMOGRÁFICOS (sexo, edad, nivel económico, tipo de colegio, nivel educativo de los padres de familia, etc.) (Montero Rojas y otros, 2007).

La predicción del rendimiento académico universitario ha recibido una atención considerable en el área de la educación (Zhang & Li, 2018) , ya que predecir si el estudiante puede presentar un bajo rendimiento lo más rápido posible es estratégico para que las instituciones educativas comiencen a actuar de manera preventiva para subsanar las posibles deficiencias y garantizar un buen entorno de enseñanza-aprendizaje para todos los actores de la educación (Namoun & Alshantqiti, 2021). Por otro lado, la capacidad de predecir el rendimiento académico puede ayudar a descubrir estudiantes con alto potencial (Tatar & D'us teg'or, 2020). Sin embargo, se ha prestado poca atención a este tema en la educación secundaria. En este sentido en el Ecuador, un método de predicción de las

calificaciones en base a los factores asociados puede ser de gran interés, para predecir estudiantes con bajo, mediano y alto rendimiento académico y de esta manera planificar capacitaciones y/o refuerzos a estudiantes de bajo rendimiento y asignar becas a estudiantes con alto rendimiento académico (Zamudio y otros, 2019). Por lo tanto, la presente investigación compara los modelos de regresión lineal múltiple vs redes neuronales artificiales supervisadas en la predicción del rendimiento académico en forma de calificaciones de la evaluación Ser Bachiller, periodo 2018-2019, mediante la comprobación de supuestos y el cálculo de medidas de adecuación para identificar el mejor método de predicción.

Para cumplir con el objetivo del presente trabajo, se consideran los datos libres publicados por el Ineval del proceso de evaluación Ser Bachiller 2018-2019 junto con los factores de tipo Institucionales, Pedagógicos, Psicosociales y Sociodemográficos de la evaluación (Tejedor Tejedor F. , 2003). Dentro de estos factores se tienen variables con incidencia significativa en el rendimiento académico (GONZALES TIRADOS , 1989). Entre las características consideradas se tiene edad, género, ámbito institucional, estado civil, trabajo, discapacidad, año de nacimiento, nota obtenida en el dominio Matemático, Lingüístico, Científico y Estudios Sociales.

Estudios de factores asociados al rendimiento académico: En el Ecuador se han desarrollado varios estudios a lo largo de los años sobre evaluaciones estandarizadas a gran escala dirigidas a estudiantes del sistema nacional de educación como son las pruebas: PISA, Ser Estudiante en la Infancia, Ser Estudiante, Ser Bachiller y Ser Estudiante Bachillerato Técnico (Ineval, 2022a,2022b,2022c). En referencia a las pruebas Ser Bachiller y el estudio de factores asociados se cuenta con algunos estudios, por ejemplo, en Argentina (INGRESO A LA UNIVERSIDAD EN ECUADOR, CUBA Y ARGENTINA); (La Brecha de Género en Matemática en Ecuador: Evidencia desde las pruebas “Ser Estudiante” y “Ser Bachiller”); (Factores institucionales, pedagógicos, psicosociales y sociodemográficos asociados al rendimiento académico en la Universidad de Costa Rica: Un análisis multinivel), entre otros. En el mismo sentido, en Ecuador se realizó el Examen Ser Bachiller, donde se analizó los factores que inciden en el rendimiento académico de los estudiantes de educación media en Ecuador (Cheng & Kaplowitz, 2016), aunque delimitar exactamente el número de factores asociados ha sido una tarea difícil a través de los años (Tejedor Tejedor & García-Valcárcel Muñoz-Repiso, Ana, 2007). Estos estudios, utilizan

herramientas matemáticas de análisis de datos como son los métodos de regresión lineal y redes neuronales.

Regresión lineal: Una forma genérica del modelo de regresión lineal múltiple que es ampliamente utilizado se describe a continuación:

$$\hat{y}_i = b_0 + \sum_{j=1}^k b_j x_{ji} + \varepsilon_i,$$

donde,  $b_j$  son los parámetros del modelo para  $j = 0, 1, \dots, k$  con  $k$  el número de variables predictoras denotadas por  $x_j$ ,  $\varepsilon_i$  los errores aleatorios e  $\hat{y}_i$  los valores predichos para el individuo  $i$  –ésimo.

