

**PONTIFICIA UNIVERSIDAD  
CATÓLICA DEL PERÚ**  
Escuela de Posgrado



Una metodología basado en conocimiento de grafos y relaciones  
conceptuales de palabras para el análisis de sentimientos

Tesis para obtener el grado académico de Doctor en Ingeniería que presenta:

*Yonatan Mamani Coaquira*

Asesor:

*Dr. Edwin Rafael Villanueva Talavera*


Lima, 2025

## Informe de Similitud

Yo, Edwin Rafael Villanueva Talavera, docente de la Escuela de Posgrado de la Pontificia Universidad Católica del Perú, asesor del trabajo de investigación titulado *Una metodología basada en conocimiento de grafos y relaciones conceptuales de palabras para el análisis de sentimientos*, de Yonatan Mamani Coaquira, dejo constancia de lo siguiente:


- El mencionado documento tiene un índice de puntuación de similitud de 4 %. Así lo consigna el reporte de similitud emitido por el software *Turnitin* el 27/10/2025.
- He revisado con detalle dicho reporte y la Tesis o Trabajo de Suficiencia Profesional, y no se advierte indicios de plagio.
- Las citas a otros autores y sus respectivas referencias cumplen con las pautas académicas.

Lima, 29 de Octubre de 2025.

Apellidos y nombres del asesor / de la asesora: <u>Villanueva Talavera, Edwin Rafael</u>	
DNI: 29714308	Firma 
ORCID: 0000-0002-6540-1230	

# Dedicatoria

Este trabajo está dedicado a mi padre Jorge Mamani Gomez y mi madre Irma Coaquira Pinto por brindarme su apoyo incondicional y son mis mejores ejemplos de disciplina y perseverancia en la vida; así mismo, dedico a mis hermanos Percy y Rosmery por su apoyo en todas mis decisiones para cumplir mis sueños. A mi hermano Edison Kevin que desde el cielo siempre me esta guiando en mi camino de vida.



# Agradecimiento

Agradezco a mis padres Irma y Jorge, también a mis hermanos Edison, Rosmery y Percy por todo el apoyo y la paciencia, gracias por acompañarme en todo momento.

Agradecer de manera especial con mi mayor gratitud a mi asesor Dr. Edwin Rafael Villanueva Talavera por su comprensión, paciencia y compartir sus conocimientos durante mis estudios doctorales. Sus consejos fueron importantes para el desarrollo de este trabajo de investigación.

Agradezco también al profesor Cesar y Edwin investigadores responsables del laboratorio de Inteligencia Artificial de la Pontificia Universidad Católica del Perú, por permitirme desarrollar mi trabajo de investigación utilizando los espacios del laboratorio y los servidores para realizar los experimentos.

Agradezco también al Consejo Nacional de Ciencia, Tecnología e Innovación Tecnológica (CONCYTEC) y al Fondo Nacional de Desarrollo Científico, Tecnológico y de Innovación Tecnológica (FONDECYT), que han financiado mis estudios doctorales de ingeniería en área de ciencias de la computación en la Pontificia Universidad Católica del Perú.

# Resumen

El análisis de sentimientos ha encontrado aplicaciones en diferentes áreas como: psicología, filosofía, sociología, marketing, economía, educación, etc. En ese sentido, las redes sociales se han convertido en una herramienta para que las personas expresen sus opiniones, especialmente de forma textual. En los últimos años, la investigación basada en el conocimiento de grafos ha surgido como un enfoque innovador y prometedor de la Inteligencia Artificial (IA) para obtener una mejor representación estructurada de los datos. El presente trabajo propone una metodología no supervisada basada en el conocimiento de grafos, específicamente en la vectorización de nodos que representan palabras de las oraciones con sus respectivas relaciones conceptuales. Parte de esta metodología se construyen diccionarios de palabras clasificadas por polaridades (positiva, negativa y neutral) utilizando VADER (*Valence Aware Dictionary and sEntiment Reasoner*), junto a conceptos basado en grafos conceptuales de WordNet y ConceptNet. Esta metodología permite capturar las relaciones de co-ocurrencia y relaciones conceptuales, junto con la polaridad de palabras. Así mismo, se propone un algoritmo denominado *Polarity-biased random Walk* para construir caminos del grafo utilizando un *bias* de polaridad. Luego mediante el algoritmo Skip-Gram se realiza la vectorización de palabras que contiene los caminos obtenidas del grafo. Esta metodología permitió encontrar resultados como, que a mayor profundidad de caminos y número de caminos por nodo mediante un *bias* de 0.95 con ConceptNet o WordNet llegan a ser mejor el resultado de clasificación de polaridad de sentimientos en comparación a modelos como Node2vec, GraphSAGA, Graph Attention y Graph Convolution Networks. Así mismo, embeddings construido a partir de IMDB *movie* permite mejorar los resultados de precisión para aplicar en dominios específicos en comparación a modelos como Word2Vec, FastText, Glove y Bert, este último con resultados muy cercanos a las propuestas.

**Palabras claves:** word embedding, análisis de sentimientos, clasificación de polaridad, conocimiento de grafo, node embedding.

# Abstract

Sentiment analysis has found applications in various fields such as psychology, philosophy, sociology, marketing, economics, education, etc. In this sense, social media has become a tool for people to express their opinions, especially in written form. In recent years, research based on graph knowledge has emerged as an innovative and promising approach of Artificial Intelligence (AI) to achieve a better structured representation of data. This work proposes an unsupervised methodology based on graph knowledge, specifically in the vectorization of nodes representing words in sentences along with their respective conceptual relationships. Part of this methodology involves building dictionaries of words classified by polarity (positive, negative, and neutral) using VADER (Valence Aware Dictionary and sEntiment Reasoner), along with concepts based on conceptual graphs from WordNet and ConceptNet. This methodology captures co-occurrence relationships and conceptual relationships, along with the polarity of words. An algorithm called Polarity-biased random Walk is also proposed to construct graph paths using a polarity bias. Then, using the Skip-Gram algorithm, the vectorization of words containing the paths obtained from the graph is performed. This methodology allowed for findings such that, with greater path depth and number of paths per node using a bias of 0.95 with ConceptNet or WordNet, the results for sentiment polarity classification improved compared to models like Node2vec, GraphSAGE, Graph Attention, and Graph Convolution Networks. Additionally, embeddings constructed from the IMDB movie dataset improve accuracy results for application in specific domains compared to models like Word2Vec, FastText, Glove, and Bert, with the latter showing results very close to the proposed methods.

**Keywords:** word embedding, sentiment analysis, polarity classification, graph knowledge, node embedding.

# Índice general

Dedicatoria	I
Agradecimiento	II
Resumen	III
Abstract	IV
<b>1. Introducción</b>	<b>1</b>
1.1. Contexto y problema	1
1.2. Preguntas de investigación	2
1.3. Objetivos	3
1.4. Hipótesis	3
1.5. Justificación	4
1.6. Contenido de la tesis	4
<b>2. Marco conceptual</b>	<b>5</b>
2.1. Análisis de sentimientos	5
2.2. Embedding	6
2.3. Análisis conceptual	6
2.4. Grafos	7
<b>3. Revisión del estado del arte</b>	<b>9</b>
3.1. Protocolo de revisión	9
3.2. Resultados de la revisión	13
3.2.1. Recolección de datos (Data collection)	13
3.2.2. Limpieza de datos (Data cleaning)	14
3.2.3. Pre-procesamiento (Preprocessing)	14
3.2.4. Codificación de texto (Text encoding)	14
3.2.5. Técnicas de Machine Learning	15
3.2.6. Clasificación de polaridad (Polarity classification granularity)	16
3.2.7. Métricas de evaluación (Evaluation metrics)	17
3.3. Desafíos y oportunidades	17

<b>4. Metodología</b>	<b>24</b>
4.1. Flujo de trabajo de la metodología . . . . .	24
4.2. Colección de datos y preprocesamiento . . . . .	26
4.3. Generar diccionario de palabras conceptuales . . . . .	27
4.4. Generar nuevas oraciones con grafos . . . . .	28
4.4.1. Generar grafo . . . . .	29
4.4.2. Generar combinación de palabras conceptuales . . . . .	31
4.4.3. Obtener nuevas oraciones . . . . .	32
4.5. Generar diccionario de polaridad de palabras . . . . .	34
4.6. Generar grafo de co-ocurrencia . . . . .	34
4.7. Generar caminos con sesgo de polaridad (polarity-biased random walk) . . . . .	37
4.7.1. Inicialización de polarity-biased random walk . . . . .	37
4.7.2. Nodos vecinos . . . . .	37
4.7.3. Probabilidades de transición . . . . .	38
4.7.4. Selección del siguiente nodo . . . . .	38
4.7.5. Generar caminos aleatorios . . . . .	38
4.7.6. Algoritmo polarity-biased random walk . . . . .	39
4.8. Generar word embedding . . . . .	39
4.8.1. Proceso de convertir palabras a embeddings . . . . .	41
4.9. Algoritmos de machine learning supervisados . . . . .	45
4.10. Métricas para clasificación de sentimientos . . . . .	45
<b>5. Resultados y discusiones</b>	<b>47</b>
5.1. Consideraciones para experimentación . . . . .	47
5.1.1. Dataset experimentales . . . . .	47
5.1.2. Métricas de evaluación . . . . .	48
5.2. Resultados de evaluación de embeddings en cuanto a su contenido predictivo . . . . .	49
5.2.1. Resultados utilizando WordNet y ConceptNet mediante número de caminos. . . . .	49
5.2.2. Resultados en el dataset IMDB utilizando embeddings basados en grafos . . . . .	53
5.2.3. Resultados de modelos pre-entrenados de codificación de palabras en el dataset IMDB. . . . .	56
5.2.4. Validación cruzada K-Fold . . . . .	58
5.2.5. Tiempo de ejecución . . . . .	59
5.3. Correlación de Spearman y Pearson . . . . .	60
5.4. Similitud de palabras por polaridad . . . . .	61
5.5. Visualización de polaridad de palabras con T-SNE . . . . .	63
5.6. Resultados de accuracy y f1-score para dominio general y específico . . . . .	65
5.6.1. Resultado dominio específico SST2 . . . . .	65
5.6.2. Resultado dominio general McDonalds . . . . .	66
5.7. Análisis general de resultados . . . . .	68
<b>6. Conclusiones y recomendaciones</b>	<b>70</b>
<b>Referencias</b>	<b>73</b>

# Índice de figuras

3.1.	Propuesta de framework para estudiar la literatura contemporanea de Análisis de Sentimientos. . . . .	11
3.2.	Representatividad de los idiomas en conjuntos de datos comunes para el análisis de sentimientos. . . . .	14
3.3.	Porcentaje de polaridad de sentimiento más utilizada para la clasificación de sentimientos. . . . .	18
4.1.	Flujo de trabajo general de la metodología propuesta basada en conocimiento de grafos para el análisis de sentimientos. . . . .	25
4.2.	Diagrama de dispersión de las dos primeras componentes principales (PCA) derivadas de las incrustaciones BERT de las reseñas de IMDB. Los colores indican las etiquetas de sentimiento. . . . .	27
4.3.	Ejemplo de grafo generado de la oración " <i>transformer movie fun visually spectacular</i> " con sus palabras conceptuales utilizando WordNet. . . . .	30
4.4.	Grafo generado de la oración " <i>transformer movie fun visually spectacular</i> " con sus palabras conceptuales utilizando ConceptNet. . . . .	30
4.5.	Grafo representativo para generar nuevas oraciones combinando palabras conceptuales con WordNet. . . . .	33
4.6.	Grafo representativo para generar nuevas oraciones combinando palabras conceptuales con ConceptNet. . . . .	33
4.7.	Grafo de co-ocurrencia de palabras de la oración original " <i>transformer moving-picture-show play visually dramatic</i> " con palabras conceptuales (WordNet) según el diccionario de polaridades. . . . .	36
4.8.	Grafo de co-ocurrencia de palabras de la oración original " <i>transformer moving-picture-show play visually dramatic</i> " con palabras conceptuales (ConceptNet) según el diccionario de polaridades. . . . .	36
5.1.	Resultados de F1-score usando WordNet bajo un bias de 0.95 y 0.15. . . . .	54
5.2.	Resultados de <i>F1-score</i> usando ConceptNet bajo un bias de 0.95 y 0.15. . . . .	55
5.3.	Resultados de <i>Accuracy</i> en el dataset IMDB para diferentes métodos de codificación de palabras basados en grafos. . . . .	57
5.4.	Resultados de <i>F1-score</i> en el dataset IMDB para diferentes métodos de codificación de palabras basados en grafos. . . . .	57
5.5.	Resultados de <i>Accuracy</i> para IMDB utilizando modelos pre-entrenados. . . . .	58
5.6.	Resultados de <i>F1-score</i> para IMDB utilizando modelos pre-entrenados. . . . .	59

5.7. Similaridad coseno mediante t-SNE para la propuesta de <i>embeddings</i> con WordNet y ConceptNet. Color rojo (palabras negativas) y verde (Palabras positivas). . . . .	64
5.8. Resultados de Accuracy para SST2 dataset. . . . .	66
5.9. Resultados de F1-score para SST2 dataset. . . . .	66
5.10. Resultados de <i>Accuracy</i> para McDonalds dataset. . . . .	67
5.11. Resultados de <i>F1-score</i> para McDonalds dataset. . . . .	68



# Índice de tablas

3.1. Cadenas de búsqueda utilizando terminos relacionados a Análisis de Sentimientos utilizando Machine Learning. . . . .	10
3.2. Los conjuntos de datos más utilizados para el análisis de sentimientos. . . . .	13
3.3. Técnicas de limpieza de datos para clasificación de sentimientos. . . . .	15
3.4. Técnicas de pre-procesamiento . . . . .	16
3.5. Técnicas comunes de codificación de texto encontradas en modelos no neuronales para la clasificación de sentimientos. . . . .	17
3.6. Técnicas comunes de codificación de texto encontradas en modelos neuronales para la clasificación de sentimientos. . . . .	20
3.7. Técnicas de Machine Learning no basadas en redes neuronales para la inducción de clasificadores de sentimiento. . . . .	21
3.8. Técnicas de Machine Learning basadas en redes neuronales para la inducción de clasificadores de sentimiento. . . . .	22
3.9. Métricas de evaluación más utilizadas. . . . .	23
4.1. Diccionario de palabras conceptuales de WordNet para la oración " <i>transformer movie fun visually spectacular</i> ". . . . .	28
4.2. Diccionario de palabras conceptuales de ConceptNet para la oración " <i>transformer movie fun visually spectacular</i> ". . . . .	28
4.3. Ejemplo de oraciones generadas a partir del grafo con WordNet y oración " <i>transformer movie fun visually spectacular</i> ". . . . .	31
4.4. Ejemplo de oraciones generadas a partir del grafo con ConceptNet y oración " <i>transformer movie fun visually spectacular</i> ". . . . .	32
4.5. Nuevas oraciones seleccionadas. . . . .	34
5.1. Número de oraciones por dataset . . . . .	48
5.2. Número de nodos ( <i>Node</i> ) y aristas ( <i>Edge</i> ) para IMDB <i>movie</i> . . . . .	48
5.3. Resultados de Accuracy para la propuesta WordNet con 0.95 bias. . . . .	50
5.4. Resultados de F1-score para la propuesta WordNet con 0.95 bias. . . . .	50
5.5. Resultados de Accuracy para la propuesta usando WordNet con 0.15 bias. . . . .	51
5.6. Resultados de F1-score para la propuesta usando WordNet con 0.15 bias. . . . .	51
5.7. Resultados de Accuracy para la propuesta usando ConceptNet con bias de 0.95. . . . .	52
5.8. Resultados de F1-score para la propuesta usando ConceptNet con bias de 0.95. . . . .	52
5.9. Resultados de Accuracy para la propuesta usando ConceptNet con bias de 0.15. . . . .	53
5.10. Resultados de F1-score para la propuesta usando ConceptNet con bias de 0.15. . . . .	53
5.11. Rendimiento de la validación cruzada con ConceptNet y WordNet . . . . .	59

5.12. Tiempo de ejecución con $b = 0,95$ , $wl = 40$ , $nw = 300$ . . . . .	60
5.13. Resultados de correlación de diferentes modelos de codificación de palabras en el dataset etiquetado WordSim-353. . . . .	61
5.14. Resultados de correlación de diferentes modelos de codificación de palabras en el dataset etiquetado SimLex-999. . . . .	62
5.15. Resultados de similaridad de palabras por polaridad. . . . .	63



# Capítulo 1

## Introducción

### 1.1. Contexto y problema

El lenguaje verbal es una de las formas más comunes de expresión humana, permitiendo comunicar información, ideas, emociones y sentimientos. En este contexto, el área de Procesamiento de Lenguaje Natural (NLP) tiene como objetivo estudiar técnicas que faciliten el análisis, interpretación y generación automatizada del lenguaje verbal. Una de las tareas fundamentales en NLP es el Análisis de Sentimientos (SA), cuyo propósito es identificar y clasificar automáticamente el sentimiento (afecto, emoción, estado de ánimo) expresado en textos. Este análisis ha encontrado aplicaciones en diversas disciplinas, tales como psicología, filosofía, sociología, marketing, economía y educación , entre otros [1].

