



Desarrollo de una herramienta para el aprendizaje del abecedario Ecuatoriano, basado en redes neuronales artificiales para la enseñanza inclusiva de lenguaje de señas

Development of a tool for learning the Ecuadorian alphabet, based on artificial neural networks for the inclusive teaching of sign language

Desenvolvimento de uma ferramenta para aprender o alfabeto equatoriano, baseada em redes neurais artificiais para o ensino inclusivo da língua de sinais

Vilma Carolina Armendariz Rodríguez ^I
caritoarmendariz2@gmail.com
<https://orcid.org/0000-0002-5268-4569>

Alcibar Geovanny Chandi Enriquez ^{II}
geovannychandy1987@gmail.com
<https://orcid.org/0009-0009-5605-5565>

Alexandra de los Ángeles Milla Estrada ^{III}
alexandramilla78@gmail.com
<https://orcid.org/0000-0001-7008-3217>

Lenin Javier Gallegos Nogales ^{IV}
lening182@hotmail.com
<https://orcid.org/0000-0001-9237-3223>

Correspondencia: caritoarmendariz2@gmail.com

Ciencias de la Educación
Artículo de Investigación

* **Recibido:** 23 de mayo de 2023 * **Aceptado:** 12 de junio de 2023 * **Publicado:** 03 de julio de 2023

- I. PhD(c) en Ciencias de la Educación, Magíster en Desarrollo de la Inteligencia y Educación, Licenciada en Ciencias de la Educación, Instituto Superior Tecnológico Bolívar, Ecuador.
- II. Magíster en Educación mención TICs, Licenciado en Ciencias de la Educación, Instituto Superior Tecnológico Bolívar, Ecuador.
- III. Magíster en Educación Mención en Tecnología e Innovación Educativa, Ingeniera en Sistemas Informáticos, Instituto Superior Tecnológico Bolívar, Ecuador.
- IV. Magíster en Informática Educativa, Ingeniero de Sistemas y Computación, Instituto Superior Tecnológico Bolívar, Ecuador.

Resumen

En este estudio, se desarrolló una aplicación de lenguaje de señas utilizando una red neuronal artificial creada mediante la herramienta Teachable de Google. Se evaluaron las métricas de precisión, sensibilidad y F1 Score utilizando una matriz de confusión para medir el rendimiento del modelo.

Los resultados obtenidos fueron destacables, con una precisión del 84%, una sensibilidad del 73% y un F1 Score del 78.11%. Estas métricas indican que el modelo logra una alta precisión en la clasificación de las letras del lenguaje de señas.

La aplicación creada tiene el potencial de facilitar la comunicación entre personas con deficiencia auditiva y aquellas que no conocen el lenguaje de señas. Además, el uso de la herramienta Teachable demostró ser eficiente y accesible para la creación de modelos de redes neuronales.

Estos resultados son prometedores y sugieren que la aplicación del aprendizaje automático y la inteligencia artificial en la interpretación del lenguaje de señas puede tener un impacto positivo en la inclusión y la comunicación efectiva. Sin embargo, se deben considerar las limitaciones de la herramienta Teachable, como la falta de flexibilidad para personalizar modelos más complejos y la dependencia de la plataforma en línea de Google.

En general, este estudio proporciona una base sólida para el desarrollo de aplicaciones de lenguaje de señas basadas en redes neuronales y destaca la importancia de las métricas de evaluación, como la precisión, la sensibilidad y el F1 Score, para medir el rendimiento y la efectividad de los modelos creados.

Palabras Clave: red neuronal artificial; educación inclusiva; inteligencia artificial.

Abstract

In this study, a sign language application was developed using an artificial neural network created using Google's Teachable tool. Precision, sensitivity and F1 Score metrics were evaluated using a confusion matrix to measure model performance.

The results obtained were remarkable, with an accuracy of 84%, a sensitivity of 73% and an F1 Score of 78.11%. These metrics indicate that the model achieves high accuracy in classifying sign language letters.

