



Tipo de artículo: Artículos originales  
Temática: Inteligencia artificial  
Recibido: 07/09/2023 | Aceptado: 18/11/2023 | Publicado: 30/03/2024

Identificadores persistentes:  
DOI: [10.48168/innosoft.s15.a125](https://doi.org/10.48168/innosoft.s15.a125)  
ARK: [ark:/42411/s15/a125](https://nbn-resolving.org/urn:ark:/42411/s15/a125)  
PURL: [42411/s15/a125](https://purl.org/urn:42411/s15/a125)

## **Análisis de sentimiento en Twitter en relación a la tecnología IA para generación de imágenes**

### *Sentiment analysis on Twitter in relation to AI technology for image generation*

Antony Pyero Rosales Espinoza <sup>1</sup>, Juan Carlos Gonzales Suarez <sup>2</sup>

<sup>1</sup> Universidad Católica Sedes Sapientiae, Junin-Tarma, Perú. [2015101350@ucss.pe](mailto:2015101350@ucss.pe)

<sup>2</sup> Universidad Católica Sedes Sapientiae, Junin-Tarma, Perú. [jgonzaless@ucss.pe](mailto:jgonzaless@ucss.pe)

\* Autor para correspondencia: [2015101350@ucss.pe](mailto:2015101350@ucss.pe)

---

#### **Resumen**

El avance en la tecnología de inteligencia artificial (IA) ha llevado a mejoras significativas en la generación de imágenes en términos de velocidad y calidad. Sin embargo, se ha generado preocupación e incertidumbre entre los artistas, quienes temen ser reemplazados por la IA en su campo de trabajo. En este contexto, se tuvo como objetivo el análisis de los Tweets donde se define el impacto de la inteligencia artificial (IA) en la adopción de tecnologías de generación de imágenes. Para ello, se llevó a cabo la recopilación, creación y evaluación de una red neuronal convolucional que clasifique los datos según un análisis de sentimiento entre positivo y negativo. Finalmente, la investigación se determinó la tasa de pérdida de un 63%, la precisión con un 61% y la curva ROC alrededor de un 64% de una red neuronal convolucional para la predicción de Tweets.

**Palabras clave:** Inteligencia artificial, Análisis de sentimiento, Red neuronal convolucional, Ámbito artístico, Twitter.

#### **Abstract**

*Advances in artificial intelligence (AI) technology have led to significant improvements in image generation in terms of speed and quality. However, it has generated concern and uncertainty among artists, who fear being replaced by AI in their field of work. In this context, the objective was to analyse Tweets defining the impact of artificial intelligence*

*(AI) on the adoption of imaging technologies. For this purpose, the collection, creation and evaluation of a convolutional neural network that classifies the data according to a sentiment analysis between positive and negative was carried out. Finally, the research determined the loss rate of 63%, the accuracy with 61% and the ROC curve around 64% of a convolutional neural network for predicting Tweets.*

**Keywords:** *Artificial intelligence, Sentiment analysis, Convolutional neural network, Artistic field, Twitter.*

---

## **Introducción**

Las plataformas de redes sociales se han transformado en un espacio virtual equivalente a una plaza pública contemporánea, donde un gran número de personas debaten, discuten y comparten sus experiencias y puntos de vista.

Twitter ocupa una posición excepcional dentro del conjunto de las redes sociales más ampliamente utilizadas, ya que su número de usuarios diarios supera los 436 millones, que lo convierte en una plataforma de elección para la expresión y difusión pública de opiniones.

Un tema que se discute entre artistas actualmente en Twitter es la utilización de IA para la generación de imágenes que causa preocupación e incertidumbre por ser reemplazados por tecnología en el campo artístico y, por otro lado, las empresas que realizan estas herramientas no saben exactamente que mejorar o cambiar para satisfacer a las demandas de sus clientes.

Para ello se realiza un análisis de sentimiento donde se lleva a cabo la recopilación, diferenciación, análisis y obtención de la información necesaria del usuario para la mejoría del software.

Para realizar esta investigación se ha revisado fuentes que incluyen las redes neuronales profundas, convolucionales y recurrentes donde se ha decidido utilizar una red neuronal convolucional con Word2Vec

que según Kalluri [1] es el más óptimo como solución para obtener y analizar la información con los procesos de recopilación de datos, preprocesado de datos, incrustación y modelación.