Los textos escritos, ampliamente disponibles en organizaciones y en Internet, son una forma prevalente de lenguaje verbal y constituyen la fuente más común de información para el análisis de sentimientos. Este análisis implica diversas tareas de procesamiento en múltiples niveles, tales como el sintáctico, morfológico, semántico, contextual y conceptual, siendo estos dos últimos los niveles más abstractos. El análisis contextual considera el contexto en el cual se encuentra el texto, mientras que el análisis conceptual proporciona una estructura universal y constante. Investigaciones recientes sugieren que el análisis conceptual, mediante el uso de ontologías y conocimiento explícito, puede enriquecer significativamente el análisis de sentimientos [2]-[5].

Un proceso importante en el análisis de sentimientos es la obtención de una representación numérica de las palabras, conocida como embedding, la cual es clave para realizar procesamientos posteriores de manera efectiva. Modelos clásicos de embeddings, tales como Word2vec [6], GloVe [7] y FastText [8], buscan capturar relaciones sintácticas y semánticas entre palabras. Más recientemente, modelos basados en redes neuronales, como ELMO [9] y BERT [10], han demostrado una alta capacidad para capturar el contexto de las palabras,

aumentando así la efectividad en sus representaciones. Sin embargo, algunos académicos han cuestionado la adecuación de estos embeddings de propósito general para aplicaciones en dominios específicos, argumentando que estos modelos no explotan plenamente la información particular de dichos dominios [11]. En respuesta, se han desarrollado embeddings preentrenados de dominio específico, tales como BioBERT [12], SciBERT [13], SentiLARE [14] y PEGASUS [15], los cuales han mostrado mejoras en precisión para tareas analíticas. A pesar de sus avances, la aplicación de estos modelos en el análisis de sentimientos sigue siendo un área poco explorada, lo que motiva a este proyecto a investigar sus beneficios en esta tarea específica.

Por otro lado, en el lenguaje humano las personas utilizan los conceptos de las palabras para identificar y entender el mensaje de forma completa. Por esta razón, incorporar y/o modelar los conceptos de las palabras en el análisis de sentimientos se espera que contribuya a mejorar la precisión en la identificación de sentimientos en textos. Si bien algunos estudios recientes han integrado análisis conceptual, su enfoque ha sido en dominios generales. Aquí se identifica una brecha de conocimiento sobre cómo el desarrollo de modelos de dominio específico que integren análisis conceptual podría impactar en la precisión de identificación de sentimientos. Este proyecto busca también explorar esta posibilidad. Algunos autores han apuntado que incorporar el análisis conceptual en la representación de palabras para entender la oración puede ser una alternativa plausible para analizar la oración en referencia a cada palabra o entidad [11], [16]-[18].

Finalmente, los modelos basados en grafos han emergido como un enfoque prometedor en inteligencia artificial para representar información estructurada [19]. Han sido aplicados en áreas como visión por computadora [20], [21], NLP [22]-[26], entre otros [27]-[29]. Particularmente en el campo del NLP, su aplicación ha sido limitada; Por ejemplo, el trabajo de Bastings, Titov, Aziz et al. [30] abordó la incorporación de la estructura sintáctica en modelos encoder-decoder basados en Redes Neuronales de Grafos (RNG). El trabajo de Marcheggiani y Titov [31] modeló grafos de dependencia sintáctica para la codificación de oraciones. El trabajo de Vashishth, Yadav, Bhandari et al. [32] propuso un método de contexto gramatical para aprender características de palabras y lograr reducir el crecimiento de palabras. Dado el potencial de estos modelos en otras tareas de NLP, resulta plausible pensar que pueden aportar representaciones efectivas para el análisis de sentimientos, lo cual también será investigado en este proyecto.

## 1.2. Preguntas de investigación

Esta investigación busca responder las siguientes preguntas:

- ¿En qué medida los embeddings de palabras de dominio específico pueden mejorar la precisión en el análisis de sentimientos?
- ¿Cómo impacta la incorporación de análisis conceptual en los embeddings de palabras en la precisión de identificación de sentimientos?
- ¿Qué tan efectivas pueden ser las representaciones basadas en grafos para el análisis de sentimientos en textos?

Responder estas preguntas permitirá desarrollar enfoques novedosos que atiendan las brechas identificadas y mejoren la precisión en la identificación de sentimientos.

### 1.3. Objetivos

El objetivo general del presente proyecto es estudiar la efectividad de embeddings de dominio específico basados en conceptos y representaciones de grafos en la mejora de precisión de identificación de sentimientos en textos.

- Desarrollar un método que incluya información conceptual de palabras mediante modelos basados en grafos.
- Desarrollar una metodología que permita extraer embeddings mediante la representación conceptual de palabras.
- Evaluar los modelos anteriores con conjuntos de datos de dominio específico.
- Evaluar el desempeño del modelo propuesto en relación con otros trabajos del estado del arte basados en dominio general.

### 1.4. Hipótesis

Considerando las brechas de conocimiento previamente discutidas, se propone la siguiente hipótesis:

*Los modelos de dominio específico que emplean embeddings de palabras a nivel conceptual y basados en grafos pueden mejorar la precisión en la identificación de sentimientos en textos.*

Esta hipótesis se fundamenta en que la representación de conceptos mediante grafos tiene el potencial de permitir una comprensión más profunda de las oraciones, afinando la representación de las palabras y, por ende, mejorando la precisión en la detección de sentimientos en el dominio en estudio, lo cual se espera genere una ganancia en representación y precisión de los sentimientos de los textos

## 1.5. Justificación

La identificación automatizada de los sentimientos expresados en textos ha adquirido una relevancia significativa y se ha convertido en una tarea altamente valorada tanto por instituciones públicas como privadas. Esto les brinda una valiosa oportunidad para comprender de manera ágil el nivel de aceptación o rechazo que los usuarios experimentan hacia sus productos o servicios, lo cual a su vez les posibilita llevar a cabo mejoras en los mismos. Sin embargo, las técnicas actuales para realizar dicha tarea aún presentan márgenes importantes de error, lo que puede conllevar a decisiones imprecisas.

## 1.6. Contenido de la tesis

El presente trabajo está organizado en 6 capítulos. El primero corresponde a la introducción donde se manifiesta el contexto y problemática del trabajo de investigación; así mismo, se plantea el objetivo general y específicos del trabajo. La hipótesis y justificación que afronta este trabajo. El segundo capítulo representa el marco conceptual correspondiente a definiciones de términos y conceptos más utilizados en el trabajo. El tercer capítulo es el estado del arte con relación a trabajos relacionados en análisis de sentimientos basados en técnicas de word embedding para clasificación de polaridad. En el cuarto capítulo se explica la propuesta metodológica desde la colección y procesamiento de datos hasta la evaluación de métricas. En el quinto capítulo se encuentran los resultados y discusiones obtenidos durante la experimentación. Finalmente, en el capítulo seis se explican las conclusiones y recomendaciones en el presente trabajo de investigación.

# Capítulo 2

## Marco conceptual

### 2.1. Análisis de sentimientos

El análisis de sentimiento tiene como principal propósito detectar sentimientos (positivo, neutral y negativo) y emociones (alegría, sorpresa, disgusto, molestia, tristeza, miedo, etc.) expresadas en diferentes canales o modos de información, tales como imágenes, videos, texto, voz e iconos (emoticons) [33], [34].

Para Yadollahi, Shahraki y Zaiane [35] existen dos tareas principales en análisis de sentimientos: minería de opinión y minería de emociones. Las tareas más populares son: clasificación de polaridad y clasificación de emociones. Por otro lado, Cortis y Davis [36] analizaron diferentes trabajos relacionados a análisis de sentimientos, esto permitió encontrar las siguientes tareas más frecuentes como: objetividad/subjetividad, polaridad del sentimientos, emoción, afecto, ironía, sarcasmo y estado de ánimo. Cada una de estas tareas tiene sub-niveles de clasificación y categoría. Sin embargo, los trabajos de investigación en esta área utiliza 3 niveles principales que son: nivel documento, nivel frase y nivel aspecto [1], [35], [37], [38].

El nivel documento tiene como objetivo determinar la polaridad del sentimiento general expresado en todo el documento [38]. Esto no permite evaluar la polaridad de diferentes entidades (por ejemplo, servicio y producto) [1]. El nivel frase determina la polaridad de la frase como positivo, negativo o neutro [35]. Para clasificar el sentimiento determina si es subjetivo u objetivo [37], [38]. Yadav y Vishwakarma [37] mencionan que la frase subjetiva es una opinión sobre la entidad. Por ejemplo, en la frase "mi perro es hermoso", aquí se manifiesta una polaridad positiva hacia el perro. Por otro lado, un ejemplo de frase objetiva sería "la casa es de color blanco". Aquí no muestra ningún sentimiento. El nivel aspecto tiene información detallada sobre aspectos de una o varias entidades [37], [38]. Este nivel también es llamado comúnmente basado en la entidad o característica; porque el texto puede tener

diferentes sentimientos por cada entidad. Las entidades comúnmente se refieren a nombres de producto, servicios, individuo, evento o organización [1]. Para Liu [1] existen dos sub-tareas en el nivel-aspecto: aspecto-extracción y aspecto-nivel.

## 2.2. Embedding

Embedding es una representación vectorial numérica de una variable categórica. Su principal característica es que compacta información relevante de la variable discreta en un espacio continuo. Los embeddings facilitan el procesamiento y entendimiento de los datos porque capturan relaciones semánticas entre palabras similares en un espacio vectorial [39], [40]. Ma y Cambria [16] mencionan que los embedding pueden reducir significativamente dimensiones altas sin generar pérdida de información. Se puede generar embedding de palabras, conceptos o frases.

En el aprendizaje de embedding con palabras o conceptos, la semántica distribuida es fundamental para el aprendizaje. Es decir, dos palabras (conceptos) son similares semánticamente si tienen la misma distribución de contextos [16]. La semántica distribuida es una tarea eficaz para trabajos de Procesamiento de Lenguaje Natural y fueron utilizados en trabajos como Word2vec [6], GloVe [7] y FastText [8]. En los trabajos de Baroni, Dinu y Kruszewski [41] y Levy, Goldberg y Dagan [42] mencionan que la clasificación de semántica distribuida se agrupan en dos categorías: basado en conteo y basado en predicción. El método basado en conteo más representativo es Single Value Decomposition (SVD) en la cual se descompone una matriz de co-ocurrencia que permite tener vectores densos de baja dimensión y mayor eficiencia computacional [42]. Entre los métodos más representativos basados en predicción se tiene al método Skip-gram, el cual es un modelo de red neuronal que aprende de manera eficiente las representaciones vectoriales de gran escala, capturadas de millones de textos [43]. Este método predice el contexto de palabras según la palabra de entrada. El método Continuous Bag-of-words (CBOW) aprende la predicción de la palabra según el contexto y es más eficiente con conjuntos de datos más pequeños [43]. Por otro lado, recientes trabajos de word embedding están basados en arquitecturas de Transformer que producen resultados destacados a nivel contextual [44].

## 2.3. Análisis conceptual

El concepto se usa para explicar y describir un objeto o acción. Son definiciones universales y constantes que permiten una comprensión profunda. El nivel-conceptual permite utilizar características semánticas de conceptos particulares [16]. Desde el punto de vista de

procesamiento de información, la cognición conceptual utiliza modelamiento de conocimientos que reflejan el mundo real y se expresa en vocabulario entendible de una cierta forma entrada de datos [18].

Para desarrollar métodos de embedding de conceptos, primero se debe aplicar la técnica de Named-Entity Recognition (NER) para normalizar e identificar conceptos de la literatura, luego aplicar modelos de ML para generar embeddings [45]. El NER va permitir extraer información de las entidades para categorizar en el texto. Jiang, Shen, Wang et al. [46] aplicaron concept embedding, que son entidades de textos cortos en un espacio semántico de baja dimensión para capturar información semántica. Li, Huang, Li et al. [47] lo aplicaron para extraer conceptos relacionados en el texto. Utilizaron dos estrategias: vinculación de entidades y conceptualización. La vinculación permite identificar la entidad mencionada en el texto, mientras que la conceptualización permite encontrar los conceptos más relevantes de la entidad.

Por otro lado, el término de concepto está relacionado directamente con las relaciones semánticas en referencia de cómo se asocian en términos de significado y son fundamentales para NLP. Este tipo de relaciones permiten que los modelos de IA interpreten el lenguaje como lo hacen los humanos. Entre las relaciones más comunes se encuentran los sinónimos, hipónimos e hiperónimos. Herramientas como WordNet y ConceptNet permiten estructurar este tipo de relaciones, la importancia radica en que los modelos de NLP capturan el significado de los textos de forma contextual y conceptual; así mismo, mejora la precisión en las diversas tareas de NLP, especialmente en análisis de sentimientos [48]-[50].

## 2.4. Grafos

Un grafo es una representación matemática que permite representar la relación de un conjunto de objetos. Tiene un conjunto de nodos (entidades o vértices) y un conjunto de aristas (conexiones) entre nodos. Existen grafos no dirigidos (unión de vértices de forma simétrica) y dirigidos (unión de vértices de forma asimétrica).