Este modelo tiene suposiciones (Rojo, 2007), con respecto al error aleatorio  $\varepsilon$ , esto son: i) Linealidad, ii) Homocedasticidad, iii) Normalidad e iv) independencia (Rojo Abuín, 2007). Este modelo se puede ajustar rápidamente en el software estadístico R mediante el comando  $\text{lm}(\cdot)$  de la paquetería básica.

El modelo de regresión lineal es muy utilizado en el quehacer académico, sin embargo, tiene las siguientes limitaciones en la práctica; i) no siempre se cumple con los supuestos del error aleatorio y ii) las relaciones entre las variables  $x$  e  $y$  no siempre son lineales. Al respecto, se tiene algunas alternativas de modelos que no tienen estas limitaciones como, por ejemplo, los modelos de redes neuronales que se describen a continuación.

Redes Neuronales: Una red neuronal artificial es conocida como nodo, neurona, celda o unidad en procesamiento (Berzal, 2018), en donde se utiliza el elemento  $X$  que representan las entradas, es decir, todas las señales que provienen de otras neuronas las cuales son capturadas por las dendritas. También se utiliza  $W$  que representan los pesos o intensidades de la sinapsis que conecta dos neuronas, en los cuales tanto  $X$  como  $W$  tienen valores reales. Además,  $\theta$  es la función umbral que la neurona debe sobrepasar para activarse. En este contexto los estímulos son los vectores  $(x_1, x_2, \dots, x_n)$ , estos se multiplicada por el correspondiente peso del siguiente modo:

$$(w_1 x_1, w_2 x_2, \dots, w_n x_n) = \sum_{j=1}^n w_j x_j.$$

El estímulo es procesado en el núcleo mediante la operación:

$$\varphi \left( \sum_{j=1}^n w_j x_j + b \right) = \varphi(X^t W + b),$$

donde  $\varphi$  es la función de transferencia o activación y  $b$  es el parámetro de sesgo o también conocido como bias.

Las redes neuronales tienen varias ventajas (Matich, 2001), entre las cuales podemos enumerar las siguientes: i) es robusto y tolerante a

fallos; ii) es flexible, es decir, se ajusta a diferentes ambientes por medio de un proceso de aprendizaje; iii) puede manejar información imprecisa, con ruido o inconsistente; iv) es altamente paralelo, v) es pequeño, compacto y el consumo de energía es mínima y vi) no tiene suposiciones (Toprak & Kalkan, 2022).

## **MATERIALES Y MÉTODOS**

Para este trabajo se utilizó información de los resultados de las pruebas Ser Bachiller del Ecuador en el ciclo 2018-2019 cuya base de datos se encuentra en la página oficial del Instituto Nacional de Evaluación Educativa. En este ciclo se contó con 514852 estudiantes evaluados de todo el país, es importante indicar que este proceso de evaluación es de tipo censal.

Para alcanzar los objetivos de este trabajo se seleccionó factores de tipo Institucional, Pedagógico, Psicosocial y sociodemográfico (León Altamirano & Oña Pillajo, 2018). De estos factores se tuvo las siguientes variables de tipo cualitativo: sexo (tp\_sex) (Garkaz y otros, 2011), financiamiento de la escuela (financiamiento), etnia (etnibbe), nivel educativo del padre (niepbbe), nivel educativo de la madre (niembbe), amistad con el maestro/a (relmabe), efecto de las acciones (afutbbe), interés del maestro/a (inmeabe), educación vocacional (ovocabe), calidad de los conocimientos adquiridos (inciabe), si el estudiante demuestra amabilidad (amabbbe), si te consideras una persona positiva (posiabe), si te sientes rechazado por el resto (srecabe), si el estudiante trabaja (ctracbe) y si los maestros faltan a clases (inapbbe). Además, se contó con las variables de tipo cuantitativo: Índice socioeconómico (isec) (Mizala & Romaguera, 2001), año de nacimiento del sustentante (na\_ena) (Houston & Rimmer, 2005), nota obtenida en matemática (imat), nota obtenida en lengua (ilyl), nota obtenida en científico (icn), nota obtenida en estudios sociales (ies) (Álvaro Page y otros, 1990). Se discretizaron las variables de tipo cualitativo quedando variables dicotómicas.