The application created has the potential to facilitate communication between people with hearing impairment and those who do not know sign language. In addition, the use of the Teachable tool proved to be efficient and accessible for the creation of neural network models.

These results are promising and suggest that the application of machine learning and artificial intelligence in sign language interpretation can have a positive impact on inclusion and effective communication. However, the limitations of the Teachable tool should be considered, such as the lack of flexibility to customize more complex models and the reliance on Google's online platform. Overall, this study provides a solid foundation for the development of neural network-based sign language applications and highlights the importance of evaluation metrics, such as accuracy, sensitivity, and F1 Score, to measure performance and effectiveness. of the models created.

Keywords: artificial neural network; inclusive education; artificial intelligence.

Resumo

Neste estudo, foi desenvolvido um aplicativo de língua de sinais utilizando uma rede neural artificial criada por meio da ferramenta Teachable do Google. As métricas de precisão, sensibilidade e F1 Score foram avaliadas usando uma matriz de confusão para medir o desempenho do modelo.

Os resultados obtidos foram notáveis, com uma precisão de 84%, uma sensibilidade de 73% e um F1 Score de 78,11%. Essas métricas indicam que o modelo atinge alta precisão na classificação de letras da língua de sinais.

O aplicativo criado tem o potencial de facilitar a comunicação entre pessoas com deficiência auditiva e aquelas que não dominam a língua de sinais. Além disso, o uso da ferramenta Teachable se mostrou eficiente e acessível para a criação de modelos de redes neurais.

Esses resultados são promissores e sugerem que a aplicação de aprendizado de máquina e inteligência artificial na interpretação da língua de sinais pode ter um impacto positivo na inclusão e na comunicação efetiva. No entanto, as limitações da ferramenta Teachable devem ser consideradas, como a falta de flexibilidade para customizar modelos mais complexos e a dependência da plataforma online do Google.

No geral, este estudo fornece uma base sólida para o desenvolvimento de aplicativos de linguagem de sinais baseados em redes neurais e destaca a importância das métricas de avaliação, como precisão, sensibilidade e F1 Score, para medir o desempenho e a eficácia dos modelos criados.

Palavras-chave: rede neural artificial; Educação inclusiva; inteligência artificial.

Introducción

La inclusión es un valor fundamental en cualquier sociedad y es importante que todos los individuos tengan las mismas oportunidades para aprender y desarrollarse. Sin embargo, en el caso de las personas con discapacidades auditivas, la enseñanza tradicional puede presentar barreras significativas. En este sentido, el desarrollo de herramientas educativas basadas en tecnologías emergentes puede ser una solución eficaz para promover la inclusión en la educación.

En cuanto a las *Redes Neuronales Artificiales* (RNA), tienen una gran cantidad de aplicaciones como por ejemplo: en medicina (Antonenko et al., 2022), ingeniería (Ahmed et al., 2023), imágenes satelitales (Castelo et al., 2021), entre otras. En educación se han realizados estudios para predecir el comportamiento de los alumnos dentro de los *Massive Open Online Courses* (MOCS) (Al-azazi & Ghurab, 2023), en la predicción del rendimiento de los estudiantes y docentes (Nazaretsky et al., 2021), también se ha desarrollado el sistema de reconocimiento de comportamiento de aprendizaje donde la *Inteligencia Artificial* (IA) puede servir como el segundo ojo de los maestros, lo que puede determinar ayudar a determinar las diferencias individuales y personalizar el aprendizaje (Huang et al., 2022). Además, se han desarrollado herramientas con inteligencia artificial para identificar lenguaje de señas alrededor del mundo teniendo en cuenta que este es distinto para cada país (Arutha et al., 2023; Sethia et al., 2023).