Galland [51] describe que existen varios objetivos diferentes al trabajar con grafos como embeddings: node embedding, graph embedding, transposición de redes neuronales de imágenes o datos textuales a grafos. Zhang [52] menciona que los métodos basados en graph embedding demuestran su eficacia en el análisis de grafos, donde los nodos de menor dimensión aprenden diferentes tipos de proximidades y luego alimentan a los modelos ML. Los métodos Graph embedding tienen dos categorías [52]: Random Walk y First/Second-order Proximity Preserving. Graph embedding permite transformar los nodos y aristas en un espacio vectorial denso (baja dimensión) conservando la información y estructura. Exis-

ten diferentes formas para utilizar graph embedding, algunas técnicas son a nivel de nodo, nivel de subgrafo y recorrido de grafos [53]. Algunos trabajos relacionados a estas técnicas son: DGNR [54], Node2Vec [55], Assym Proj [56], GraphSAGE [57], WatchYourStep [58], DeepWalk [59], Graph2vec [60] y Harp [61]. Por otro lado, existen trabajos como Graph Convolutional Networks (GCN) [62] y Graph Attention Networks (GAN) [63] en el cual los nodos fueron adaptados como palabras para clasificación de texto [64].



# Capítulo 3

## Revisión del estado del arte

El contenido desarrollado en este capítulo corresponde al proceso de revisión sistemática realizado durante este trabajo de investigación, cuyo objetivo fue analizar los enfoques, tendencias, desafíos y oportunidades relacionados con machine learning y deep learning para análisis de sentimientos en textos. Como resultado, se publicó un artículo científico [65] en la revista IEEE Access. Y. Mamani-Coaquira y E. Villanueva. *A Review on Text Sentiment Analysis With Machine Learning and Deep Learning Techniques*. IEEE Access, vol. 12, págs. 193115-193130, 2024. doi: <https://doi.org/10.1109/ACCESS.2024.3513321>. Esta publicación respalda el proceso metodológico de la revisión, así como la relevancia y aporte científico del estudio dentro del área de análisis de sentimientos.

### 3.1. Protocolo de revisión

La Tabla 3.1 presenta las cadenas de búsqueda usadas para encontrar trabajos relacionados al Análisis de Sentimientos en el área de las ciencias de la computación. Esta búsqueda se realizó con ayuda de la base de datos de Web of Science. En la revisión de trabajos se consideró la conjunción de los siguientes criterios de búsqueda:

- Trabajos sobre Análisis de Sentimientos que usen datos textuales.
- Trabajos en el área de la inteligencia artificial, machine learning y deep learning.

Después de realizada la búsqueda y aplicar los criterios de inclusión y exclusión, se obtuvo un corpus de 158 trabajos que se consideraron para la presente revisión (hasta abril de 2023).

En la Figura 3.1 proponemos un framework de estudio para analizar la literatura obtenida. Este delinea las etapas y procedimientos que suelen estar presentes en los métodos propuestos para el Análisis de Sentimientos en textos. Cada etapa contribuye en el procesado textual.

Tabla 3.1 Cadenas de búsqueda utilizando terminos relacionados a Análisis de Sentimientos utilizando Machine Learning.

String	Cadena de búsqueda	Descripción del contexto
String 1	TS=(“sentiment analysis” OR “opinion mining” OR “sentiment classification” OR “sentiment polarity”) AND TS=(“machine learning”) AND AK=(“machine learning”) NOT AK = (“neural network*” or “deep learning”)	Buscar trabajos de modelos de Machine Learning no basados en redes neuronales. Por ejemplo, SVM, RF, DT, NB, etc.
String 2	TS=(“sentiment analysis” OR “opinion mining” OR “sentiment classification” OR “sentiment polarity”) AND TS=(“deep learning” OR “neural network”) AND AK=(“deep learning”)	Buscar trabajos con modelos basados en redes neuronales. Por ejemplo, recurrentes, convolucionales, híbridos u otros relacionados.
String 3	TS=(“sentiment analysis” OR “opinion mining” OR “sentiment classification” OR “sentiment polarity”) AND TS=(“hybrid” AND “deep learning”)	Buscar trabajos con modelos de Deep Learning donde incluyan el término Hybrid.

La etapa de representación de palabras (Word Embedding) suele ser uno de los pasos más relevantes e influyentes en la precisión final del modelo.

Como primer punto podemos decir que existe una diversidad de trabajos basados en aprendizaje de máquina. El texto es analizado a nivel documento, nivel frase o nivel aspecto. La etapa de pre-procesamiento y extracción de características es muy importante en este tipo de análisis. Por ese motivo, se siguen proponiendo diferentes métodos para la representación numérica de los textos de manera eficiente. Uno de los primeros métodos es TF-IDF [66], [67], que permite cuantificar la relevancia de las cadenas de texto, analiza la frecuencia de palabras y extrae palabras más esenciales del documento. Su utilidad esta basada en características de nivel léxico. Luego aparecen trabajos como Word2vec [6], GloVe [7] y FastText [8]. Estos empezaron a cambiar los paradigmas para representar palabras en vectores densos (word embeddings). Estos métodos permiten entender la semántica y sintáctica de las palabras. La función principal es encontrar la similitud o relación entre palabras en un espacio vectorial y no requieren de etiquetas. FastText a diferencia de GloVe y Word2vec representa palabras como bolsa de n-grams de caracteres, esto permite entender palabras raras. Estos métodos permiten mejorar el rendimiento de tareas en NLP. Sin embargo, estos algoritmos carecen de capacidad para representar el contexto y concepto de palabras. Para resolver es-




Figura 3.1 Propuesta de framework para estudiar la literatura contemporanea de Analisis de Sentimientos.

tos problemas, algunos trabajos proponen modelos que incorporan información contextual. Peters, Neumann, Iyyer et al. [9] proponen el modelo ELMO que permite la representación contextual de palabras: una palabra puede tener significado diferente según el contexto. Este trabajo utiliza modelos neuronales recurrentes de tipo Long Short-Term Memory (LSTM) y tiene pasos morfológicos para formar palabras que están fuera del vocabulario entrenado. Este método demostró grandes mejoras en tareas de NLP y principalmente en análisis de sentimientos. Desde entonces se han propuesto diferentes enfoques para word embedding. La arquitectura Transformer [44] es una de las más utilizadas hoy en día para la representación de palabras. Permite entrenar modelos neuronales profundos para tareas de NLP. Algunos modelos que utilizan esta arquitectura son: GPT [68] BERT [10], RoBERTa [69], ALBERT [70] y T5 [71]. Estos modelos aprenden contextos bidireccionales y fueron entrenados con millones de datos para entender las palabras polisémicas, estructura léxica y sintáctica. Lograron mejoras significativas de rendimiento en tareas de NLP.

Los modelos arriba mencionados fueron generalmente entrenados para tareas de propósito general, tales como: resumen de texto, marcado de párrafos, análisis de sentimientos, preguntas y respuestas, traducción, etc. Sin embargo, Han, Zhang, Ding et al. [11] mencionan que: comprender el lenguaje en un dominio y tarea específica permite que el aprendizaje supervisado sea más eficiente que aprender en un dominio general. También se espera que el conocimiento aprendido en dominio específico sea más profundo que en un dominio general. Por este motivo, se han propuesto modelos de representación de palabras de dominio específico, tales como: BioBERT (Biomedical) [12], SciBERT (Scientific text) [13], SentiLARE (Sentiment Analysis) [14] y PEGASUS (summarization)[15]. Los resultados muestran mejoras en la precisión en comparación a los modelos de dominio general.

Varios trabajos de la literatura reciente han descrito y experimentado procesos de análisis conceptual de las palabras [16], [72]. Estos trabajos han destacado la importancia que tiene el análisis del nivel conceptual de palabras para la comprensión del texto. Estos métodos consideran semánticas subyacentes del texto para comprender el análisis de sentimientos. La representación del concepto como vector numérico contribuye a medir la similitud entre palabras y textos [72]. Ma y Cambria [16] proponen un método para incorporar información conceptual en word embeddings y aplican la técnica de NER para encontrar palabras vecinas. Speer, Chin y Havasi [73] proponen ConceptNet Numberbatch, de dominio general, para representación de vectores de palabras semánticas. Determinan los significados de palabras que no se observan en contextos. El modelo fue entrenado con datos de Word2vec, GloVe y OpenSubtitles de 2016. Los resultados encontrados en estos trabajos son evidencias que el conocimiento basado en conceptos y grafos para word embedding pueden aportar en mejorar

la comprensión del contenido textual.

## 3.2. Resultados de la revisión

Esta sección se muestran hallazgos encontrados durante la revisión. A continuación, presentamos las siete fases de la propuesta (ver Figura 3.1), las cuales se basan en los resultados de la revisión sistemática.

### 3.2.1. Recolección de datos (Data collection)

En esta fase se identificaron varios conjuntos de datos públicos relacionados al análisis de sentimientos, como se detalla en la Tabla 3.2. La mayoría de los artículos de investigación utilizan conjuntos de datos recolectados de tweets, junto con conjuntos de datos de IMDB y Amazon, para determinar la polaridad positiva y negativa. La Figura 3.2 muestra la representatividad de los idiomas en los conjuntos de datos utilizados en varios modelos de clasificación de sentimientos. Es evidente que el inglés es el idioma más representativo en comparación con otros idiomas para el entrenamiento y validación de diferentes modelos.

Tabla 3.2 Los conjuntos de datos más utilizados para el análisis de sentimientos.

Dataset	Polaridad	Registros	Número de estudios
Tweets extraction <sup>a</sup>	-	-	66
IMDB movie review	positivo y negativo	50k	32
Amazon product review	positivo y negativo	568k	28
Yelp sentiment	positivo y negativo	560k	11
Sentiment140	positivo y negativo	1.6M	17
Twitter US Airline Sentiment	positivo, neutral y negativo	14.6k	16
SemEval 2014	positivo, neutral y negativo	6k	17
SemEval 2015	positivo, neutral y negativo	3k	8
SemEval 2016	positivo, neutral y negativo	4.5k	12
SemEval 2017	positivo, neutral y negativo	50k	7

<sup>a</sup> Los tweets de Twitter son extraídos de diferentes dominios (restaurante, películas, música, etc..) y los investigadores determinar las etiquetas de polaridad según análisis. Del mismo modo, se extraen otros conjuntos de datos de blogs, YouTube, Weibo y Facebook




Figura 3.2 Representatividad de los idiomas en conjuntos de datos comunes para el análisis de sentimientos.

### 3.2.2. Limpieza de datos (Data cleaning)

Durante esta fase, se realizan varias tareas para limpiar los datos. Sin embargo, las tareas específicas de limpieza a utilizar dependen del tipo de análisis y del conjunto de datos utilizado para el desarrollo del modelo. Identificamos 16 técnicas comunes de limpieza durante la revisión, las cuales se enumeran en la Tabla 3.3.

### 3.2.3. Pre-procesamiento (Preprocessing)

Esta fase tiene como objetivo preparar los datos para una extracción de características eficiente. Identificamos tres técnicas de preprocesamiento frecuentes: stemming, lematización y tokenización (ver Tabla 3.4). La elección de la técnica depende de los objetivos definidos para desarrollar el modelo.

### 3.2.4. Codificación de texto (Text encoding)

La codificación de texto es un paso importante en la clasificación de sentimientos. Su objetivo es encontrar representaciones numéricas de palabras. Se puede considerar como una forma de extracción de características para la fase anterior a la construcción del modelo.

Tabla 3.3 Técnicas de limpieza de datos para clasificación de sentimientos.

Nro.	Técnica
1	Lowercase
2	Remove unicode string and noise
3	Remove o replace url
4	Remove html tag
5	Remove number
6	Remove punctuation
7	Remove white space
8	Remove special character
9	Remove stopwords
10	Remove duplicated row
11	Remove emoticon
12	Remove o replace hashtags
13	Remove retweets
14	Remove o replace user mentions
15	Replace slang and abbreviations
16	Spelling correction

La Tabla 3.5 muestra las técnicas de codificación de texto más comunes que encontramos en artículos que proponen modelos no neuronales para la clasificación de sentimientos. Se puede ver que TF-IDF y BoW son las técnicas de codificación de texto más frecuentemente utilizadas. En artículos que proponen modelos basados en redes neuronales, las técnicas de codificación de texto suelen ser diferentes. Enumeramos dichas técnicas en la Tabla 3.6. Se puede ver que Word2vec es la técnica de codificación de texto más común en modelos basados en redes neuronales. También se utilizan comúnmente las técnicas GloVe, FastText y BERT como técnicas de incrustación de palabras. La mayoría de los autores indica que dichas codificaciones contribuyen a mejorar el rendimiento de los clasificadores de polaridad de sentimientos debido a sus buenas representaciones numéricas de palabras, que se obtienen mediante el pre-entrenamiento de los codificadores con grandes cantidades de datos.

### 3.2.5. Técnicas de Machine Learning

Las técnicas de Machine Learning están en el corazón del proceso de construcción de modelos de detección de sentimientos. En los resultados de esta revisión, agrupamos estas técnicas en aquellas que no están basadas en redes neuronales y aquellas que sí lo están. La Tabla 3.7 enumera las técnicas no basadas en redes neuronales, siendo las técnicas más populares NB, SVM, LR y modelos de ensamblaje (RF, Bagging, Voting, Stacking). La Tabla

Tabla 3.4 Técnicas de pre-procesamiento

Técnica	Número de estudios	Referencia
Tokenization	129	[74]-[201]
Lemmatization	33	[77], [81], [85], [90], [103], [116], [117], [125], [129], [133]-[136], [142], [145], [147], [148], [154], [167], [171], [173]-[175], [177], [181], [194], [198], [202]-[207]
Stemming	65	[79], [81], [82], [84], [85], [88], [93], [95]-[98], [102], [104], [106], [109], [116], [117], [119], [124], [126]-[129], [137], [138], [141], [146]-[148], [150]-[153], [156], [162], [163], [165], [166], [168], [171], [173], [175], [177], [181], [185]-[188], [191], [194]-[197], [203], [205], [208]-[214]

3.8 muestra las técnicas basadas en redes neuronales. Las arquitecturas de redes neuronales más comunes son las Convolutional Neural Networks (CNN), Long Short Term Memory (LSTM), Gated Recurrent Unit (GRU) y las redes Attention Mechanisms (AM). Estas arquitecturas se utilizan de forma independiente o hibridizadas con otros modelos neuronales o no neuronales. Las técnicas con mayores ganancias de rendimiento son generalmente modelos híbridos.

### 3.2.6. Clasificación de polaridad (Polarity classification granularity)

Las etiquetas de clasificación de polaridad de sentimientos normalmente se determinan en la definición del proyecto de desarrollo del modelo, ya que definen los requisitos de etiquetado de datos para la fase de entrenamiento y validación. La mayoría de los estudios de clasificación de polaridad apuntan a dos clases: sentimientos positivos y sentimientos negativos. También es común encontrar modelos de clasificación de tres polaridades: sentimientos positivos, negativos y neutrales. La Figura 3.3 muestra la proporción relativa de los estudios para cada granularidad de clasificación. Podemos observar que hay algunos trabajos que se enfocan en cinco polaridades: clases muy positivas, positivas, neutrales, negativas y muy negativas. Este pequeño número de estudios probablemente se deba al pequeño número de conjuntos de datos disponibles que tienen más de 3 clases etiquetadas.

Tabla 3.5 Técnicas comunes de codificación de texto encontradas en modelos no neuronales para la clasificación de sentimientos.