El análisis de los datos del rendimiento académico de los estudiantes en los dominios de Matemática, Lingüístico, Científico y Ciencias Social, se realizó por institución educativa (amie) considerando aquellas amie con más de 300 sustentantes para asegurar la convergencia del algoritmo de red neuronal con 2 capas de 5 y 3 neuronas por capa. Se utilizaron los modelos de Regresión Lineal Múltiple y Redes Neuronales Artificiales Supervisadas (P. Mohd Arsad, 2014). Además, en la identificación del mejor modelo de

predicción de calificaciones se calculó las medidas de adecuación: i) Desviación Media Absoluta (MAD), ii) Error Cuadrático Medio (MSE), iii) Error Porcentual Absoluto Medio (MAPE), iv) Error Porcentual Medio (MPE), v) Coeficiente U Theil y el vi) Test de Diebolt Mariano. El proceso de análisis se realizó utilizando el software estadístico R.

Se seleccionaron 172 instituciones educativas del Ecuador para el estudio considerando que tengan más de 300 sustentantes. El 18.97% de las amien fueron de la provincia de Pichincha, seguido por 34.48% de Guayas, 9.20% de Manabí y el resto con porcentajes inferiores a 9.00%. Los porcentajes de las variables cualitativas se informan a continuación:

**Tabla 1.** *Porcentajes de las variables cualitativas de los sustentantes del proyecto de evaluación Ser Bachiller ciclo 2018-2019.*

Variable	Característica	Porcentaje	Variable	Característica	Porcentaje
<b>Sexo</b>	Mujer	53.76 %	relmabe	No	9.86 %
	Hombre	46.24 %		Si	90.14 %
<b>Etnia</b>	Minoría étnica	12.81 %	afutbbe	Frecuentemente	80.7 %
	Otra	87.19 %		Muy frecuentemente	19.3 %
<b>Niepbbe</b>	Otro	91.88 %	inmeabe	No	9.71 %
	Universitario	8.12 %		Si	90.29 %
<b>Niembbe</b>	Otro	90 %	ovocabe	Acuerdo	77.37 %
	Universitario	10 %		Desacuerdo	22.63 %
<b>Inciabe</b>	Nunca	8.24 %			
	Siempre	91.76 %			

Elaborado: Autores

De la tabla anterior se resalta que el 53.76% de los sustentantes fueron mujeres, el 12.81% de minorías étnicas y los padres tuvieron estudios universitarios con el 10% en madres y 8.12% en padres.

## RESULTOS

Sobre las variables cuantitativas se presenta el promedio y la desviación estándar en la siguiente tabla:

**Tabla 2.** Estadísticos descriptivos de las variables cuantitativas de los sustentantes del proyecto de evaluación Ser Bachiller ciclo 2018-2019.

Variable	Estadístico	Valor
<b>isec</b>	Media	-0.02
	Desviación estándar	0.97
<b>imat</b>	Media	7.58
	Desviación estándar	0.92
<b>Ilyl</b>	Media	7.7
	Desviación estándar	0.92
<b>Icn</b>	Media	7.48
	Desviación estándar	1.02
<b>Ies</b>	Media	7.46
	Desviación estándar	1.03

Elaborado: Autores

El promedio del índice socioeconómico fue de -0.02 con una desviación estándar de 0.97. En comparación de las notas promedio por campos la mayor nota es para Lengua y Literatura, seguido de Matemática, Ciencias Naturales y Estudios Sociales. Las desviaciones estándar de los campos son muy similares.


Se calculó la correlación de Pearson entre las notas por campo y el índice socioeconómico, dando las puntuaciones de 0.24, 0.26, 0.22 y 0.21 para Matemática, Lengua y Literatura, Ciencias Naturales y Estudios Sociales respectivamente. Todas estas correlaciones fueron significativas al 95% de confianza.

Seguido se desarrolló el ajuste de modelos de regresión lineal múltiple y Redes Neuronales Artificiales Supervisadas (con 2 capas

de 5 y 3 neuronas por capa) para 172 instituciones educativas del Ecuador considerando las variables descritas en el apartado de metodología de este documento. Para el caso de los modelos de regresión se estudió los supuestos de Linealidad, Homocedasticidad, Normalidad e Independencia. En general los modelos no cumplieron con los supuestos de linealidad, homocedasticidad e independencia, sin embargo, más del 80% de los modelos cumplieron con normalidad en todos los campos evaluados.