En la sección 2 se realizó una revisión conceptual que abarcó la definición de diversos conceptos. La sección 3 se hace una comparación entre modelos DNN, CNN y RNN según lo propuesto por Kalluri[1]. La sección 4 se define los pasos clave de la solución. La sección proporciona una descripción detallada de la ejecución de la solución. La sección 6 se muestran los resultados y finalmente en la sección 7 se realiza las conclusiones.

## Revisión conceptual

Para elegir el mejor modelo para la solución se describió diferentes conceptos y analizó una valoración de los criterios con la comparativa que realizó Kalluri [1] entre DNN, CNN y RNN con TF-IDF y Word2vec.

- **Análisis de sentimiento:** El análisis de sentimiento es la técnica que consiste en obtener información sobre una entidad y determinar sus subjetividades de forma automática. El propósito es identificar si el material generado por el usuario expresa sentimientos favorables, negativos o neutrales. La clasificación del sentimiento puede realizarse en tres niveles de extracción: nivel de aspecto o rasgo, nivel de frase y nivel de documento.
- **Word Embedding (Incrustación de palabras):** La mayoría de los algoritmos de aprendizaje automático no pueden interpretar cadenas o texto plano en su forma básica. Por el contrario, necesitan entradas numéricas para funcionar. Al convertir las palabras en vectores, la incrustación de palabras permite procesar grandes cantidades de datos de texto y adaptarlos a los algoritmos de aprendizaje automático. En este apartado se usa Word2vec [14] y TF-IDF [15,25] como técnicas de incrustación de palabras [8]. Se examina todo el texto y el procedimiento de construcción del vector se lleva a cabo identificando las palabras con las que la palabra objetivo aparece con más frecuencia. De este modo, también se muestra la proximidad semántica de las palabras, a diferencia de otras técnicas se lleva a cabo un procedimiento de aprendizaje no supervisado mediante redes neuronales artificiales, se utilizan datos no etiquetados para entrenar el modelo Word2Vec que crea vectores de palabras.
- **Red neuronal profunda (DNN):** Esta red neuronal tiene la característica distintiva de permitir captar automáticamente las funciones necesarias. El modelo de aprendizaje profundo es una función matemática  $f: X,$

Y. El aprendizaje profundo es el desarrollo de una red neuronal artificial (ANN) que emplea más de una capa oculta para modelar un conjunto de datos [7].

- Red neuronal Convolutiva (CNN): consisten en múltiples capas de convoluciones con funciones de activación no lineales, como ReLU o tanh, aplicadas a los resultados. En una red neuronal feedforward convencional, cada neurona de entrada está conectada a cada neurona de salida de la capa siguiente. Esto también se conoce como una capa totalmente conectada [6]. Finalmente, los datos se preprocesan para la matriz de incrustación, pasan por capas y filtros para obtener un resultado de análisis de sentimiento entre positivo o negativo [23,24].
- Red neuronal recurrente (RNN): La red neuronal recurrente es una extensión de la red neuronal directa con una memoria interna ya que realiza la misma función para cada entrada de datos, mientras que el resultado de la entrada actual depende del cálculo anterior [11]. Una vez generada la salida, se duplica y se vuelve a introducir en la red recurrente. Para la toma de decisiones, evalúa tanto la entrada actual como el resultado de la entrada anterior de la que ha aprendido. La red de memoria a corto plazo es una RNN avanzada, una red secuencial, que permite la persistencia de la información. Es capaz de resolver el problema de gradiente, pero son incapaces de reconocer las dependencias a largo plazo por eso se usan las LSTM [16,19] que significa memoria a corto plazo para evitar dificultades.

El preprocesamiento de los datos de entrada es parecida al CNN, pasando por celdas y funciones para la disminución de vectores de salida con el fin de dar un resultado (positivo o negativo).

## Comparación de modelos

Ahora que sabemos cada concepto se pasa a la valorización de los criterios usando la Tabla 1 para determinar el puntaje según el rango.

Tabla 1. Tabla de evaluación de rangos para los criterios

Rango de evaluación	Puntaje
0-6	1
6-8	2
8-10	3

Según el resultado de las pruebas que realizó Kalluri [1], lo reemplazaremos con un puntaje para determinar el modelo óptimo según la Tabla 1.