Nro.	Técnica	Número de estudios	Referencia
1	Term Frequency-Inverse Document Frequency (TF-IDF)	29	[77], [79], [83], [85], [86], [88]-[91], [94], [124], [126]-[129], [145], [146], [148], [150], [151], [153], [204], [205], [209], [215]-[219]
2	Bag of Word (BoW)	19	[74], [79], [80], [82], [89], [94], [129], [146], [151], [152], [203], [205], [209], [215], [216], [220]-[223]
3	N-Gram	11	[75], [76], [85], [88], [91], [92], [204], [218], [222], [224], [225]
4	Word2vec	8	[89], [124], [150], [202], [203], [205], [220], [223]
5	Word vector construction	5	[78], [81], [83], [148], [149]
6	GloVe	3	[79], [124], [203]
7	Doc2vec	2	[89], [221]
8	StringToWordVector	1	[216]
9	BERT	1	[147]

### 3.2.7. Métricas de evaluación (Evaluation metrics)

La Tabla 3.9 muestra las métricas de evaluación que encontramos en los estudios revisados. Las métricas más comúnmente utilizadas son *Accuracy*, *Precision*, *Recall* y *F1-score*. Sin embargo, se han utilizado otras métricas de evaluación para la evaluación del modelo, como *AUC*, *Kappa score*, etc. Muchos estudios utilizan más de una métrica. Esto se debe a que cada métrica evalúa o enfatiza algún aspecto de los resultados, por lo que el uso de múltiples métricas genera una visión más amplia de las capacidades del modelo.

## 3.3. Desafíos y oportunidades

Luego de revisar los trabajos identificados, se analizó las lagunas y desafíos actuales del área y oportunidades de investigaciones futuras. A continuación describimos algunos retos que podrían ayudar con el progreso de Análisis de Sentimientos.

**Reducir costo computacional.** La mayoría de modelos requieren de buena capacidad

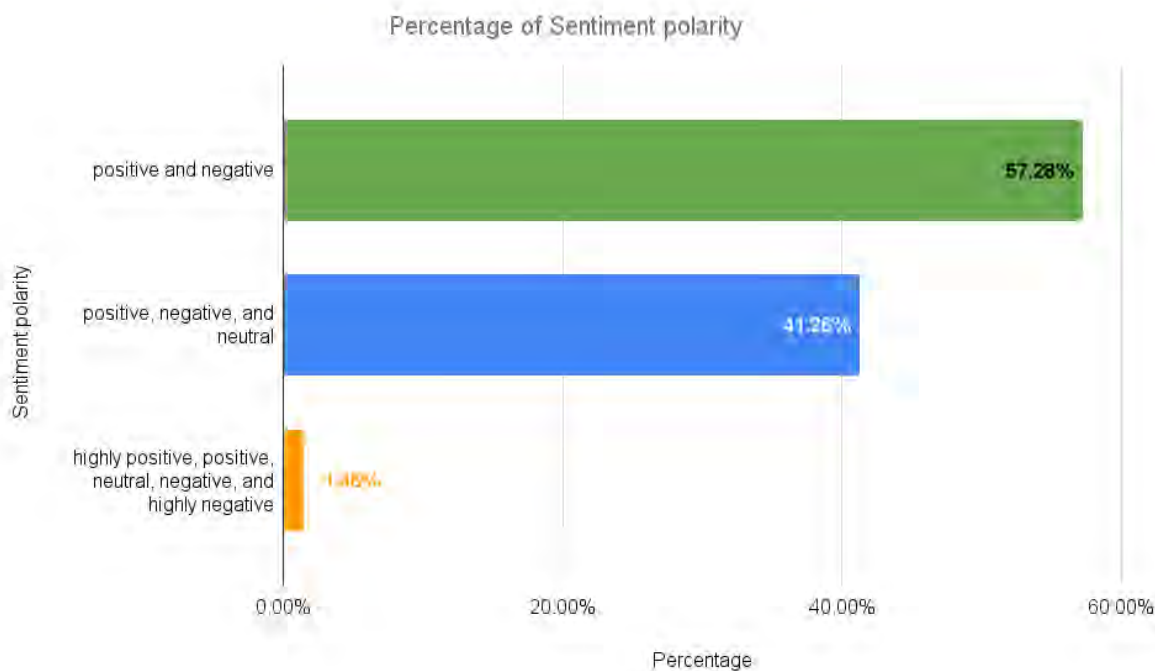


Figura 3.3 Porcentaje de polaridad de sentimiento más utilizada para la clasificación de sentimientos.

de memoria para el entrenamiento. Por ejemplo, utilizar el dataset Sentiment140 (1.6 millones de registros) con modelos pre-entrenados para extracción de características y redes neuronales profundas, tienen un entrenamiento lento. Incorporar técnicas que permitan reducir el costo computacional de modelos de Machine y Deep Learning tiene un potencial de mejorar el rendimiento de los modelos; porque permitiría encontrar mas rápidamente los mejores hiperparámetros.

**Nuevos dataset.** En la revisión de estudios recientes encontramos conjuntos de datos frecuentes dentro de Análisis de Sentimientos. A continuación mencionamos los más utilizados: 39 estudios extraen opiniones Twitter, 27 estudios utilizan IMDB movie review, 22 estudios utilizan Amazon review y 14 utilizan Sentiment140. Sin embargo, aún existe la necesidad de proponer nuevos conjuntos de datos con mayor cantidad de registros, multiclasificaciones, polaridad por cada entidad y multilinguaje. Así mismo, construir conjuntos de datos orientado hacia dominios específicos.

**Análisis de Sentimiento a nivel de aspecto.** La mayoría de investigaciones están basadas en nivel de documento y frase porque existen conjunto de datos que tienen esa orientación por ejemplo como: IMDB, Amazon review, Twitter US airline, Sentiment140, Yelp Sentiment. Sin embargo, el nivel de aspecto es una área relativamente nueva y poco

estudiada. En ese sentido el conjunto de datos SemEval es el único que tiene etiquetas a nivel de aspecto. Por tal motivo, se requiere nuevos estudios con conjunto de datos y modelos relacionados al Análisis de sentimientos basados en aspectos y dominios específicos.

**Comprender texto basado en conceptos.** La fase de codificación basado en Word Embedding contribuye en obtener mejores modelos de clasificación de sentimientos. Estas técnicas son conocidas basadas en comprender la similaridad semántica y sintáctica, tienen un análisis forma contextual. Sin embargo, para entender conceptualmente cada palabra del texto debemos implementar el análisis de nivel conceptual. Esta técnica va permitir encontrar palabras óptimas de forma explícita y podrá definir cada palabra de sentimiento conceptualmente y no agrupar por similitudes como hacen los modelos conocidos.

**Modelos de Deep Learning.** Los modelos de Deep learning con Convolutional Neural Network, Recurrent Neural Network, Transformers y Attention Mechanisms han demostrado buenos resultados para Análisis de Sentimientos; sin embargo, estos no pueden entender directamente los símbolos y palabras del texto. Existe la necesidad de desarrollar arquitecturas basadas en Redes Neuronales Profundas que puedan entender los textos en sus diferentes niveles de abstracción (léxico, sintáctico, semántico, morfológicos, contextual y conceptual) para comprender completamente el texto.



Tabla 3.6 Técnicas comunes de codificación de texto encontradas en modelos neuronales para la clasificación de sentimientos.

Nro.	Técnica	Número de estudios	Referencia
1	Word2Vec	53	[98], [101], [103], [107], [109], [110], [114]-[116], [118], [121], [133], [135], [139], [154], [155], [159]-[161], [166], [168], [169], [174], [177], [178], [182], [185]-[188], [190], [198], [199], [211], [226]-[244]
2	GloVe	42	[47], [96], [99], [103], [105], [112], [116], [120], [123], [134], [136], [139], [159]-[161], [167], [170], [171], [175], [178], [187], [190], [207], [226], [229], [232], [233], [235], [236], [238], [242], [243], [245]-[253]
3	BERT	26	[47], [95], [97], [131], [155]-[157], [164], [172], [178], [179], [181], [182], [184], [194], [196], [201], [227], [240], [254]-[260]
4	FastText	18	[97], [116], [134], [137], [159]-[161], [167], [168], [191], [238], [239], [242], [255], [261]-[263]
5	TF-IDF	16	[102], [103], [134], [135], [138], [144], [174], [182], [188], [190], [210], [213], [214], [229], [247]
6	Embedding function or hybrid	11	[158], [162], [163], [165], [173], [180], [183], [189], [192], [195], [200]
7	RoBERTa	5	[122], [140], [176], [196], [197]
8	BoW	5	[102], [210], [213], [214], [235]
9	DistilBERT	3	[194], [196], [197]
10	N-gram	3	[211], [235], [264]
11	Graph Construction	3	[201], [265], [266]
12	Word2Sent	1	[236]
13	Sent2seq	1	[106]
14	ALBERT	1	[193]

Tabla 3.7 Técnicas de Machine Learning no basadas en redes neuronales para la inducción de clasificadores de sentimiento.

Nro.	Técnica	Número de estudios	Referencia
1	Support Vector Machine	43	[79], [81]-[87], [89]-[92], [94], [100], [124], [126]-[129], [145]-[153], [203]-[206], [208], [217]-[220], [222], [223], [267]-[270]
2	Naive Bayes	41	[76]-[78], [80]-[83], [85]-[87], [89]-[94], [100], [124], [127], [128], [147], [148], [152], [153], [203]-[205], [208], [209], [215]-[219], [222], [224], [225], [268]-[271]
3	Random Forest	30	[74], [76], [77], [79], [83]-[85], [88], [89], [93], [124], [126]-[129], [145], [147]-[151], [153], [203], [221], [224], [225], [268], [270]
4	Logistic Regression	28	[74], [76], [77], [79], [80], [82], [83], [85], [86], [91]-[93], [124], [127], [145]-[149], [151], [152], [203], [205], [216], [217], [220], [268]
5	Decision Tree	20	[74], [77], [83], [85], [87], [89], [100], [124], [126], [145], [146], [148], [152], [153], [203], [217], [219], [221], [267], [270]
6	K-nearest Neighbors	15	[76], [81]-[85], [89], [146], [148], [150], [152], [153], [203], [267], [268]
7	Boosting (Adaboost, Gradient Boosting, XGBoost, LogitBoost)	12	[79], [83], [85], [87], [91], [124], [129], [147], [148], [203], [221]
8	Stochastic Gradient Descent	6	[77], [79], [91], [145], [202], [203]
9	Voting	3	[152], [222], [224]
10	Bagging	2	[88], [222]
11	Sequential Minimal Optimization (SMO)	2	[93], [267]
12	Stacking	1	[81]

Tabla 3.8 Técnicas de Machine Learning basadas en redes neuronales para la inducción de clasificadores de sentimiento.

Técnica	Número de estudios	Referencia
- LSTM	49	[96], [98], [100], [102], [104], [106], [122], [134], [135], [137], [139], [140], [154], [156], [157], [159], [162], [164], [166]-[169], [172]-[174], [176], [177], [179], [181], [188], [189], [192], [196], [200], [202], [210], [214], [228], [237], [239], [241], [249], [256], [259], [262], [264], [270], [272], [273]
- CNN	39	[96], [98], [100], [106], [134], [135], [137], [139], [155], [157], [159], [161], [163]-[167], [172], [173], [176], [179], [182], [183], [189], [196], [198], [200], [202], [205], [210], [228], [236], [241], [243], [244], [262], [263], [270], [274]
- BiLSTM	29	[97], [98], [106], [130], [134], [136], [137], [140], [154], [155], [157], [158], [161], [163], [167], [172], [177], [182], [191], [192], [196]-[198], [200], [210], [211], [237], [239], [256]
- CNN & LSTM	26	[98], [100], [109], [114], [118], [121], [132], [134], [165], [166], [171], [179], [180], [183], [200], [210], [213], [228], [230], [232], [235], [247], [252], [256], [270], [275]
- CNN & BiLSTM	17	[95], [109], [113], [123], [134], [144], [165], [167], [170], [187], [194], [198]-[200], [242], [250], [276]
- GRU	15	[140], [154], [157], [165], [172], [173], [179], [192], [196], [198], [202], [210], [211], [238], [239]
- LSTM & AM	9	[103], [111], [112], [163], [176], [212], [234], [253], [277]
- CNN & LSTM or BiLSTM or GRU or BiGRU & SVM or NB or LR	8	[142], [162], [183], [192], [199], [244], [255], [257]
- BiGRU	8	[104], [133], [154], [158], [162], [163], [191], [197]
- CNN & BiLSTM & AM	7	[99], [120], [175], [184], [199], [226], [260]
- LSTM & CNN & AM	3	[101], [230], [231]
- CNN & GRU	3	[95], [104], [179]
- CNN & AM	3	[173], [212], [227]
- BiLSTM & AM	3	[110], [178], [245]
- CNN & BiGRU	2	[115], [143]
- BiGRU & BiLSTM & CNN & AM	2	[105], [191]
- BiGRU & CNN & AM	2	[160], [248]
- CNN & BiLSTM & GRU & AM	1	[207]
- BiLSTM & AM & LR	1	[108]
- Graph Convolutional Network & AM	1	[47]
- Knowledge Graph & LSTM or BiLSTM	1	[265]
- BiLSTM & GRU & AM	1	[251]

Tabla 3.9 Métricas de evaluación más utilizadas.

Nro.	Métrica	Cantidad de estudios
1	Accuracy	206
2	Precision	159
3	Recall	159
4	F1-score	151
5	F1-macro	11
6	AUC	8
7	Kappa score	4
8	F1-micro	3

# Capítulo 4

## Metodología

El contenido de este capítulo presenta la metodología propuesta de la investigación, cuyo objetivo fue diseñar un enfoque basado en conocimiento de grafos para el análisis de sentimientos en textos. Como resultado, se publicó un artículo científico [278] en la revista *IEEE Open Journal of the Computer Society*. Y. Mamani-Coaquira y E. Villanueva. *An Unsupervised Model Based on Knowledge Graph and Concepts for Sentiment Analysis*. *IEEE Open Journal of the Computer Society*, vol. 6, págs. 1561-1574, 2025. doi: <https://doi.org/10.1109/OJCS.2025.3616329>. Esta publicación respalda la metodología propuesta y evidencia su relevancia y originalidad científica en el campo del análisis de sentimientos.

### 4.1. Flujo de trabajo de la metodología

La Figura 4.1 muestra el flujo de trabajo general del enfoque propuesto basado en conocimiento de grafos para el análisis de sentimientos. El proceso comienza con la recolección y pre-procesamiento de datos, lo que implica la lectura y limpieza de los datos. A continuación, se construyen diccionarios de palabras conceptuales basados en WordNet y ConceptNet. Posteriormente, se generan nuevas oraciones utilizando WordNet y ConceptNet para mejorar el corpus con relaciones semánticas adicionales. Luego, se construyen diccionarios de palabras clasificadas por polaridad (positivas, negativas y neutrales) utilizando VADER (*Valence Aware Dictionary and sEntiment Reasoner*). Utilizando esta información, se genera un grafo de co-ocurrencia, y se aplican recorridos aleatorios sesgados por polaridad de palabras para crear embeddings de palabras más representativas. Estos embeddings pueden ser utilizados por varios algoritmos de machine learning, como Support Vector Machine (SVM), Random Forest (RF), XGBoost (XGB), Logistic Regression (LR), y K-nearest Neighbor (KNN), para realizar el entrenamiento de modelos y clasificación de sentimientos.