Para la identificación del mejor modelo de predicción de calificaciones de estudiantes en el proyecto de evaluación Ser Bachiller 2018-2019 de Ecuador, se obtuvo para cada modelo los valores de las medias de adecuación i) Desviación Media Absoluta (MAD), ii) Error Cuadrático Medio (MSE), iii) Error Porcentual Absoluto Medio (MAPE), iv) Error Porcentual Medio (MPE) y v) Coeficiente U Theil. Además, se desarrolló el Test de Diebolt Mariano. La idea de las medidas de adecuación es medir la capacidad predictiva de los modelos, por lo tanto, mientras más pequeñas sean estas medidas mejor es el modelo. Mientras que el Test de Diebolt Mariano realiza un contraste de hipótesis que determina con un grado de confiabilidad si existe una diferencia significativa en el pronóstico utilizando regresión lineal vs redes neuronales. A continuación, se muestran gráficas comparativas del Coeficiente U Theil y del Test de Diebolt Mariano por campo evaluado en las Pruebas Ser Bachiller. Es importante indicar que el patrón que muestra el Coeficiente U Theil es el mismo visto de las demás medidas de adecuación del modelo, sin embargo, no se muestran para mejorar la presentación de los resultados.

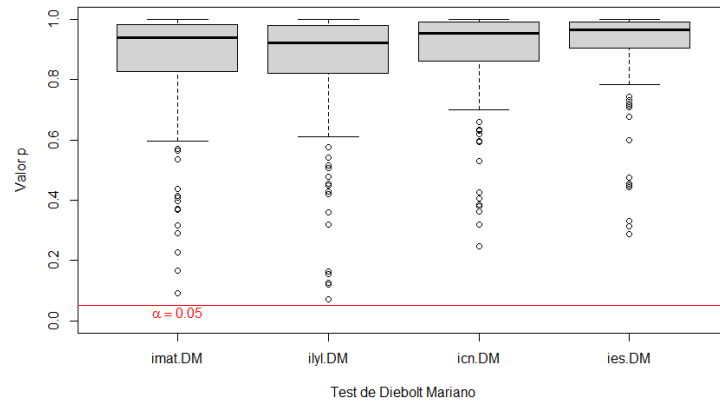
**Gráfica 1.** Coeficiente U Theil de regresión lineal múltiple (reg) y redes neuronales (rn).



Elaborado: Autores

El coeficiente U Theil permite medir la exactitud de la predicción, este coeficiente toma valores entre cero y uno, cuando más se acerque a cero la predicción es mejor. En este sentido, al comparar las distribuciones de los coeficientes U Theil entre el modelo de regresión y las redes neuronales para cada campo evaluado (Ver Gráfica 1.), observamos que en general los valores del coeficiente U Theil de regresión están por debajo de la red neuronal. Además, los valores p del Test de Diebolt Mariano son todos superiores a el nivel de significancia 0.05 (Ver Gráfica 2.). Por lo tanto, los pronósticos generados por el modelo de regresión lineal son mejores que los desarrollados mediante redes neuronales. Sin embargo, en los modelos de regresión lineal no se cumplen los supuestos de linealidad, homocedasticidad e independencia.

**Gráfica 2.** Valores p del Test de Diebolt Mariano en la comparación de los modelos de regresión lineal múltiple y redes neuronales.



Elaborado: Autores

En este punto se estudió que mejores son las predicciones de los modelos de regresión lineal en comparación de las redes neuronales, para esto se muestra en la Tabla 3. los errores porcentuales absolutos medios de cada campo evaluado. De forma global, las medias aritméticas de los MAPE son inferiores para el caso de regresión en 2.03% en promedio. Para una calificación real de 7 en Matemática, la predicción mediante regresión puede ser  $7(1 + 0.0648) = 7.4536$  y la predicción mediante redes neuronales es  $7(1 + 0.0766) = 7.5362$ , es decir, existe una discrepancia de 0.0826 en la predicción. La desviación estándar por campo y modelo de predicción son diferentes en cada caso.

En conjunto, se tiene que las predicciones mediante modelos de regresión lineal son un poco más precisas que las redes neuronales, pero los modelos de regresión lineal no cumplen con los supuestos de linealidad, homocedasticidad e independencia. Por lo tanto, en virtud de las medidas de adecuación de los modelos y las pruebas de hipótesis que contrasta la diferencia de la precisión de predicción entre los modelos, creemos que es mejor utilizar redes neuronales artificiales supervisadas en la predicción de calificaciones Ser Bachiller del ciclo 2018-2019 del Ecuador, debido a que no necesitan de la comprobación de supuestos y en promedio discrepan en un 2.03% con las predicciones de regresión lineal.

