Desarrollo, entrenamiento y evaluación de modelos de machine learning para clasificación de imágenes

Romeo Federico Florentín Páez¹, Antonio David Ruiz Díaz Medina²

RESUMEN

Introducción: El machine learning posee numerosas ventajas, pero el rendimiento de la inteligencia artificial desarrollada varía de acuerdo con los hiper parámetros que se introducen dentro de la configuración del modelo de esta. Al diseñar un modelo de machine learning, el objetivo del desarrollador debe ser ajustar óptimamente la configuración para así producir un modelo con un alto nivel de precisión a través de la reducción de la función de pérdida ya que el entrenamiento de estos modelos demanda una cantidad considerable de tiempo y dinero.

Objetivo: Analizar el rendimiento de distintos modelos de machine learning para la tarea de clasificación del conjunto de imágenes Fashion MNIST.

Metodología: Investigación de enfoque cuantitativo con diseño cuasi-experimental. Las variables independientes fueron los algoritmos de optimización SGD con momentum, AdaGrad, AdaDelta, Adam, Adamax y RMSProp. Y la variable independiente fue la función de pérdida (loss).

Para analizar el rendimiento de los modelos se utilizó el conjunto de datos Fashion MNIST, que consiste en 70.000 imágenes de artículos de vestir. Luego, se desarrollaron 6 modelos de machine learning, cada uno con un algoritmo de optimización mencionado anteriormente. La codificación fue hecha en una instancia N1 con GPU Nvidia Tesla T4 de Google Cloud Computing, ejecutando JupyterLab con Python. El conjunto de datos se dividió de la siguiente forma: 55.000 imágenes se utilizaron para el entrenamiento de los modelos, 5.000 imágenes para validación del modelo y 10.000 imágenes para pruebas de los modelos.

El entrenamiento consistió en 1000 iteraciones para cada modelo. Ya, para la evaluación de los modelos se utilizó la métrica de función de pérdida, calculada

1. Universidad Nacional de Canindeyú, Facultad de Ciencias y Tecnología, Paraguay.

2. Universidad Nacional de Canindeyú, Facultad de Ciencias y Tecnología, Paraguay, Tutor.

E-mail: davidruizdiaz@facitec.edu.py

Trabajo final de grado para optar al título de Licenciado en Análisis de Sistemas presentado a la Universidad Nacional de Canindeyú.

DOI:10.26885/rcei.foro.2020.175

utilizando el framework TensorFlow y el software wandb. También se realizaron comparaciones por medio de las pruebas de Friedman y Wilcoxon, utilizando el lenguaje de programación R y el IDE RSTUDIO.

Resultados: Los resultados de la comparación de rendimiento entre los algoritmos optimizadores indican que entre los de mejor rendimiento se encuentran Adam y Adamax. Los cuales tuvieron una mayor reducción de la función de pérdida (<0.1), siendo Adamax el de mejor resultado (0.084). La prueba de Friedman revela que existen diferencias significativas entre los algoritmos de optimización. Por lo cual se acepta la hipótesis: “Al cambiar el algoritmo de optimización de los modelos de machine learning, el rendimiento de estos varía”. Por otra parte, La prueba de Wilcoxon por pares revela que existen diferencias significativas entre todos los algoritmos para todos los grupos de optimizadores.

Conclusiones: Se constató que existe una diferencia significativa entre los algoritmos optimizadores para modelos de machine learning desarrollados. Como era de esperarse, los algoritmos Adam y Adamax obtuvieron los mejores resultados, ya que combinan las características más ventajosas que los demás algoritmos.

La mayoría de los algoritmos tuvieron un rendimiento relativamente estable, lo que indica que siguieron el camino negativo de la gradiente, sin oscilar en la dirección contraria. Este no es el caso del algoritmo de optimización RMSprop, que quedó atrapado en un mínimo local del que no logro recuperarse a lo largo de 1000 iteraciones.

Palabras clave: *machine learning*, algoritmos de optimización, descenso de gradientes.

REFERENCIAS

- Dauphin, Y., Vries, H., Chung, J., & Bengio, Y. (2015). RMSProp and equilibrated adaptive learning rates for non-convex optimization. *arXiv*, 35.
- Dogo, E. M., Afolabi, O. J., Nwulu, N. I., Twala, B., & Aigbavboa, C. O. (2018). A Comparative Analysis of Gradient Descent-Based Optimization Algorithms on Convolutional Neural Networks. *2018 International Conference on Computational Techniques, Electronics and Mechanical Systems (CTEMS)* (pp. 92–99).
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Google Developers. (2020, March 5). Glosario sobre aprendizaje automático. *Aprendizaje automático*. <https://developers.google.com/machine-learning/glossary/>
- Hallén, R. (2017). *A Study of Gradient-Based Algorithms*.