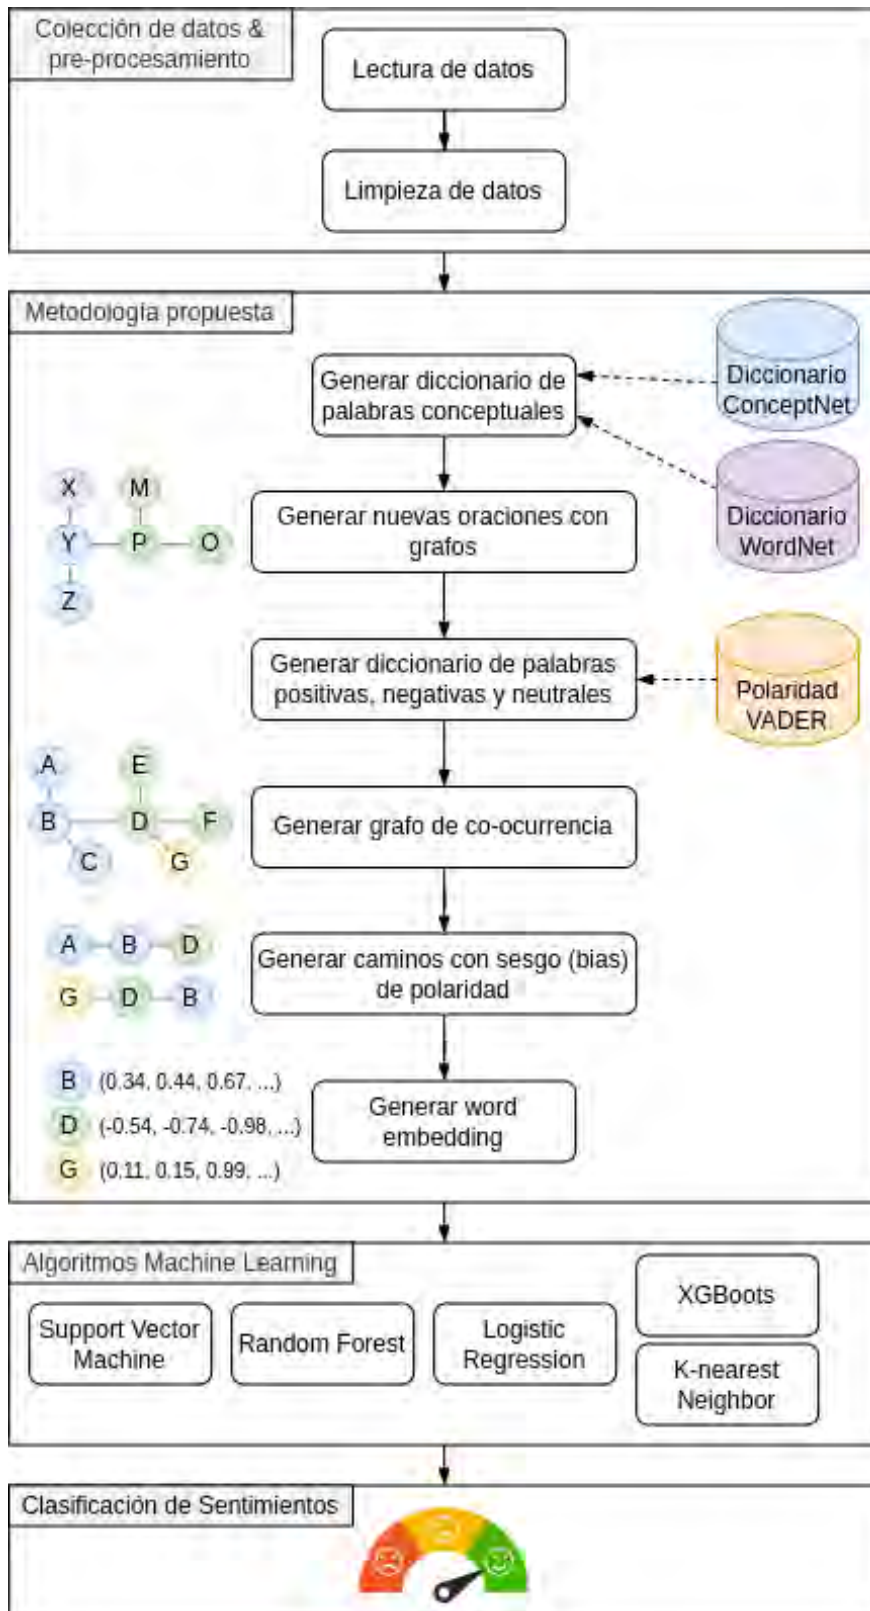


Figura 4.1 Flujo de trabajo general de la metodología propuesta basada en conocimiento de grafos para el análisis de sentimientos.

La propuesta de esta metodología tiene un enfoque que permite realizar una representación conceptual de palabras y polaridad para análisis de sentimientos mediante fundamentos de conocimiento de grafos y embeddings. Cada paso depende de la anterior para construir una representación de mayor calidad que permita una clasificación más precisa. Esta metodología está basada en conocimiento de grafos y permite no solo capturar relaciones conceptuales, sino también la relación de polaridad entre palabras, y el paso de generar caminos con sesgo de polaridad refuerza este aspecto, generando embeddings mediante el modelo de Skip-Gram que no solo representa la proximidad semántica, sino también la coherencia emocional. En ese sentido, la metodología no solo optimiza la calidad de embedding con enfoque de sentimientos, sino que también mejora la capacidad de los algoritmos de clasificación para identificar y diferenciar polaridades, logrando así una mejora en la precisión de clasificación de polaridad.

## 4.2. Colección de datos y preprocesamiento

En este trabajo, utilizamos el conjunto de datos de películas de IMDB, que se usa comúnmente para el análisis de sentimientos. El conjunto de datos consiste en reseñas de películas etiquetadas con su polaridad correspondiente (positiva o negativa). Para preparar los datos para la generación de embeddings, implementamos un algoritmo de limpieza de datos para eliminar el ruido textual. En este proceso se aplicó procesos convencionales que involucró convertir el texto a minúsculas, eliminar etiquetas HTML, eliminar URLs, menciones en redes sociales y caracteres especiales. También eliminamos corchetes y palabras de más de 20 caracteres, y normalizamos los espacios en blanco. Después de esto, aplicamos lematización, tokenización y eliminamos un conjunto de palabras vacías en inglés para reducir el tamaño del vocabulario sin perder el significado esencial para el análisis de sentimientos.

Por ejemplo, la oración original *"The Transformers movie was fun and visually spectacular"* luego de aplicar el pre-procesamiento generaría la oración: *"transformer movie fun visually spectacular"*.

Para comprender mejor los datos, agrupamos las reseñas de IMDB utilizando TF-IDF y BERT embeddings, seguidos de K-means. La figura 4.2 muestra una proyección de los BERT embeddings en los dos primeros componentes PCA. Esto muestra una fuerte mezcla de reseñas positivas y negativas sin una separación clara. La concordancia entre los clústeres K-means y las etiquetas de sentimiento es baja: encontramos un Adjusted Rand Index (ARI) de 0,0217 y una puntuación de Purity de 0,5765 utilizando las incrustaciones TF-IDF, y un ARI de 0,0011 y una puntuación de Purity de 0,523 utilizando las incrustaciones BERT [279]. Estos resultados indican un solapamiento léxico/semántico sustancial entre las clases, lo que subraya la dificultad de la clasificación del sentimiento en este ámbito.

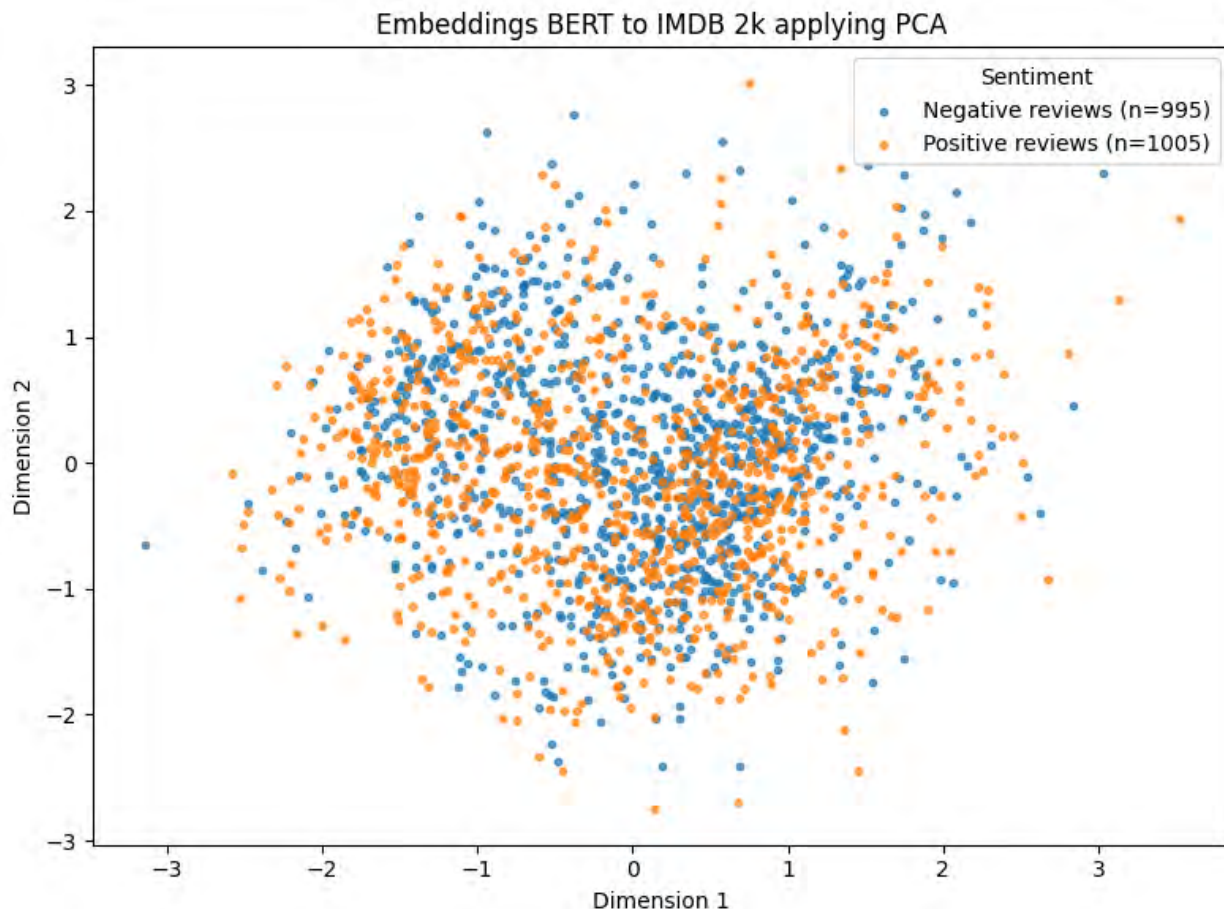


Figura 4.2 Diagrama de dispersión de las dos primeras componentes principales (PCA) derivadas de las incrustaciones BERT de las reseñas de IMDB. Los colores indican las etiquetas de sentimiento.

### 4.3. Generar diccionario de palabras conceptuales

Esta sección consiste en la creación de un diccionario que relacione palabras originales con sus conceptos semánticamente similares. Bases de datos léxicas como ConceptNet y WordNet se utilizan para construir este diccionario obteniendo palabras relacionadas con sinónimos e hipónimos. Al incorporar palabras conceptuales, los datos del corpus se mejoran, lo que da como resultado una representación más variada de las oraciones.

Dado un conjunto de oraciones  $O = \{o_1, o_2, \dots, o_n\}$  (por ejemplo, extraídas del conjunto de datos de películas de IMDB) y sus conceptos asociados  $C(o_i)$  obtenidos de bases como ConceptNet o WordNet, el diccionario conceptual  $D$  de una oración  $C(o_i)$  se define como:

$$D(o_i) = \{c_{i1}, c_{i2}, \dots, c_{im}\} \quad \text{donde} \quad c_{ij} \in C(o_i) \quad (4.1)$$

Por ejemplo, considerando la oración "transformer movie fun visually spectacular". Seguidamente se emplea una función para obtener palabras conceptuales, el diccionario de palabras para WordNet y ConceptNet sería según las Tablas 4.1 y 4.2 respectivamente.

Tabla 4.1 Diccionario de palabras conceptuales de WordNet para la oración "transformer movie fun visually spectacular".

Orden	Palabra original	Conceptos
1	transformer	-
2	movie	<i>moving_picture, flick, pic, motion_picture, picture_show, moving_picture_show, film, motion_picture_show, picture</i>
3	fun	<i>merriment, sport, play, playfulness</i>
4	visually	-
5	spectacular	<i>outstanding, salient, prominent, striking, dramatic</i>

Tabla 4.2 Diccionario de palabras conceptuales de ConceptNet para la oración "transformer movie fun visually spectacular".

Orden	Palabra original	Conceptos
1	transformer	<i>shape-change, vehicle, voltage, device, transform</i>
2	movie	<i>cinema, film, screen</i>
3	fun	<i>activity, amusement, funny, kid, playful, playfulness</i>
4	visually	<i>aurally, sight</i>
5	spectacular	<i>display, dramatic, glasses, outstanding, species, spectacle, striking</i>

#### 4.4. Generar nuevas oraciones con grafos

En esta fase, el objetivo es generar nuevas oraciones utilizando el conjunto de datos de películas de IMDB. Esto se hará mediante un enfoque basado en el conocimiento grafos y extrayendo palabras conceptuales a través del diccionario de palabras conceptuales  $D(o_i)$ . Cada palabra de la oración original se representará como un nodo en el grafo, y se conectarán nodos adicionales mediante aristas para representar palabras conceptuales.

#### 4.4.1. Generar grafo

El grafo  $G_j = (V_j, E_j)$  se genera para cada oración  $o_j$ , donde los nodos  $V_j$  representan tanto las palabras originales de la oración como sus conceptos relacionados.

Dada la oración  $o_j = \{w_1, w_2, \dots, w_k\}$ , del conjunto de nodos  $V_j$  del grafo consta de las palabras originales  $w_i$  y sus conceptos  $D(w_i) = \{c_{i1}, c_{i2}, \dots, c_{im}\}$ , donde  $c_{ij} \in C(w_i)$  es un concepto asociado con  $w_i$ . El conjunto de nodos  $V_j$  se define como:

$$V_j = \{w_1, w_2, \dots, w_k\} \cup D(w_i) \quad (4.2)$$

El conjunto de aristas  $E_j$  contiene dos tipos de relaciones:

- Las conexiones entre palabras consecutivas en la oración:

$$E_j = \{(w_i, w_{i+1}) \mid 1 \leq i < k\} \quad (4.3)$$

- Las conexiones entre cada palabra  $w_i$  y sus conceptos  $c_{ij} \in D(w_i)$ :

$$E'_j = \{(w_i, c_{ij}) \mid c_{ij} \in D(w_i)\} \quad (4.4)$$

El grafo resultante para cada oración es  $G_j = (V_j, E_j \cup E'_j)$ , representando la estructura semántica de la oración y sus relaciones conceptuales.