En el ámbito educativo para necesidades especiales también se ha utilizado es así que Emiratos Arabes se ha desarrollado un modelo para este propósito utilizando que posteriormente fue evaluado tuvo una precisión del 92% también se ha utilizado esta técnica (Mouti & Rihawi, 2022) En este contexto, la utilización de redes neuronales para la enseñanza inclusiva de lenguaje de señas puede ser una opción efectiva para ayudar a las personas con discapacidades auditivas a aprender de una manera más accesible y amigable. El lenguaje de señas es un medio de comunicación importante para las personas con discapacidades auditivas y el desarrollo de herramientas que les permitan aprender de manera inclusiva es esencial para garantizar la igualdad de oportunidades en la educación.

Este proyecto tiene como objetivo el desarrollo de una herramienta basada en RNA por medio de la Herramienta Teachable de Google para la enseñanza inclusiva de lenguaje de señas.

Metodología

Se utiliza un enfoque cualitativo ya que se hacen observaciones acerca de la tasa de error de las predicciones del modelo, se utilizó como medida la precisión en una matriz de confusión, midiendo los aciertos y desaciertos del modelo.

Se utilizó la herramienta Teachable Machine para el desarrollo del modelo, se recolectaron cerca de 300 muestras por letra, siendo un total de 27 caracteres es decir alrededor de 800 muestras en total, para el aprendizaje del RNA se tomaron en cuenta 50 épocas con una tasa de aprendizaje de 0.001 y un tamaño de lote de 16.

Teachable Machine

Es una plataforma gratuita en línea proporcionada por Google que permite a los usuarios crear modelos de aprendizaje automático sin necesidad de tener experiencia en programación previa. Esta herramienta brinda la capacidad de entrenar modelos para reconocer imágenes, sonidos o poses en tiempo real, y luego exportarlos para su uso en aplicaciones web o móviles. Utilizando una técnica de aprendizaje automático conocida como "Aprendizaje Profundo", específicamente Redes Neuronales Artificiales (RNA) Teachable Machine logra entrenar modelos de manera eficiente, incluso con grandes cantidades de datos de entrenamiento. Debido a su facilidad de uso, personas de diferentes edades y niveles de habilidad utilizan esta herramienta para desarrollar proyectos creativos, educativos o comerciales.

Esta herramienta ha sido utilizada en ámbitos educativos por su facilidad de uso tanto que se ha utilizado en la enseñanza y creación de modelos de Aprendizaje de Máquina "Machine Learning" en la secundaria (Martins et al., 2023); también para la enseñanza de aprendizaje automático con niños de África (Sanusi et al., 2023), una vez que se ha creado el modelo se lo ha integrado con HTML y Java Script para hacerlo atractivo para el usuario. Se espera que esta herramienta sea una solución efectiva para las barreras lingüísticas que enfrentan las personas con discapacidades auditivas en el proceso de aprendizaje. Además, la herramienta podría ser utilizada por cualquier persona interesada en aprender el abecedario en el lenguaje de señas de manera accesible y eficaz.

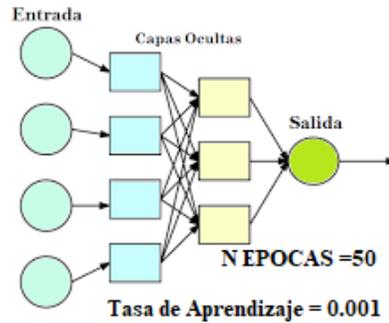


Ilustración 1. Arquitectura de la Red Neuronal Artificial

Para medir la precisión de la Red Neuronal se utilizó un matriz de confusión que se describe a continuación.

Matriz de Confusión



Ilustración 2. Esquema General de una Matriz de Confusión

Verdaderos Positivos (VP) se refiere a los casos en los que el modelo ha realizado una predicción correcta al identificar correctamente que una muestra pertenece a una clase específica. Por ejemplo, si estamos evaluando un modelo para reconocer letras del abecedario en lenguaje de señas, y consideramos la letra "A" como una clase, un verdadero positivo se daría cuando el modelo predice correctamente que una muestra es "A" y efectivamente se trata de la letra "A".