**Tabla 3.** *Error Porcentual Absoluto Medio (MAPE) de los modelos de regresión lineal y de red neuronal según campo de evaluación de Ser Bachiller ciclo 2018-2019.*

Variable	Modelo	Estadístico	Valor
<b>Imat</b>	Regresión	Media	6.48%
		Desviación estándar	1.26%
	Red Neuronal	Media	7.66%
		Desviación estándar	1.56%
<b>Ilyl</b>	Regresión	Media	6.06%
		Desviación estándar	1.37%
	Red Neuronal	Media	7.36%
		Desviación estándar	3.02%
<b>Icn</b>	Regresión	Media	7.58%
		Desviación estándar	1.82%
	Red Neuronal	Media	10.39%
		Desviación estándar	18.85%
<b>Ies</b>	Regresión	Media	7.58%
		Desviación estándar	1.82%
	Red Neuronal	Media	10.39%
		Desviación estándar	18.85%

**Elaborado:** Autores

### CONCLUSIONES

El presente estudio, se desarrolló con el objetivo de predecir el rendimiento académico de estudiantes del sistema nacional de educación secundaria del Ecuador. Para esto se comparó los modelos de regresión lineal múltiple y redes neuronales utilizando información de la evaluación estandarizada a gran escala Ser Bachiller del ciclo 2018-2019. Se utilizó las variables explicativas sexo, etnia, nivel educativo del padre, nivel educativo de la madre,

amistad con el maestro/a, efecto de las acciones, interés del maestro/a, educación vocacional, calidad de los conocimientos adquiridos, índice socioeconómico Ineval, nota obtenida en matemática, lengua y literatura, ciencias naturales y estudios sociales, para predecir las calificaciones de la evaluación Ser Bachiller. En este sentido, Montero et al. (2007) definen factores de tipo Institucional, Pedagógicos, Psicosociales y Sociodemográficos que van en sintonía de las variables descritas anteriormente. Las conclusiones más importantes se presentan a continuación:

Es importante tener un método preciso de predicción del rendimiento académico, ya que predecir qué un estudiante pueda presentar un bajo rendimiento lo más rápido posible es estratégico para las instituciones educativas que comienzan a actuar de manera preventiva para subsanar las posibles deficiencias y garantizar un buen entorno de enseñanza-aprendizaje para todos los actores de la educación. Del mismo modo, la capacidad de predecir el rendimiento académico puede ayudar a descubrir estudiantes con alto potencial.

El modelo de regresión lineal es muy utilizado en el quehacer académico, sin embargo, no siempre se cumple con los supuestos del error aleatorio y las relaciones entre las variables  $x$  e  $y$  no siempre son lineales. En contraste, las redes neuronales no necesitan la verificación de supuestos, más bien es robusto y tolerante a fallos; se ajusta a diferentes ambientes por medio de un proceso de aprendizaje; puede manejar información imprecisa, con ruido o inconsistente y es altamente paralelo.

En comparación de las notas promedio por campos de la evaluación Ser Bachiller ciclo 2018-2021, la mayor nota es para Lengua y Literatura, seguido de Matemática, Ciencias Naturales y Estudios Sociales. Las desviaciones estándar de los campos son muy similares.

Se desarrolló el ajuste de modelos de regresión lineal múltiple y Redes Neuronales Artificiales Supervisadas (con 2 capas de 5 y 3 neuronas por capa) para 172 instituciones educativas del Ecuador considerando como factores que influyen en el rendimiento académico a factores de tipo Institucional, Pedagógicos, Psicosociales y Sociodemográficos.

En general los modelos de regresión no cumplieron con los supuestos de linealidad, homocedasticidad e independencia, sin embargo, más del 80% de los modelos cumplieron con normalidad en todos los campos evaluados. Al comparar las distribuciones de los coeficientes U Theil entre el modelo de regresión y las redes neuronales para cada

campo evaluado, se concluyó que los valores del coeficiente U Theil de regresión están por debajo de la red neuronal. Además, los valores p del Test de Diebolt Mariano son todos superiores a el nivel de significancia 0.05. En este marco, los errores porcentuales absolutos medios de cada campo evaluado son inferiores para el caso de regresión en promedio en 2.03%.