Tabla 2. Comparativa entre modelos según Kalluri[1]

Metrics	TF-IDF			Word2vec		
	DNN	CNN	RNN	DNN	CNN	RNN
Accuracy	0.7548	0.7563	0.5432	0.7702	0.8001	0.815
Recall	0.7423	0.7321	0.7623	0.7865	0.8012	0.8241
Precision	0.748	0.7366	0.7635	0.7845	0.8023	0.8269
F Score	0.764	0.7542	0.6412	0.7888	0.8074	0.818
AUC	0.746	0.754	0.7557	0.7875	0.8006	0.8214

Se observa la Accuracy (Exactitud), Recall (Recall), Precision, F Score y AUC (Area Under The Curve) para cada red neuronal y se realiza una comparación de los datos [17,21] según la Tabla 2.

Tabla 3. Comparativa entre métodos basado en la valorización del criterio.

<u>Metrics</u>	TF-IDF			Word2vec		
	DNN	CNN	RNN	DNN	CNN	RNN
Accuracy	2	2	1	2	3	3
Recall	2	2	2	2	3	3
Precision	2	2	2	2	3	3
F Score	2	2	2	2	3	3
AUC	2	2	2	2	3	3
Total	10	10	9	10	15	15

El análisis del resultado da un total de 15 para CNN y RNN por parte de Word2Vec como los más óptimos dando un empate entre los modelos según la Tabla 3.

Tabla 4. Comparativa entre métodos basado en el tiempo de procesamiento según Kalluri [1].

<u>Metricas</u>	TF-IDF			Word2vec		
	DNN	CNN	RNN	DNN	CNN	RNN
Accuracy	2	2	1	2	3	3
Recall	2	2	2	2	3	3
Precision	2	2	2	2	3	3
F Score	2	2	2	2	3	3
AUC	2	2	2	2	3	3
Total	10	10	9	10	15	15

Para hacer el desempate, se realizó una siguiente comparación, pero basado en el tiempo de procesamiento de cada red neuronal que según el tiempo nos da para CNN 36 minutos y 12 segundos que es mucho menor que el RNN que tarda 1 hora y 32 segundos según la Tabla 4.

## Modelo de la solución

Para realizar el modelo se necesita diferentes pasos para llevar los mensajes o tweets a una clasificación por sentimiento.

- Recopilación de datos, se extrae los datos de twitter sin ninguna corrección o modificación, en otras palabras, son los datos brutos.
- Preprocesado de datos, se limpia los datos de toda clase de ruido, emojis, caracteres especiales, mayúsculas, entre otras.
- Preparación de la capa de incrustación, convierte los datos textuales en forma numérica para que se pueda interpretar para la clasificación.
- Red neuronal convolucional, los datos son clasificados por medio de la red neuronal dando un resultado numérico que se interpreta como positivo, neutro o negativo.

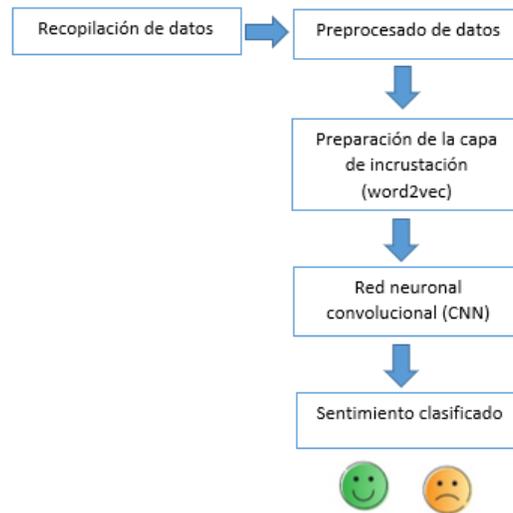


Figura 1. Esquema del flujo de trabajo según Paredes [2]

En la Figura 1, se muestra el esquema del flujo de trabajo que planeo Paredes [2] con el objetivo de brindar una comprensión más clara de la metodología empleada para el desarrollo del análisis de sentimiento.