Falsos Positivos (FP) se refiere a los casos en los que el modelo de clasificación hace una predicción incorrecta al identificar erróneamente que una muestra pertenece a la clase negativa en lugar de la clase positiva. En otras palabras, el modelo "equivocadamente" descarta una característica que debería haber sido identificada como positiva. Un falso positivo es un tipo de error en el que el modelo no reconoce correctamente una muestra que debería haber sido clasificada

como positiva. Esto puede ser especialmente problemático en situaciones donde la clase positiva es relevante y no debe ser ignorada.

Un ejemplo de falso positivo en el contexto del reconocimiento del lenguaje de señas sería cuando el modelo predice incorrectamente que una muestra representa la letra "b" en lugar de la letra "a", cuando en realidad se trata de la letra "a". En este caso, la letra "b" sería la predicción del modelo (VP) y la letra "a" sería el valor real (VR). Por lo tanto, el modelo comete un error al predecir "b" en lugar de "a", lo que resulta en un falso positivo en la celda correspondiente a la fila "a" y la columna "b" de la matriz de confusión.

Falsos Negativos (FN)

Un falso negativo ocurre en un modelo de clasificación cuando el resultado predicho es negativo, pero en realidad es positivo. Esto significa que el modelo no logra detectar correctamente un resultado positivo genuino y lo clasifica erróneamente como negativo.

En el contexto de la matriz de confusión del reconocimiento del lenguaje de señas, un ejemplo de falso negativo sería cuando el valor real es la letra "A", pero el modelo predice incorrectamente que es la letra "B". En este caso, la letra "A" se consideraría un verdadero positivo (VP), mientras que la letra "B" sería un falso negativo (FN).

Verdaderos Negativos(VN)

En el contexto de una prueba de diagnóstico o predicción, un verdadero negativo (VN) se refiere a un resultado en el que el modelo o la prueba ha identificado correctamente la ausencia de una condición o característica buscada. Por ejemplo, en un modelo de reconocimiento de lenguaje de señas, un verdadero negativo sería cuando el modelo identifica correctamente una letra que no está presente en la imagen. Esto demuestra que el modelo ha dado una respuesta negativa precisa, indicando la ausencia de la letra buscada.

Resultados

Se empleó un enfoque cuantitativo para evaluar las predicciones del modelo, utilizando la tasa de error y la precisión como medidas de rendimiento. La precisión se calcula dividiendo el número de predicciones correctas entre el número total de predicciones realizadas. Además, se considera la sensibilidad, que evalúa la proporción de verdaderos positivos (TP) respecto al número total de

verdaderos positivos y falsos negativos (FN). Estas métricas permiten analizar la precisión y el alcance del modelo de clasificación utilizado.

Se utilizó la precisión como medida de rendimiento del modelo, calculando la proporción de predicciones correctas respecto al total de predicciones realizadas. Además, se empleó la sensibilidad, que evalúa la proporción de verdaderos positivos respecto al número total de verdaderos positivos y falsos negativos. Para evaluar el desempeño general del modelo, se utilizó el F1 Score, que combina tanto la precisión como la sensibilidad en una única medida. El F1 Score proporciona una forma de evaluar el rendimiento en casos de datos desequilibrados, donde ambas métricas son importantes. Un F1 Score cercano a 1 indica un buen rendimiento del modelo, mientras que un valor de 0 indica un rendimiento similar a una elección aleatoria. En general, se considera que un F1 Score por encima de 0.7 es bueno en la mayoría de los casos, a continuación se muestra la matriz de confusión de donde se ha obtenido los valores antes citados ver Tabla 1.

Como medida de rendimiento de modelo se tomó en cuenta la precisión que es la que se calcula dividiendo el número de predicciones correctas por el número total de predicciones realizadas. **# predicciones correctas / # predicciones realizadas.**

También se utiliza como medida la sensibilidad que es una métrica de evaluación de un modelo de clasificación que mide la proporción de verdaderos positivos (TP) respecto al número total de verdaderos positivos (TP) y falsos negativos (FN).

La fórmula de la sensibilidad es:

precisión = # predicciones correctas / # predicciones realizadas.