Entonces, se tiene que las predicciones mediante modelos de regresión lineal son un poco más precisas que las redes neuronales, pero los modelos de regresión lineal no cumplen con los supuestos de linealidad, homocedasticidad e independencia. En virtud de las medidas de adecuación de los modelos y las pruebas de hipótesis que contrasta la diferencia de la precisión de predicción entre los modelos, creemos que es mejor utilizar redes neuronales artificiales supervisadas en la predicción de calificaciones Ser Bachiller del ciclo 2018-2019 del Ecuador.

Dentro de las limitaciones de este trabajo se encuentra que no fue posible ajustar modelos de redes neuronales por circuito, distrito o zona. Esto debido a que no se contó con la capacidad computacional necesaria para el ajuste de modelos con más de 1000 sustentantes. Por lo tanto, el trabajo futuro sería ajustar modelos de redes neuronales para predecir las calificaciones considerando agregaciones superiores a las instituciones de educación.

Otra limitación fue la gran cantidad de valores faltantes en la información de los factores de tipo Institucional, Pedagógicos, Psicosociales y Sociodemográficos de las bases de datos de Ineval. Es importante, buscar la manera reducir al máximo la falta de respuesta de los sustentantes para contar con información completa que permita ajustar modelos que describen el sistema de educación del Ecuador.

## REFERENCIAS

- Pérez Hidalgo, M., & Basulto Santos, J. (2019). *Un antecedente histórico de regresión lineal*.  
<https://gaceta.rsme.es/abrir.php?id=1519>
- Álvaro Page, M., Bueno Monreal, M. J., Calleja Sopena, J. A., Cerdán Victoria, J., Echeverría Cubias, M. J., García López, C., Gaviria Soto, J. L., Gómez Bueno, C., Jiénez Suárez, S. C., Romero, L. M.-J., Marín-Javato Romero, L., Múiguez CebaUos, A. L., Sánchez Ruiz, A., & Trillo Marco, C. (1990).

- HACIA UN MODELO CAUSAL DEL RENDIMIENTO ACADÉMICO*. Madrid: Centro de Publicaciones del Ministerio de Educación y Ciencia: C.I.D.E.
- Berzal, F. (2018). *REDES NEURONALES & DEEP LEARNING*. Granada.
- Cheng, S., & Kaplowitz, S. (2016). Family economic status, cultural capital, and academic achievement: The case of Taiwan. *International Journal of Educational Development*. 49, 271-278.  
<https://doi.org/https://doi.org/10.1016/j.ijedudev.2016.04.002>
- Correa, J. J. (abril de 2004). Determinantes del rendimiento educativo de los estudiantes de secundaria en Cali: un análisis multinivel. *Revista Sociedad y Economía*(6), 81-105.
- Edel Navarro , R. (2003). El rendimiento académico: concepto, investigación y desarrollo. *REICE. Revista Iberoamericana sobre Calidad, Eficacia y Cambio de Educación*, 1(2), 0.
- Elola, N., & Toranzos, L. (2000). *EVALUACIÓN EDUCATIVA: una aproximación conceptual*. (U. A. CRISTIANO, Editor) <http://bibliotecadigital.academia.cl/xmlui/handle/123456789/585>
- Garkaz, M., Banimahd, B., & Esmaeili , H. (2011). Factores que afectan el desempeño de los estudiantes de contabilidad: el caso de los estudiantes de la Universidad Islámica Azad. *Procedia - Social and Behavioral Sciences*, 29, 122-128.  
<https://doi.org/https://doi.org/10.1016/j.sbspro.2011.11.216>
- GONZALES TIRADOS , R. (1989). *ANÁLISIS de las causas del fracaso académico en la Universidad Politécnica de Madrid*. CENTRO DE PUBLICACIONES -Secretaría General Técnica. Ministeriode Educación y Ciencia. .
- Houston, M., & Rimmer, R. (2005). A comparison of academic outcomes for business and other students. The international journal of management education. *The International Journal of Management Education*, 4, 11-20.  
<https://doi.org/10.3794/ijme.43.96>
- INEVAL. (Noviembre de 2019). *Informe de resultados nacional Ser Bachiller Año lectivo 2018-2019*. <http://evaluaciones.evaluacion.gob.ec/BI/nacional/>
- Ineval. (2022a,2022b,2022c). *Ser Estudiante*. <http://evaluaciones.evaluacion.gob.ec/BI/ser-estudiante/>.
- León Altamirano , J., & Oña Pillajo, A. (Noviembre de 2018). *Determinantes socioeconómicos que influyen en la prueba*