## Desarrollo de la solución

Se realizó la solución siguiendo los pasos del modelo de la solución, en este apartado se dividió en 4 módulos:

Módulo de recopilación de datos de Twitter se desarrolló con la ayuda de la librería de Selenium que permite automatizar las acciones en el navegador web para recopilar los datos y ChromeDriver que facilita la interacción de Selenium con el navegador.

Tabla 5. Datos recopilados

Tweet
"Foxy Heaven IA cool #AIArt"
"GM, X Posting some tech-inspired stuff for #TechTuesday. Feel free to share your creations. #AIart #AIartwork #AIartCommunity #AIartGallery #AIã,ããf@ã,ããf"
"A girl pilot in a blue pilot suit AI is cool. #BluePilotSuit
gooooo morning! #AIart #AIã,ããf@ã,ããf` #AIã,ããf@ãã"ã,c #AIã½¼ãã³
Blending some styles this AM! #AIart #AIartwork #midjourneyart #midjourneyartwork
Starry Dreams! #AIartGallery #AIartworks #AIartists #AIart
"Out of all the vibrant, colorful raincoats out there, you choose transparent? This is beyond frustrating." #AIartwork #AIart #pixai #Aigirl #AIã,ããf@ã,ããf` #AIã,ããf@ãã"ã,c
All right people of X! How about some action. It's a technical drawing time. Prompt: Patent drawing. Technical drawing of a [your fav object], [your fav colour] eyes colour. Let's tag friends into this.
Welcome To The Best MMORPG #IA
#AIart #nijiourney #fabricfolklore #AIartwork fabric folklore 106
Silver knight #AIart

En la tabla 5, se muestra los datos recopilados en bruto que aún no han sido procesados.

Módulo de preprocesado de datos, en esta etapa se realiza la limpieza de los tweets, este proceso se realiza de dos maneras: utilizando software o de forma manual. En este caso, se optó por la última opción con el objetivo de proporcionar coherencia a los datos. Para lograrlo, se siguieron indicaciones específicas, tales como:

- No debe contar con caracteres especiales, emojis, entre otros.
- No debe existir espacios entre vacíos entre filas.
- No se considera los caracteres especiales incluyendo las palabras que contengan “#” o “@” solo en caso de que sea una palabra dentro de la oración.
- No se considera elementos que tengan URL.
- No se considera frases sin sentido o ilegibles.
- Debe estar relacionado al tema artístico o IA.
- Debe existir coherencia las frases y el sentimiento.

Tabla 6. Datos recopilados y preprocesados

Tweet
"Foxy Heaven IA cool #AIArt"
"GM, X Posting some tech-inspired stuff for #TechTuesday. Feel free to share your creations. #Alart #AIArtwork #AIArtCommunity #AIArtGallery #Alä,äf@ä,'äf"
"A girl pilot in a blue pilot suit AI is cool. #BluePilotSuit goood morning! #Alart #Alä,äf@ä,'äf #Alä,°äf@äf"ä,c #Alä¼¼ä¼³
Blending some styles this AMâ€! #Alart #AIArtwork #midjourneyart #midjourneyartwork Starry Dreams! #AIArtGallery #AIArtworks #Alartists #Alart
"Out of all the vibrant, colorful raincoats out there, you choose transparent? This is beyond frustrating." #AIArtwork #Alart #pixai #Algirl #Alä,äf@ä,'äf #Alä,°äf@äf"ä,c All right people of X! How about some action. Itâ€™s a technical drawing time. Prompt: Patent drawing. Technical drawing of a [your fav object], [your fav colour] eyes colour. Letâ€™s tag friends into this.
Welcome To The Best MMORPG #IA
#Alart #nijijourney #fabricfolklore #AIArtwork fabric folklore 106
Silver knight #Alart

En la tabla 6, los datos han sido recopilado, preprocesados y clasificados con una librería de python llamada textblob aun así el error persiste por lo cual se realizó una revisión de forma manual.

Módulo de preparación de la capa de incrustación, en esta etapa se usa el word2vec para la incrustación de palabras, esta herramienta implementa el modelo de bolsa continua de palabras (CBOW) y el modelo de para calcular representaciones vectoriales de palabras [3,9].

La incrustación de las palabras es esencial en la estructura de las CNN, ya que posibilitan la obtención de información tanto sintáctica (estructura gramatical) como semántica (significado y contexto) de los tweets. Esta característica resulta crucial en el proceso de clasificación de sentimientos.