Considerando el ejemplo de la oración y sus conceptos de las Tablas 4.1 y 4.2 el nuevo grafo construido de la oración original según los conceptos de WordNet es la Figura 4.3 y para ConceptNet es la Figura 4.4.

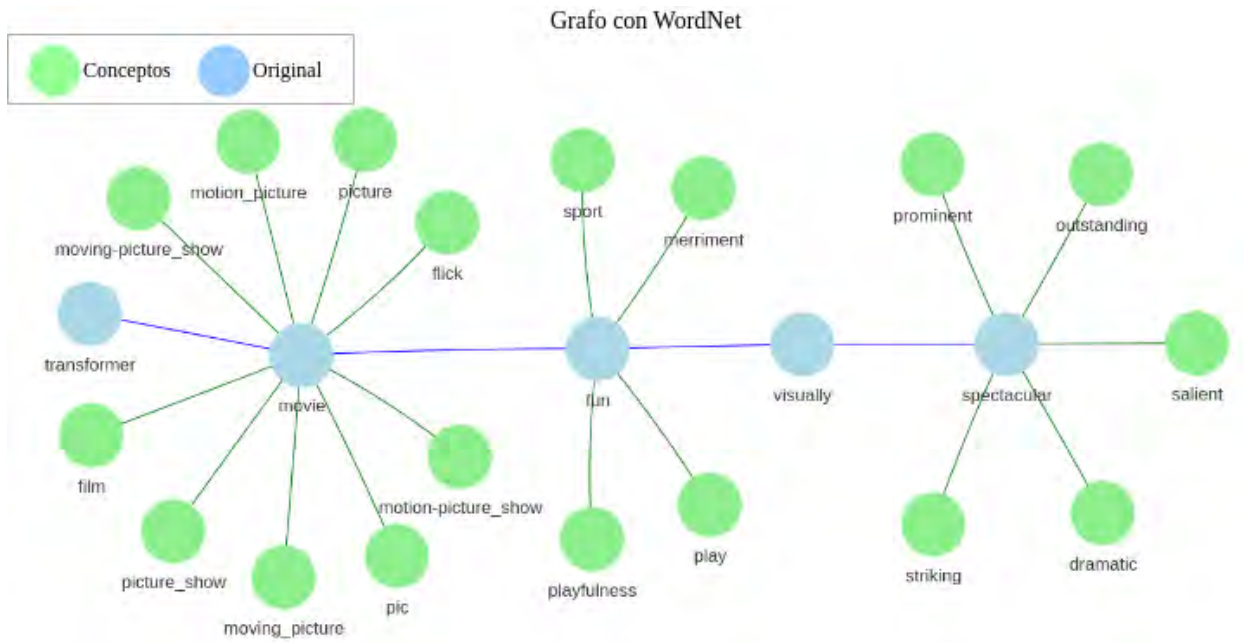


Figura 4.3 Ejemplo de grafo generado de la oración "transformer movie fun visually spectacular" con sus palabras conceptuales utilizando WordNet.

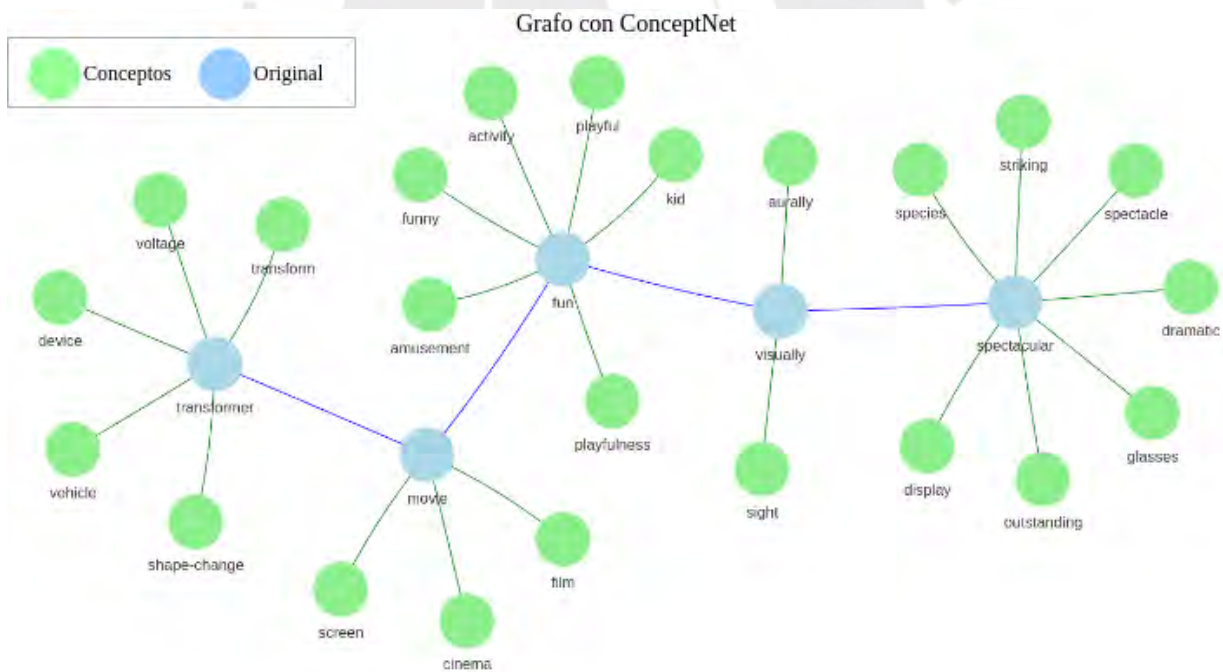


Figura 4.4 Grafo generado de la oración "transformer movie fun visually spectacular" con sus palabras conceptuales utilizando ConceptNet.

#### 4.4.2. Generar combinación de palabras conceptuales

El  $G_j$  representa una nueva combinación de palabras conceptuales para cada oración donde para cada palabra  $w_i$ , se consideran tanto la palabra original como sus conceptos  $D(w_i)$ , y se generan todas las combinaciones posibles de estas palabras.

El conjunto total de combinaciones posibles para una oración  $o_j$  se define como el producto cartesiano de las opciones disponibles para cada palabra  $w_i$ :

$$\mathcal{C}(o_j) = \prod_{i=1}^k (\{w_i\} \cup D(w_i)) \quad (4.5)$$

Cada palabra original  $w_i$  se puede reemplazar por cualquiera de sus conceptos  $c_{ij} \in D(w_i)$ . Del mismo modo, el número de combinaciones está limitado a un máximo  $\mathcal{C}_{\text{selected}}$  que representa el número total de frases seleccionadas de un subconjunto aleatorio de combinaciones realizadas en  $\mathcal{C}(o_j)$ .

La Tabla 4.3 y 4.4 representan un ejemplo de conjunto de  $\mathcal{C}_{\text{selected}}$  formado por combinaciones aleatorias utilizando WordNet y ConceptNet respectivamente. Para este ejemplo se generaron 10 oraciones posibles similares a la oración original. Estas combinaciones se realizaron a partir de la oración original *transformer movie fun visually spectacular*. Estas nuevas oraciones se forman mediante recorrido de nodos de forma aleatoria.

Tabla 4.3 Ejemplo de oraciones generadas a partir del grafo con WordNet y oración "transformer movie fun visually spectacular".

Combinación	Nuevo oración
Combinación 1	(transformer, moving_picture, fun, visually, salient)
Combinación 2	(transformer, flick, sport, visually, striking)
Combinación 3	(transformer, film, playfulness, visually, striking)
Combinación 4	(transformer, moving_picture_show, play, visually, dramatic)
Combinación 5	(transformer, moving_picture, play, visually, salient)
Combinación 6	(transformer, moving_picture_show, sport, visually, salient)
Combinación 7	(transformer, motion_picture_show, playfulness, visually, spectacular)
Combinación 8	(transformer, moving_picture_show, play, visually, striking)
Combinación 9	(transformer, film, play, visually, prominent)
Combinación 10	(transformer, pic, fun, visually, prominent)

Las Figuras 4.5 y 4.6 representan ejemplos del recorrido de caminos por cada nodo seleccionando una palabra de forma aleatoria. La combinación 2 y 9 de la Figura 4.5 son recorridos realizados con WordNet y que se encuentran dentro de las 10 combinaciones en la

Tabla 4.4 Ejemplo de oraciones generadas a partir del grafo con ConceptNet y oración "transformer movie fun visually spectacular".

Combinación	Nuevo oración
Combinación 1	( <i>vehicle, screen, activity, aurally, glasses</i> )
Combinación 2	( <i>transformer, movie, funny, aurally, glasses</i> )
Combinación 3	( <i>vehicle, film, activity, visually, spectacle</i> )
Combinación 4	( <i>transform, cinema, amusement, visually, spectacular</i> )
Combinación 5	( <i>voltage, film, fun, visually, species</i> )
Combinación 6	( <i>vehicle, screen, playful, visually, spectacular</i> )
Combinación 7	( <i>device, movie, kid, visually, striking</i> )
Combinación 8	( <i>device, cinema, fun, sight, striking</i> )
Combinación 9	( <i>vehicle, film, amusement, sight, dramatic</i> )
Combinación 10	( <i>shape-change, cinema, playfulness, aurally, display</i> )

Tabla 4.3. De la misma forma, la combinación 4 y 8 de la Figura 4.6 son recorridos realizados con ConceptNet y que se encuentran dentro de las 10 combinaciones en la Tabla 4.4.

### 4.4.3. Obtener nuevas oraciones

Las combinaciones seleccionadas  $\mathcal{C}_{\text{selected}}$  se utilizan para construir nuevas oraciones. Cada combinación de  $\mathcal{C}_{\text{selected}}$  resulta en una nueva oración donde algunas palabras originales han sido reemplazadas por sus conceptos.

Para cada combinación  $c \in \mathcal{C}_{\text{selected}}$ , se genera una nueva oración  $o_j^{\text{new}}$  como una secuencia de palabras  $w'_i$ , donde  $w'_i \in \{w_i\} \cup D(w_i)$ . La nueva oración está dada por:

$$o_j^{\text{new}} = (w'_1, w'_2, \dots, w'_k) \quad (4.6)$$

El conjunto total de nuevas oraciones generadas a partir de la oración original  $o_j$  se denota como:

$$\mathcal{O}_j^{\text{new}} = \{o_j^{\text{new}} \mid o_j^{\text{new}} \in \mathcal{C}_{\text{selected}}\} \quad (4.7)$$

Finalmente, el conjunto de todas las nuevas oraciones generadas para todo el conjunto de datos es donde  $N$  es el número total de oraciones en el conjunto de datos.

$$\mathcal{O}^{\text{new}} = \bigcup_{j=1}^N \mathcal{O}_j^{\text{new}} \quad (4.8)$$

La Tabla 4.5 representa las nuevas oraciones seleccionadas mediante el recorrido de pa-

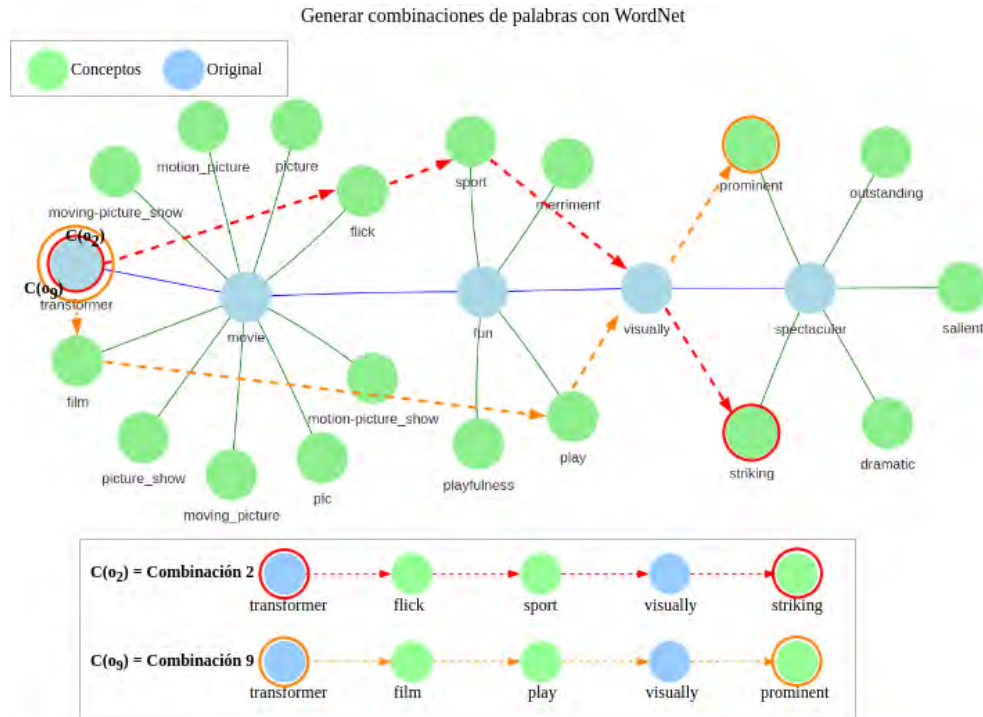


Figura 4.5 Grafo representativo para generar nuevas oraciones combinando palabras conceptuales con WordNet.

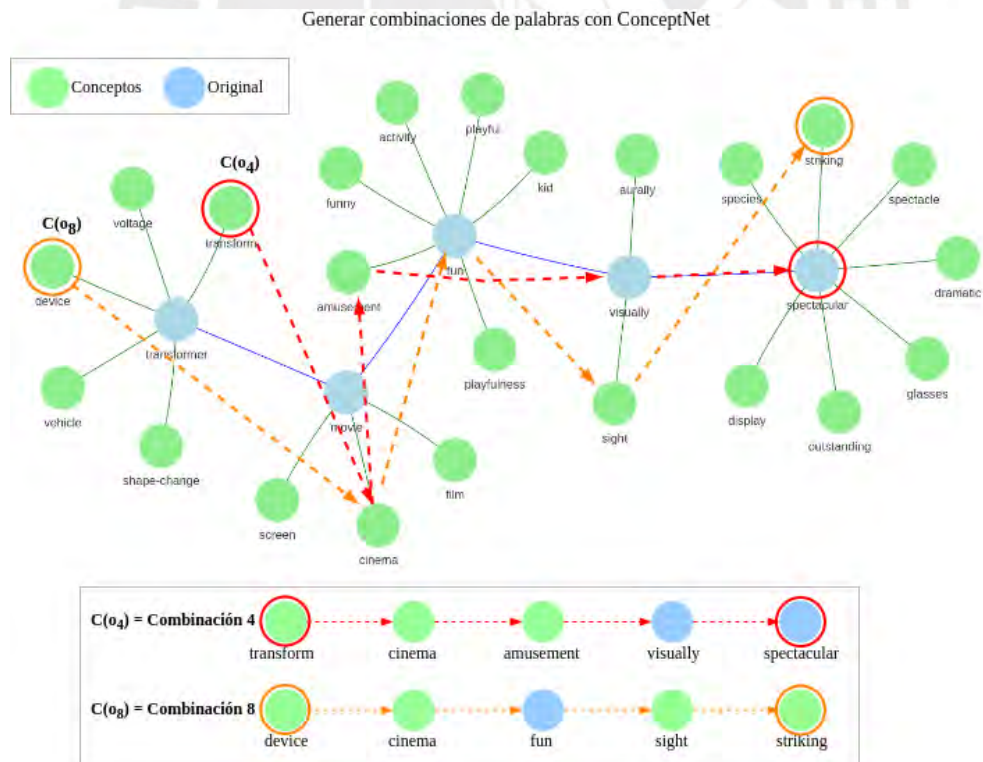


Figura 4.6 Grafo representativo para generar nuevas oraciones combinando palabras conceptuales con ConceptNet.

labras entre nodos que fueron generadas en el ejemplo de las Figuras 4.5 y 4.6.