- “ser bachiller” para la postulación a la educación superior, Ecuador Periodo 2016-2017. Quito.
- Matich, D. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*.
- Mizala, A., & Romaguera, P. (2001). FACTORES SOCIOECONÓMICOS EXPLICATIVOS DE LOS RESULTADOS ESCOLARES EN LA EDUCACIÓN SECUNDARIA EN CHILE. *El Trimestre Económico*, 515-549.
- Montero Rojas, E., Villalobos Palma, J., & Valverde Bermúdez, A. (2007). Factores institucionales, pedagógicos, psicosociales y sociodemográficos asociados al rendimiento académico en la Universidad de Costa Rica: Un análisis multinivel. *RELIEVE*, 13(2), 215-2234. [www.uv.es/RELIEVE/v13n2/RELIEVEv13n2\\_5.htm](http://www.uv.es/RELIEVE/v13n2/RELIEVEv13n2_5.htm)
- Namoun, A., & Alshantiti, A. (2021). Predicting student performance using data mining and learning analytics techniques: A systematic literature review. *Applied Sciences* 11, 237. <https://doi.org/10.3390/app11010237>
- P. Mohd Arsad, N. B.-I. (2014). Métodos de Redes Neuronales y Regresión Lineal para la predicción del rendimiento académico de los estudiantes. *Conferencia mundial de educación en ingeniería (EDUCON) de IEEE de 2014*, 916-921. <https://doi.org/10.1109/EDUCON.2014.6826206>.
- Pino Diez, R., Gómez Gómez, A., & de Abajo Martínez, N. (2001). *INTRODUCCIÓN A LA INTELIGENCIA ARTIFICIAL: Sistemas Expertos, Redes Neuronales Artificiales y Computación Evolutiva*. Servicio de Publicaciones Universidad de Oviedo.
- Rojo Abuín, J. M. (2007). Regresión lineal múltiple. *ACADEMIA*.
- Rojo, J. (2007). Regresión lineal múltiple. *Instituto de Economía y Geografía*, 17-23.
- Tatar, A., & Düşteğör, D. (2020). Prediction of academic performance at undergraduate graduation: Course grades or grade point average? *Applied Sciences* 10, 4967. <https://doi.org/10.3390/app10144967>
- Tejedor Tejedor, F. J., & García-Valcárcel Muñoz-Repiso, Ana. (2007). Causas del bajo rendimiento del estudiante universitario (en opinión de los profesores y alumnos). Propuestas de mejora en el marco del EEES. *Revista de EDUCACIÓN*.

- Tejedor Tejedor, F. (enero-abril de 2003). Poder explicativo de algunos determinantes del rendimiento en los estudios universitarios. *Revista de Pedagogía*, 5-32.
- Toprak, E., & Kalkan, Ö. (2022). Comparación del rendimiento de la regresión múltiple y la red neuronal artificial en la determinación del orden de importancia de los predictores en la investigación educativa. *Revista de Educación*, 233-268. <https://doi.org/https://doi.org/10.4438/1988-592X-RE-2023-399-568>
- Valle Arias, A., González Cabanach, R., Núñez Pérez, J. C., & González Pienda, J. A. (1998). Variables cognitivo-motivacionales, enfoques de aprendizaje y rendimiento académico. *Psicothema*, 10(2), 393-412.
- Waples, E., & Darayseh, M. (2005). Determinants Of Students' Performance. *Journal of College and Learning*, 2(12).
- Zamudio, P., López, F., & Reyes-Sosa, H. (2019). La representación social del fracaso escolar. *Perfiles Educativos*. 41(165), 27-42. <https://doi.org/https://doi.org/10.22201/iissue.24486167e.2019.165.59051>
- Zhang, L., & Li, K. (2018). Education analytics: Challenges and approaches, in: 2018 32nd International Conference on Advanced InformationNetworking and Applications Workshops (WAINA). 193-198. <https://doi.org/10.1109/WAINA.2018.00086>