Antes de crear el word2vec, se dividió los datos entre: datos de entrenamiento y datos de prueba, por lo cual se usó los datos de entrenamiento para etiquetarlos que consiste en dividir las palabras en más pequeñas para facilitar el manejo y procesamiento como se muestra en la Figura 2.

```
[TaggedDocument (words=['AI',
'opens', 'the', 'door', 'for',
'far', 'more', 'people', 'to',
'create', 'art.', 'Good',
'artists', 'who', 'embrace', 'it',
'will', 'be', 'able', 'to', 'get',
'results', 'that', 'were', 'only',
'attainable', 'by', 'great',
'artists', 'before', 'AI,', 'and',
'great', 'artists', 'will',
'reach', 'into', 'the', 'realms',
'of', 'artistic', 'possibilities',
'that', 'we', 'still', "can't",
' imagine', 'yet.', 'AI', 'art...'],
```

Figura 2. Palabras tokenizadas de los Tweets

Luego se creó el word2vec con el uso de la librería de Python llamado Gensim y en base a los datos etiquetados se realizó el entrenamiento.

Módulo de red neuronal convolucional (CNN), en esta etapa se crea la CNN para clasificar los tweets en positivos y negativos. Su arquitectura requiere vectores de palabras concatenadas del texto como entrada.

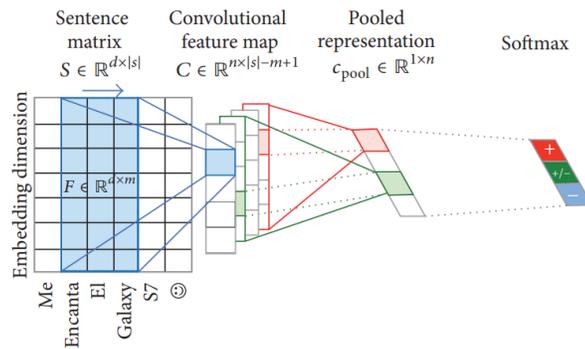


Figura 3. Modelo de aprendizaje para la clasificación de sentimientos según Severyn [2]

En la figura 3, se muestra la arquitectura de una red neuronal para la clasificación de sentimiento.

Para realizar la CNN se utilizó la librería de Python Keras y se utilizó varias capas como:

- Capa de entrada, para el ingreso de los datos de los tweets.

- Capa de Embedding, para convertir a cada palabra a un vector [22].
- Capa de Conv1D, donde se hace las convoluciones de bigram, trigram, fourgram [12,13].
- Capa de GlobalMaxPool, donde se realiza la operación max pooling para reducir la dimensionalidad y mejorar el modelo [26].
- Capa de salida, se obtiene el resultado mostrando los valores de 0 (negativo) o 1 (positivo).

Además, se utilizó hiperparametros para ajuste del modelo como la tasa de aprendizaje (learning rate) que determina los ajustes de los pesos en cada iteración con un valor de 0.0001 y una tasa de perdida (dropout) para evitar el sobreajuste con un valor de 0.2.

## Resultados

Los datos obtenidos son divididos en 2 partes:

- Datos para el entrenamiento con un 45.16% negativos y un 54.84% positivos.
- Datos para prueba con un 54.55% negativos y un 45.45% positivos.

Los datos tienen casi un 50% entre las dos partes dando una igualdad casi pareja entre positivo y negativo.

Por parte, en la red neuronal convolucional se tiene los siguientes resultados para determinar la eficiencia actual con los datos de entrenamiento:

Tasa de Perdida (Dropout):  $0.6318122148513794 = 63\%$

Precisión:  $0.6181818246841431 = 61\%$

ROC =  $0.643 = 64\%$



Figura 4. Curva ROC

En la Figura 4, se muestra gráficamente la curva ROC (Característica Operativa del Receptor) con los datos de eficiencia obtenidos de la CNN.