Precisión = 26/22 = 84%

Sensibilidad = TP / (TP + FN) 22/22+8 = 73%

F1 Score es una medida de evaluación de la precisión de un modelo de clasificación, que combina tanto la precisión (accuracy) como la sensibilidad (recall) en una sola medida. Es la media armónica entre la precisión y la sensibilidad:

F1 Score = 2 * (precision * recall) / (precision + recall)

F1 Score = 2*(84*73)/(84+73) = 78.11

Donde precisión se refiere a la fracción de los casos clasificados como positivos que son realmente positivos, y recall (también llamado sensibilidad) es la fracción de los casos positivos que son correctamente identificados.

El F1 Score proporciona una forma de evaluar el desempeño de un modelo de clasificación, especialmente cuando se trata de datos desequilibrados, es decir, cuando hay una cantidad significativamente mayor de una clase en comparación con otra. Es útil cuando tanto la precisión como la sensibilidad son importantes y no se puede sacrificar una por la otra.

La interpretación del F1 Score es que cuanto más cerca esté de 1, mejor será el desempeño del modelo, lo que significa que la precisión y la sensibilidad son altas. Un F1 Score de 0 indica que el modelo no es mejor que una elección aleatoria, mientras que un F1 Score de 1 indica que el modelo es perfecto. En general, se considera un buen F1 Score ya que supera el 70%

REALES

	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	r	s	t	u	v	w	x	y	z
a	x																									
b		x																								
c			x																							
d				x																						
e					x																					
f						x									x											
g							x																			
h								x																		
i									x																x	
j										x																
k											x															
l												x														
m													x	x												
n																										
o															x											
p																										
q																	x									
r				x																						

PRECISION

Esta investigación es un buen comienzo en la creación de herramientas para personas con discapacidades auditivas en Ecuador. Aunque se enfrentaron dificultades debido a la similitud de las posiciones de las manos, se logró representar el alfabeto de manera satisfactoria. Se recolectaron 300 muestras por cada letra del abecedario ecuatoriano, con un total de 26 letras (excluyendo letras dobles como LL, RR y CH).

Una desventaja de este modelo es la dependencia de Teachable, que presenta limitaciones en la personalización de modelos más complejos y requiere una gran cantidad de datos de entrenamiento para obtener resultados precisos. Además, Teachable Machine es más adecuada para proyectos de nivel básico y no se recomienda para aplicaciones críticas.

Comparado con otros modelos más complejos y sofisticados, como el presentado por Siddique et al. (2023), donde se utilizó Python y diversas bibliotecas de aprendizaje automático como OpenCV, scikit-learn y TensorFlow, se observa que se logró una mayor precisión en la identificación de gestos. En ese estudio, se emplearon técnicas de preprocesamiento de imágenes para mejorar la calidad y reducir el ruido, y se experimentó con diferentes clasificadores como Random Forest, K-Nearest Neighbors y Support Vector Machine.

Conclusiones

- Se logró obtener una precisión superior al 70% mediante el uso de una matriz de confusión, lo que demuestra que el modelo es altamente efectivo en el proceso de aprendizaje.
- Durante el desarrollo de la herramienta, se observó que existen letras en las que el modelo tiende a confundirse debido a la similitud en los rasgos de las manos al generar el alfabeto para personas con deficiencia auditiva.
- La herramienta Teachable se destaca por su facilidad de uso y su capacidad para crear modelos basados en redes neuronales. Esto abre oportunidades para la creación de herramientas educativas inclusivas basadas en algoritmos de inteligencia artificial.

El uso de RNA es un amplio campo que aún no ha sido muy explotado en educación y menos aún en educación inclusiva.