Tabla 4.5 Nuevas oraciones seleccionadas.

Combinación	Concepto	Oración seleccionada
Combinación 4	WordNet	<i>transformer moving-picture-show play visually dramatic</i>
Combinación 5	WordNet	<i>transformer moving-picture play visually salient</i>
Combinación 10	WordNet	<i>transformer pic fun visually prominent</i>
Combinación 4	ConceptNet	<i>transform cinema amusement visually spectacular</i>
Combinación 2	ConceptNet	<i>transformer movie funny aurally glasses</i>
Combinación 9	ConceptNet	<i>vehicle film amusement sight dramatic</i>

## 4.5. Generar diccionario de polaridad de palabras

En esta fase, creamos un diccionario de polaridad de palabras utilizando el léxico VADER. Este diccionario clasifica las palabras como positivas, negativas o neutrales al evaluar el puntaje de cada palabra en el léxico VADER. Este diccionario facilita el proceso de etiquetar palabras según su sentimiento en las tareas de análisis de sentimientos. Para cada palabra  $w \in \text{VADER}$ , la polaridad se asigna de la siguiente manera:

$$W_{\text{polarity}} = \begin{cases} 1 & \text{if } \text{score}(w) \geq 0,05 \quad (\text{Positive}) \\ -1 & \text{if } \text{score}(w) \leq -0,05 \quad (\text{Negative}) \\ 0 & \text{if } -0,05 < \text{score}(w) < 0,05 \quad (\text{Neutral}) \end{cases} \quad (4.9)$$

El diccionario de polaridad  $\mathcal{D}_{\text{polarity}}$  asigna cada palabra  $w$  a su polaridad correspondiente  $W_{\text{polarity}}$ .

## 4.6. Generar grafo de co-ocurrencia

En esta fase, se crea un grafo para representar relaciones de co-ocurrencia y conexiones de palabras conceptuales basadas en la polaridad. Para cada secuencia de *tokens* en una oración, el grafo identifica las palabras presentes en el vocabulario (*tokens*) y establece conexiones (aristas) entre palabras que co-ocurren dentro de una ventana de contexto específica. Además, el diccionario conceptual agrega nuevos nodos y aristas para palabras del vocabulario solo si estas palabras conceptuales son parte del diccionario de polaridad.

Dada una oración representada como una secuencia de palabras  $T = \{w_1, w_2, \dots, w_n\}$ , el conjunto de nodos  $N$  consiste en las palabras que aparecen en la oración  $N = \{w_1, w_2, \dots, w_n\}$ . Cada palabra  $w_i \in T$  se representa como un nodo en el grafo.

Para cada palabra  $w_i \in N$ , una ventana de contexto de tamaño  $k$  se define alrededor de  $w_i$ , lo que significa que  $w_i$  está conectada a las palabras  $w_j$  que están a  $k$  posiciones a la izquierda o derecha. Los bordes de co-ocurrencia se definen como:

$$E_{\text{co-occurrence}} = \{(w_i, w_j) \mid |i - j| \leq k, i \neq j, w_i, w_j \in N\} \quad (4.10)$$

El diccionario conceptual  $D(w_i)$  contiene los conceptos de cada palabra  $w_i$ . Para cada palabra  $w_i$ , se recuperan sus conceptos, y si un concepto  $c \in C(w_i)$  pertenece al conjunto de palabras de polaridad  $W_{\text{polarity}}$ , se añade una arista semántica entre  $w_i$  y  $c$ .

Los aristas semánticas se definen como:

$$E_{\text{semantic}} = \{(w_i, c) \mid c \in D(w_i), c \in W_{\text{polarity}}\} \quad (4.11)$$

El resultado del grafo  $G$  es no dirigido compuesto por el conjunto de nodos  $N$  y el conjunto de aristas  $E$ , que incluye tanto aristas de co-ocurrencia como aristas semánticas.

$$G = (N, E), \quad \text{where} \quad E = E_{\text{co-occurrence}} \cup E_{\text{semantic}} \quad (4.12)$$

Las Figuras 4.7 y 4.8 representan el resultado del grafo de co-ocurrencia generada en el ejemplo dado mediante las relaciones conceptuales según la similaridad de polaridad de palabras.



Figura 4.7 Grafo de co-ocurrencia de palabras de la oración original *"transformer moving picture show play visually dramatic"* con palabras conceptuales (WordNet) según el diccionario de polaridades.

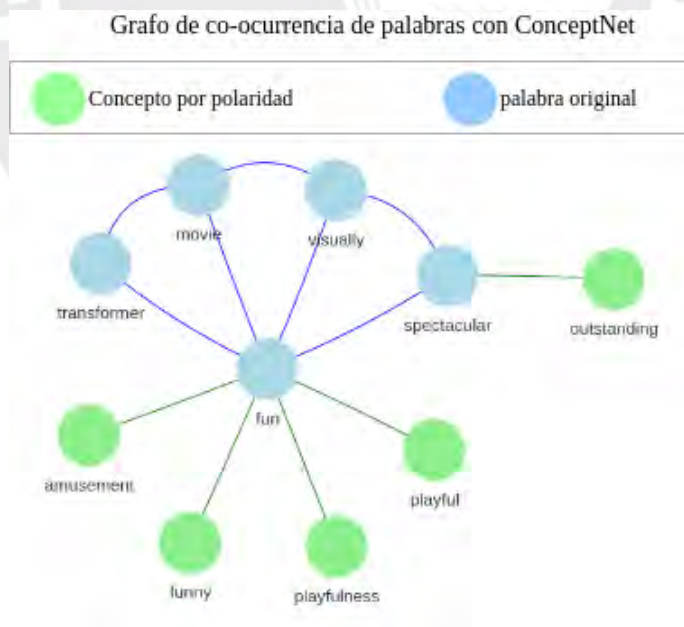


Figura 4.8 Grafo de co-ocurrencia de palabras de la oración original *"transformer moving picture show play visually dramatic"* con palabras conceptuales (ConceptNet) según el diccionario de polaridades.

## 4.7. Generar caminos con sesgo de polaridad (polarity-biased random walk)

El algoritmo de caminata aleatoria sesgado por polaridad (*Polarity-biased Random Walk*) (ver Algoritmo 1) está creado para navegar en un grafo de co-ocurrencias de palabras. En este grafo, los nodos representan palabras o conceptos, y las aristas representan sus relaciones semánticas o de co-ocurrencia. El algoritmo prefiere transiciones entre nodos que tienen la misma polaridad de sentimiento. Utiliza un parámetro de sesgo (*bias*) denotado como  $b$  para aumentar la probabilidad de moverse hacia los nodos vecinos con la misma polaridad (positiva, neutral o negativa). Este enfoque ayuda a mantener la consistencia de la polaridad en los caminos generados, lo cual es beneficioso para desarrollar representaciones de polaridad en tareas de análisis de sentimientos, como la creación de vectorización de palabras.

### 4.7.1. Inicialización de polarity-biased random walk

Sea  $G = (V, E)$  un grafo no dirigido, donde  $V$  es el conjunto de nodos (representan palabras).  $E$  es el conjunto de aristas, que representan relaciones entre nodos (co-ocurrencias o relaciones conceptuales). Cada nodo  $v \in V$  está asociado con un valor de polaridad  $p(v) \in \{-1, 0, 1\}$ , donde:

- $p(v) = 1$  palabras positivas.
- $p(v) = -1$  palabras negativas.
- $p(v) = 0$  palabras neutrales o palabras sin polaridad asignada.

A *polarity-biased random walk* comienza desde el nodo  $v_0$ , se representa como una secuencia:

$$W = \{v_0, v_1, v_2, \dots, v_{L-1}\} \quad (4.13)$$

Donde  $v_0$  es el nodo inicial y  $L$  es la longitud total del camino.

### 4.7.2. Nodos vecinos

Para obtener los nodos vecinos por cada nodo  $v_i$  en el recorrido, el conjunto de vecinos  $N(v_i)$  se define como:

$$N(v_i) = \{v_j \in V \mid (v_i, v_j) \in E\} \quad (4.14)$$

Este conjunto contiene todos los nodos  $v_j$  que están conectados a  $v_i$  por una arista en  $E$ .

### 4.7.3. Probabilidades de transición

La probabilidad de transición desde el nodo  $v_i$  a un nodo vecino  $v_j \in N(v_i)$  se determina por sus respectivos valores de polaridad. La probabilidad se define como:

$$P(v_j | v_i) = \begin{cases} b & \text{if } p(v_i) = p(v_j) \text{ and } p(v_i) \neq 0 \\ 1 - b & \text{if } p(v_i) \neq p(v_j) \text{ or } p(v_i) = 0 \end{cases} \quad (4.15)$$

Donde  $b$  es un parámetro de sesgo que da mayores probabilidades de transición a nodos con la misma polaridad que  $v_i$ . Si las polaridades de  $v_i$  y  $v_j$  son iguales y no neutrales, la probabilidad de transición es alta ( $b$ ). Si las polaridades son diferentes o son neutrales, la probabilidad de transición es menor ( $1 - b$ ).

Después, las probabilidades de transición se normalizan para asegurar que sumen 1. Para cada nodo  $v_i$ , la suma de las probabilidades de transición a sus vecinos  $v_j \in N(v_i)$  es:

$$\sum_{v_j \in N(v_i)} P(v_j | v_i) = 1 \quad (4.16)$$

### 4.7.4. Selección del siguiente nodo

Para la selección del siguiente nodo en el recorrido de caminos,  $v_{i+1}$ , se selecciona del conjunto de vecinos  $N(v_i)$  basado en las probabilidades de transición:

$$v_{i+1} = \arg \max_{v_j \in N(v_i)} P(v_j | v_i) \quad (4.17)$$

Este proceso de selección asegura que los nodos con polaridades similares tengan mayor probabilidad de ser elegidos durante el recorrido de caminos.

### 4.7.5. Generar caminos aleatorios

El camino  $W = \{v_0, v_1, \dots, v_{L-1}\}$  continúa hasta que alcanza la longitud máxima  $L(\text{walk length})$ , o termina antes si el nodo actual no tiene vecinos. Luego, es necesario crear múltiples caminatas para cada nodo  $v \in V$ , se generan múltiples caminatas aleatorias independientes con polaridad sesgada. El número de pasos está definido por  $n(\text{num walks by node})$ , lo que lleva a la generación de un conjunto de pasos representada en  $W$  :

$$\mathcal{W} = \bigcup_{v \in V} \{W_1(v), W_2(v), \dots, W_n(v)\} \quad (4.18)$$

Donde  $W_i(v)$  representa el paso  $i$  empezando desde el nodo  $v$ .

#### 4.7.6. Algoritmo polarity-biased random walk

El algoritmo 1 representa los pasos explicados en la sección 4.7. Este algoritmo realiza caminatas aleatorias sesgadas por polaridad en un grafo. Comienza en un nodo específico y en cada paso selecciona un nodo vecino basado en similitud de polaridad con el nodo actual. Si un vecino tiene la misma polaridad que el nodo actual, se le asigna una alta probabilidad (sesgo  $b$ ); caso contrario, se asigna una probabilidad más baja. El objetivo es generar caminatas aleatorias que prioricen las conexiones entre nodos de la misma polaridad, lo que es útil para capturar las relaciones semánticas del grafo.

### 4.8. Generar word embedding

Para convertir las palabras en valores numéricos vectoriales, primero transformamos cada nodo de los paseos en una cadena de texto. Luego, procesamos estas cadenas usando el modelo de aprendizaje Skip-Gram [6], que utiliza la secuencia de caminos para crear representaciones vectoriales. El modelo Skip-Gram se presenta de la siguiente manera.

El objetivo es predecir las palabras de contexto dado una palabra objetivo central. El modelo busca maximizar la probabilidad de predecir correctamente las palabras cercanas  $w_{t+j}$  dada una palabra central  $w_t$ , dentro de una ventana de contexto de tamaño  $c$ . Esta técnica es particularmente útil para capturar relaciones semánticas y de co-ocurrencia entre palabras en un corpus.

Dada una secuencia de palabras  $w_1, w_2, \dots, w_T$ , el objetivo del modelo Skip-gram es maximizar la probabilidad de predecir las palabras cercanas  $w_{t+j}$  para una palabra central  $w_t$ , dentro de una ventana de contexto de tamaño  $c$ . Esto se expresa como:

$$\prod_{t=1}^T \prod_{-c \leq j \leq c, j \neq 0} P(w_{t+j} | w_t) \quad (4.19)$$

Para optimizar este modelo, maximizamos el log-likelihood de la probabilidad conjunta:

$$\frac{1}{T} \sum_{t=1}^T \sum_{-c \leq j \leq c, j \neq 0} \log P(w_{t+j} | w_t) \quad (4.20)$$

---

**Algorithm 1:** Polarity-biased random walk algorithm

---

**Input:** Graph  $G = (V, E)$ , Walks by node  $n$ , Walk length  $l$ , Bias  $b$

**Output:** List of polarity-biased walks

```
1 LearnFeatures (Graph  $G = (V, E)$ , Walks by node  $n$ , Walk length  $l$ , Bias  $b$ ):
2 Initialize walks as an empty list;
3 for each node  $u \in V$  do
4   for  $iter = 1$  to  $n$  do
5     walk = PolarityBiasedWalk( $G, u, l, b$ );
6     Append walk to walks;
7 return walks;

8 PolarityBiasedWalk (Graph  $G = (V, E)$ , Start node  $u$ , Length  $l$ , Bias  $b$ ):
9 Initialize walk = [ $u$ ];
10 for  $walk\_iter = 1$  to  $l - 1$  do
11   curr_node = walk[-1];
12   neighbors = GetNeighbors(curr_node,  $G$ );
13   if neighbors is empty then
14     break;
15   Initialize probabilities as an empty list;
16   for each neighbor in neighbors do
17     curr_polarity = GetPolarity(curr_node);
18     neighbor_polarity = GetPolarity(neighbor);
19     if curr_polarity = neighbor_polarity and curr_polarity  $\neq 0$  then
20       probability =  $b$ ;
21     else
22       probability =  $1 - b$ ;
23     Append probability to probabilities;
24   Normalize probabilities so they sum to 1;
25
26   Select random next_node from neighbors based on the normalized probabilities:
27
28     
$$\sum_{w_j \in N(\text{curr\_node})} P(\text{neighbor}_i \mid \text{curr\_node}) = 1$$

29
30     
$$\text{next\_node} = \arg \max_{w_j \in N(\text{curr\_node})} P(w_j \mid \text{curr\_node})$$

31
32   Append next_node to walk;
33 return walk;
```

---

La probabilidad condicional  $P(w_{t+j} | w_t)$  se modela utilizando la función softmax, que asigna una probabilidad a cada palabra en el vocabulario en función de las representaciones vectoriales  $v_{w_t}$  de las palabras. Esto se representa como:

$$P(w_{t+j} | w_t) = \frac{\exp(v_{w_{t+j}}^\top v_{w_t})}{\sum_{w_k \in V} \exp(v_{w_k}^\top v_{w_t})} \quad (4.21)$$

Donde:

- $v_{w_t}$  es la representación vectorial de la palabra central  $w_t$ .
- $v_{w_{t+j}}$  es la representación del contexto de la palabra.
- $V$  es el conjunto de todas las palabras en el vocabulario.
- $\exp(\cdot)$  denotado como la función exponencial.