Tabla 7. Datos recopilados y preprocesados

Tabla de prediccion de los datos con la red neuronal			
	Frases	Pred.	Pred.Red
121	Come Master. Let's finish quickly these meetin...	1	1
122	A picture says it all, incredible	1	1
16	SUNSPROUT Knight IA is incredible	1	1
229	Mediocre artists see the writing on the wall. ...	0	1
149	If we're so mediocre, maybe y'all should stop ...	0	0
41	I feel cruelly cheated when I see an interesti...	0	1
249	That's not AI coloring, that's running your sk...	0	0
262	You can consume bad writing and good writing. ...	0	1
265	IA you suck	0	1
209	What I have said is that I'm an artist and I l...	1	1

En la Tabla 7, se muestra la predicción de los datos de prueba comparando con la predicción que realiza la CNN.

## Conclusiones

En este estudio, se realizó un análisis de sentimiento con una red neuronal convolucional para clasificar los mensajes de tweets entre positivo y negativo dando los siguientes resultados:

- La precisión es un 61%, el porcentaje esperado era entre 70-80%, esto sugiere que la CNN no está llegando a la eficiencia deseada en la predicción.
- La tasa de pérdida es de un 63%, el porcentaje esperado era de menos de un 15%, esto sugiere que la CNN tiene dificultades para minimizar el error durante el entrenamiento.
- ROC es de 64%, el porcentaje esperado era entre 70-80%. esto sugiere que la CNN no logra separar las clases adecuadamente entre positivo y negativo.

Al realizar la clasificación con los datos de prueba con la red neuronal ocurre errores con la predicción que sucede por la insuficiencia de datos para mejorar la capacidad predictiva de la red neuronal, en este caso se podría considerar la obtención de datos adicionales.

También se puede mejorar agregando más especificaciones en el preprocesado como convertir las mayúsculas a minúsculas o seguir ajustando los hiperparámetros para obtener un resultado más óptimo.

## Contribución de Autoría

**Antony Pyero Rosales Espinoza:** [Conceptualización](#), [Análisis formal](#), [Investigación](#), [Software](#), [Validación](#), [Redacción - borrador original](#), [Curación de datos](#), [Escritura, revisión y edición](#), [Visualización](#), [Metodología](#), [Software](#), **Juan Carlos Gonzales Suarez:** [Conceptualización](#), [Investigación](#), [Visualización](#), [Metodología](#), [Software](#), [Validación](#), [Redacción - borrador original](#), [Curación de datos](#), [Redacción - borrador original](#).

## Referencias

- [1] Kalluri, S (2023). Deep Learning Based Sentiment Analysis. Faculty of Faculty, Blekinge Institute of Technology, Karlskrona, Sweden. <https://www.diva-portal.org/smash/get/diva2:1741487/FULLTEXT02.pdf>
- [2] Paredes-Valverde, M. A., Colomo-Palacios, R., Salas-Zárate, M. D. P. & Valencia-García, R. (2017). Sentiment Analysis in Spanish for Improvement of Products and Services: A Deep Learning Approach. Scientific Programming, 2017. <https://doi.org/10.1155/2017/1329281>

- [3] T. Mikolov, I. Sutskever, K. Chen, G. Corrado, and J. Dean, "Distributed representations of words and phrases and their compositionality," in Proceedings of the 27th Annual Conference on Neural Information Processing Systems (NIPS '13), pp. 3111-3119, December 2013.
- [4] A. Severyn and A. Moschitti, "UNITN: training deep convolutional neural network for twitter sentiment classification," in Proceedings of the 9th International Workshop on Semantic Evaluation (SemEval '15), pp. 464-469, 2015.
- [5] A. Severyn and A. Moschitti, "UNITN: training deep convolutional neural network for twitter sentiment classification," in Proceedings of the 9th International Workshop on Semantic Evaluation (SemEval '15), pp. 464-469, 2015.
- [6] A. Zhang, L.; Wang, S.; Liu, B. Deep learning for sentiment analysis: A survey. WIREs Data Min. Knowl. Discov. 2018, 8, e1253.
- [7] Kraus, M.; Feuerriegel, S. Sentiment analysis based on rhetorical structure theory: Learning deep neural networks from discourse trees. Expert Syst. Appl. 2019, 118, 65-79.
- [8] Ain, Q.T.; Ali, M.; Riaz, A.; Noureen, A.; Kamran, M.; Hayat, B.; Rehman, A. Sentiment analysis using deep learning techniques: A review. Int. J. Adv. Comput.Sci. Appl. 2017, 8, 424
- [9] N. F. F. Da Silva, E. R. Hruschka, and E. R. Hruschka, "Tweet sentiment analysis with classifier ensembles," Decision Support Systems, vol. 66, pp. 170-179, 2014.
- [10] T. Mikolov, I. Sutskever, K. Chen, G. Corrado, and J. Dean, "Distributed representations of words and phrases and their compositionality," in Proceedings of the 27th Annual Conference on Neural Information Processing Systems (NIPS '13), pp. 3111- 3119, December 2013.
- [11] Britz, D. Recurrent Neural Networks Tutorial, Part 1-Introduction to Rnns. <https://dennybritz.com/posts/wildml/recurrent-neural-networks-tutorial-part-1/>