Referencias

Ahmed, T., Mita, A. F., Ray, S., & Haque, M. (2023). Engineering properties of concrete incorporating waste glass as natural sand substitution with tin can fiber: Experimental and

- Ann Application. *Journal of Engineering and Applied Science*, 70(1).
<https://doi.org/10.1186/s44147-023-00224-6>
- Al-azazi, F. A., & Ghurab, M. (2023). Ann-LSTM: A deep learning model for early student performance prediction in MOOC. *Heliyon*, 9(4).
<https://doi.org/10.1016/j.heliyon.2023.e15382>
- Antonenko, D., Fromm, A., Thams, F., Grittner, U., Meinzer, M., & Flöel, A. (2022). Microstructural and Functional Plasticity Following Repeated Brain Stimulation during Cognitive Training in Non-Demented Older Adults. <https://doi.org/10.21203/rs.3.rs-2304556/v1>
- Castelo, M. J., Buñay, G., & Pillajo, B. (2021). Uso de Redes Neuronales Artificiales y Computación en la Nube para clasificar la cobertura del suelo en territorio ecuatoriano. *POLO DE CONOCIMIENTO*, 6(5), 14–28. <https://doi.org/10.23857/pc.v6i5.2628>
- Das, S., Imtiaz, Md. S., Neom, N. H., Siddique, N., & Wang, H. (2023). A hybrid approach for Bangla sign language recognition using deep transfer learning model with random forest classifier. *Expert Systems with Applications*, 213, 118914.
<https://doi.org/10.1016/j.eswa.2022.118914>
- Fotso, J. E., Batchakui, B., Nkambou, R., & Okereke, G. (2022). Algorithms for the development of deep learning models for classification and prediction of learner behaviour in moocs. *Artificial Intelligence for Data Science in Theory and Practice*, 41–73.
https://doi.org/10.1007/978-3-030-92245-0_3
- Huang, Y.-M., Cheng, A.-Y., & Wu, T.-T. (2022). Analysis of learning behavior of human posture recognition in Maker Education. *Frontiers in Psychology*, 13.
<https://doi.org/10.3389/fpsyg.2022.868487>
- K, A., P, P., & Poonia, R. C. (2023). List: A lightweight framework for continuous indian sign language translation. *Information*, 14(2), 79. <https://doi.org/10.3390/info14020079>
- Martins, R. M., von Wangenheim, C. G., Rauber, M. F., & Hauck, J. C. (2023). Machine learning for all!—introducing machine learning in middle and high school. *International Journal of Artificial Intelligence in Education*. <https://doi.org/10.1007/s40593-022-00325-y>
- Mouti, S., & Rihawi, S. (2022). Special needs classroom assessment using a sign language communicator (CASC) based on artificial intelligence (AI) techniques. *International Journal of E-Collaboration*, 19(1), 1–15. <https://doi.org/10.4018/ijec.313960>

- Nazaretsky, T., Bar, C., Walter, M., & Alexandron, G. (2021). Empowering Teachers with AI: Co-Designing a Learning Analytics Tool for Personalized Instruction in the Science Classroom. <https://doi.org/10.35542/osf.io/krynm>
- Sanusi, I. T., Sunday, K., Oyelere, S. S., Suhonen, J., Vartiainen, H., & Tukiainen, M. (2023). Learning machine learning with young children: Exploring informal settings in an African context. *Computer Science Education*, 1–32. <https://doi.org/10.1080/08993408.2023.2175559>
- Sethia, D., Singh, P., & Mohapatra, B. (2023). Gesture recognition for American sign language using Pytorch and Convolutional Neural Network. *Lecture Notes in Electrical Engineering*, 307–317. https://doi.org/10.1007/978-981-19-6581-4_24
- Siddique, S., Islam, S., Neon, E. E., Sabbir, T., Naheen, I. T., & Khan, R. (2023). Deep learning-based Bangla sign language detection with an edge device. *Intelligent Systems with Applications*, 18, 200224. <https://doi.org/10.1016/j.iswa.2023.200224>

© 2023 por los autores. Este artículo es de acceso abierto y distribuido según los términos y condiciones de la licencia Creative Commons Atribución-NoComercial-CompartirIgual 4.0 Internacional (CC BY-NC-SA 4.0) (<https://creativecommons.org/licenses/by-nc-sa/4.0/>).