- [12] M. del Pilar Salas-Zarate, M. A. Paredes-Valverde, J. Limon- ´ Romero, D. Tlapa, and Y. Baez-Lopez, "Sentiment classification of Spanish reviews: an approach based on feature selection and machine learning methods," *Journal of Universal Computer Science*, vol. 22, no. 5, pp. 691-708, 2016.
- [13] P. Smith and M. Lee, "Cross-discourse development of supervised sentiment analysis in the clinical domain," in *Proceedings of the 3rd Workshop in Computational Approaches to Subjectivity and Sentiment Analysis*, pp. 79-83, 2012.
- [14] Mikolov, Tomas, Kai Chen, Greg Corrado, and Jeffrey Dean. "Efficient estimation of word representations in vector space." *arXiv preprint arXiv: 1301.3781* (2013). <https://doi.org/10.1145/3388218.3388229>
- [15] Djoerd Hiemstra. 2000. A probabilistic justification for using  $tf \times idf$  term weighting in information retrieval. *International Journal on Digital Libraries* 3, 2 (2000), 131-139.
- [16] M. Cliche, "BB twtr at SemEval-2017 Task 4: Twitter Sentiment Analysis with CNNs and LSTMs," Apr. 2017.
- [17] M. D. P. Salas-Zarate, R. Valencia-Garc ´ ´a, A. Ruiz-Mart ´ ´nez, and R. Colomo-Palacios, "Feature-based opinion mining in financial news: an ontology-driven approach," *Journal of Information Science*, 2016.
- [18] Z. Wang, H. Wang, Z. Liu & J. Liu, "Rolling Bearing Fault Diagnosis
- [19] Using CNN-based Attention Modules and Gated Recurrent Unit", *Global Reliability and Prognostics and Health Management* 7(2020) 6.
- [20] Umarania, V., Juliana, A., & Deepab, J. (2023). Sentiment Analysis using various Machine Learning and Deep Learning Techniques. *Journal of Computational Intelligence*, 7(3), 245-260. <https://doi.org/10.46481/jnsps.2021.308>

- [21] S. Md and S. Krishnamoorthy, "Student performance prediction, risk analysis, and feedback based on context-bound cognitive skill scores," *Educ. Inf. Technol.*, vol. 27, no. 3, pp. 3981-4005, 2022, doi: 10.1007/s10639-021-10738-2.
- [22] D. Tang, F. Wei, B. Qin, T. Liu, and M. Zhou, "Coooooll: A Deep Learning System for Twitter Sentiment Classification," in *Proceedings of the 8th International Workshop on Semantic Evaluation (SemEval '14)*, pp. 208-212, Dublin, Ireland, 2014.
- [23] Bhavitha, B.; Rodrigues, A.P.; Chiplunkar, N.N. Comparative study of machine learning techniques in sentimental analysis. In *Proceedings of the 2017 International Conference on Inventive Communication and Computational Technologies (ICICCT)*, Coimbatore, India, 10-11 March 2017; pp. 216-221.
- [24] Zhang, L.; Wang, S.; Liu, B. Deep learning for sentiment analysis: A survey. *WIREs Data Min. Knowl. Discov.* 2018, 8, e1253.
- [25] Sohangir, S.; Wang, D.; Pomeranets, A.; Khoshgoftaar, T.M. Big Data: Deep Learning for financial sentiment analysis. *J. Big Data* 2018, 5, 3
- [26] D. Britz, "Understanding Convolutional neural networks for NLP," in *WildML*, WildML. <http://www.wildml.com/2015/11/understanding-convolutional-neural-networks-for-nlp/>