### 4.8.1. Proceso de convertir palabras a embeddings

#### Convertir secuencia de palabras a vector binario

Se tiene una secuencia de palabras  $V = w_1, w_2, w_3 \dots, w_n$ , luego estas palabras son representadas de forma vectorial empleando el método de *one-hot encoding*. Para cada palabra  $w_i$  en el vocabulario, su representación *one-hot* es un vector  $v_{w_i}$  de tamaño  $V$  que cumple la siguiente condición.

$$\mathbf{v}_{w_i} = [0 \ 0 \ \dots \ 1 \ \dots \ 0] \quad (4.22)$$

Donde:

- $\mathbf{v}_{w_i} \in \mathbb{R}^V$ .
- El valor 1 está en la posición correspondiente al índice de la palabra  $w_i$  en el vocabulario.
- Todas las demás posiciones son 0.

La representación *one-hot* de una palabra  $w_i$  usando la función delta de *Kronecker*  $\delta_{ij}$ :

$$\mathbf{v}_{w_i}[j] = \delta_{ij} = \begin{cases} 1, & \text{si } i = j \\ 0, & \text{si } i \neq j \end{cases} \quad (4.23)$$

Donde:

- $i$  es el índice de la palabra  $w_i$  en el vocabulario.

- $j$  es la posición en el vector *one-hot*.
- $\delta_{ij}$  es 1 si  $i = j$  (la posición que corresponde a la palabra  $w_i$ ) y 0 en otro caso.

### Crear la matriz de pesos de entrada

Luego de obtener el vector de palabras con *one-hot encoding*, se crea la matriz de pesos  $W_{in}$ , donde los valores se inicializan aleatoriamente con valores pequeños cercanos a cero. Durante el entrenamiento del modelo, estos valores se ajustan para minimizar el error en las predicciones de las palabras de contexto.

La matriz  $W_{in}$  se define como:

$$W_{in} = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1N} \\ w_{21} & w_{22} & \dots & w_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ w_{V1} & w_{V2} & \dots & w_{VN} \end{bmatrix} \quad (4.24)$$

Donde:

- $w_{ij}$  representa el peso que corresponde a la  $i$ -ésima palabra en el vocabulario y la  $j$ -ésima dimensión en el espacio de embeddings.
- $V$  es el tamaño del vocabulario (número total de palabras únicas en el corpus).
- $N$  es la dimensión de los embeddings (un número que defines, como 100, 200, etc., para obtener vectores densos de tamaño  $N$  que representen las palabras).

### Obtener la matriz de pesos de salida

Además de la matriz de pesos de entrada  $W_{in}$ , el modelo Skip-gram también necesita una segunda matriz de pesos, llamada matriz de pesos de salida  $W_{out}$  donde los valores se inicializan aleatoriamente.

Dado un embedding de la palabra central  $h$ , que obtuvimos al multiplicar el vector *one-hot* de la palabra central con  $W_{in}$ :

$$h = \mathbf{v}_{w_i} \times W_{in} \quad (4.25)$$

El siguiente paso es proyectar este vector de embedding  $h$  en el espacio del vocabulario para calcular las puntuaciones para cada palabra en el vocabulario. Esto se realiza multiplicando  $h$  por la matriz de salida  $W_{out}$ :

$$W_{out} = \begin{bmatrix} w'_{11} & w'_{12} & \dots & w'_{1N} \\ w'_{21} & w'_{22} & \dots & w'_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ w'_{V1} & w'_{V2} & \dots & w'_{VN} \end{bmatrix} \quad (4.26)$$

$$u = h \times W_{out} \quad (4.27)$$

donde  $u$  es un vector de tamaño  $V$ , y cada elemento de  $u$  representa la puntuación para cada palabra en el vocabulario, dado el contexto de la palabra central.

### Determinar probabilidad mediante la función softmax

La multiplicación  $u = h \times W_{out}$  produce un vector  $u$  de tamaño  $V$ , donde cada elemento  $u_k$  es la puntuación para la palabra  $w_k$  en el vocabulario, dado el contexto de la palabra central. Para convertir estas puntuaciones en probabilidades, se utiliza la función softmax:

$$P(w_{t+j}|w_t) = \frac{\exp(u_{w_{t+j}})}{\sum_{k=1}^V \exp(u_{w_k})} \quad (4.28)$$

Donde:

- $P(w_{t+j}|w_t)$  es la probabilidad de que  $w_{t+j}$  sea una palabra de contexto dada la palabra central  $w_t$ .
- $u_{w_{t+j}}$  es la puntuación obtenida para la palabra  $w_{t+j}$ .
- $\sum_{k=1}^V \exp(u_{w_k})$  es la suma de las exponenciales de todas las puntuaciones, lo que garantiza que todas las probabilidades sumen 1.

La función softmax convierte el vector de puntuaciones  $u$  en un vector de probabilidades  $P$  de tamaño  $V$ , donde cada elemento representa la probabilidad de que una palabra específica en el vocabulario sea una palabra de contexto de la palabra central.

### Función de pérdida

Después de obtener las probabilidades, el siguiente paso es calcular la función de pérdida para entrenar el modelo. Esta función mide el error en las predicciones del modelo. En Skip-gram, se utiliza la entropía cruzada (*cross-entropy loss*) entre la probabilidad predicha y la probabilidad real de las palabras de contexto.

Para un par (palabra central  $w_t$ , palabra de contexto  $w_{t+j}$ ), la pérdida es:

$$L = -\log P(w_{t+j}|w_t) \quad (4.29)$$

La idea es maximizar la probabilidad de predecir correctamente las palabras de contexto para cada palabra central. Para todo el corpus, la pérdida total (*log-likelihood*) se calcula como la suma de todas las pérdidas para las palabras de contexto en cada ventana alrededor de cada palabra central:

$$\text{Loss} = -\sum_{t=1}^T \sum_{-c \leq j \leq c, j \neq 0} \log P(w_{t+j}|w_t) \quad (4.30)$$

Donde:

- $T$  es el número total de palabras en el corpus.
- $c$  es el tamaño de la ventana de contexto.

### Optimización de pesos con Backpropagation

El modelo utiliza *backpropagation* y descenso de gradiente para minimizar la pérdida y ajustar los valores en  $W_{in}$  y  $W_{out}$ . Este proceso de retropropagación del error y ajuste de los pesos se repite en cada paso de entrenamiento para cada palabra central y sus palabras de contexto en el corpus.

1. Cálculo de Gradientes: Se calcula el gradiente de la función de pérdida con respecto a cada peso en  $W_{in}$  y  $W_{out}$ .
  - Esto incluye los gradientes de los embeddings de la palabra central (matriz  $W_{in}$ ) y los gradientes de los pesos de salida (matriz  $W_{out}$ ).
2. Actualización de Pesos: Usando una tasa de aprendizaje  $\eta$ , los pesos en  $W_{in}$  y  $W_{out}$  se ajustan en la dirección que reduce la pérdida. Esto se hace de la siguiente manera:

$$W_{in} = W_{in} - \eta \frac{\partial \text{Loss}}{\partial W_{in}} \quad (4.31)$$

$$W_{out} = W_{out} - \eta \frac{\partial \text{Loss}}{\partial W_{out}} \quad (4.32)$$

## Obtener embeddings de palabras

Después de múltiples iteraciones sobre el corpus (épocas de entrenamiento), los valores en  $W_{in}$  y  $W_{out}$  se ajustan para minimizar la función de pérdida. Una vez que el entrenamiento termina y los pesos han convergido (es decir, la función de pérdida ya no disminuye significativamente), los embeddings finales de las palabras se encuentran en las filas de la matriz  $W_{in}$ . En el modelo Skip-gram:

- Los word embeddings finales se obtienen de las filas de la matriz  $W_{in}$ . Cada fila de  $W_{in}$  es el embedding de una palabra en el vocabulario.
- $W_{out}$  se utiliza solo para calcular las puntuaciones durante la predicción y no se considera para los embeddings finales.
- Cada fila de  $W_{in}$  corresponde a una palabra del vocabulario. Por ejemplo, si la palabra *transformer* es la tercera palabra en el vocabulario, su embedding estará en la tercera fila de  $W_{in}$ .

## 4.9. Algoritmos de machine learning supervisados

En esta fase, aplicamos varios algoritmos de machine learning para clasificar el sentimiento utilizando embeddings de palabras generados en secciones anteriores. Los algoritmos que se experimentó fueron: SVM, RF, LR, XGBoost y KNN. Utilizamos embeddings de palabras como los vectores de características de entrada para entrenar clasificadores que puedan predecir la polaridad del sentimiento (positivo, negativo o neutral). Estos modelos se entrenan para maximizar la precisión y la generalización en la clasificación de sentimientos.

## 4.10. Métricas para clasificación de sentimientos

La fase de clasificación de sentimientos consiste en evaluar el rendimiento de los modelos de machine learning. Para ello, se emplean dos métricas clave de evaluación, que son: *accuracy* y *F1-score* [280]-[282]. *Accuracy* mide la proporción de predicciones correctas (positivas y negativas) sobre el número total de instancias evaluadas. Se define como:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.33)$$

Donde:

- *TP* (*True Positives*) son las instancias positivas correctamente predichas.

- *TN* (*True Negatives*) son las instancias negativas correctamente predichas.
- *FP* (*False Positives*) son las instancias incorrectamente predichas como positivas.
- *FN* (*False Negatives*) son las instancias incorrectamente predichas como negativas.

*F1-score* es la media armónica de la *precision* y el *recall*, y es especialmente útil cuando hay un desequilibrio entre clases. Se define como:

$$\text{F1-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4.34)$$

Donde la *precision* y *recall* se representan de la siguiente manera:

$$\text{Precision} = \frac{TP}{TP + FP} \quad \text{Recall} = \frac{TP}{TP + FN} \quad (4.35)$$



# Capítulo 5

## Resultados y discusiones

### 5.1. Consideraciones para experimentación

En esta sección, realizamos experimentos utilizando un conjunto de datos relacionado a análisis de sentimientos específicamente para la tarea de clasificación de polaridad. Esto va a permitir verificar el rendimiento de la metodología propuesta.

#### 5.1.1. Dataset experimentales

El dataset elegido para construir *embeddings* de palabras, generar modelos de pre-entrenamiento y realizar comparaciones es IMDB *movie dataset* con polaridad negativa y positiva (ver Tabla 5.1). Se comparan modelos de grafos con Node2Vec, GraphSAGE, GAT y GCN. Así mismo, la propuesta se compara con modelos de embedding pre-entrenados de dominio general como: Word2vec, GloVe, FastText y BERT, los cuales son utilizados frecuentemente para análisis de sentimientos. Por otro lado, realizamos nuestros propios *embeddings* utilizando los algoritmos de Word2vec, GloVe, FastText y BERT, el resultado de estos *embeddings* se compara con la propuesta utilizando el *dataset* de dominio específico SST2. También se realiza la comparación con *dataset* de dominio general como McDonalds (opiniones de comida rápida) (ver Tabla 5.1) ambas con polaridades positivas y negativas. Por otro lado, para crear un diccionario de polaridad de palabras conceptuales utilizamos VADER, que permite generar el diccionario de WordNet y ConceptNet de relación conceptual de palabras.

La Tabla 5.2 representa el número de nodos (*node*) y aristas (*edge*) para la construcción del grafo utilizando relaciones conceptuales mediante WordNet y ConceptNet. Posteriormente, estos grafos son utilizados para el recorrido de caminos y construcción de *embeddings* propios con la metodología propuesta.

Tabla 5.1 Número de oraciones por dataset

Dataset	Oraciones positivas	Oraciones negativas	Total de oraciones
IMDB movie	1005	995	2000
SST2 movie	4522	4219	8741
McDonal's	2693	2307	5000

Tabla 5.2 Número de nodos (*Node*) y aristas (*Edge*) para IMDB *movie*

Dataset	Nro. oraciones	Concepto	Nodes	Edges
IMDB movie	2000	-	25007	332493
IMDB movie	2000	WordNet	25265	348563
IMDB movie	2000	ConceptNet	25007	369296

### 5.1.2. Métricas de evaluación

Los modelos propuestos para generar *embedding* de palabras fueron evaluados usando varias métricas para validar su efectividad. Los coeficientes de correlación de Spearman y Pearson, junto con sus respectivos resultados *p-value*, se usaron para evaluar que tan bien los *embeddings* capturan la similitud de palabras anotadas por humanos usando los conjuntos de datos WordSim-353 y SimLex-999. Además, se usaron métricas de similitud de palabras basadas en polaridad (Similitud Positivo-Positivo, Negativo-Negativo y Positivo-Negativo) para explicar variaciones de sentimiento. También, se aplica t-SNE (*t-Distributed Stochastic Neighbor Embedding*) para visualizar la proyección de los vectores de palabras en dos dimensiones y de esa manera facilitar la identificación de relaciones de similitud de palabras con base a su polaridad (positiva y negativa). Finalmente, se evalúan métricas como el *accuracy* y *F1-score* para medir el rendimiento general del modelo en la clasificación de la polaridad de sentimientos [280]-[282].

## 5.2. Resultados de evaluación de embeddings en cuanto a su contenido predictivo

### 5.2.1. Resultados utilizando WordNet y ConceptNet mediante número de caminos.

Para evaluar la metodología propuesta consideramos los hiperparámetros de *Walk Length* ( $wl$ ), *Number of walk by node* ( $nw$ ) y *bias* ( $b$ ). Esto permitió realizar recorrido de caminos de manera aleatoria con un sesgo  $b$  para encontrar mejores representación de palabras correlacionadas. Luego, estos embeddings generados se utilizaron en la clasificación de polaridad de sentimientos mediante algoritmos de SVM, RF, LR, XGB y KNN. Mediante la métrica de *accuracy* y *f1-score* se pudo identificar que hiperparámetros de la propuesta generan mejor rendimiento de clasificación de polaridad.

#### Resultados usando WordNet con bias de 0.95

Los resultados presentados en las Tablas 5.3 y 5.4 muestran el desempeño en términos de *accuracy* y *F1-score* de diferentes modelos de clasificación con un sesgo ( $b = 0,95$ ) en las caminatas aleatorias. Se evaluaron 4 experimentos con distintas profundidades de caminata ( $wl$ ) y número de caminatas por nodo ( $nw$ ) para analizar su impacto en la clasificación de sentimientos.

En ambas tablas, se observa que el rendimiento mejora a medida que se incrementa  $wl$  y  $nw$ , siendo los resultados más consistentes en los modelos SVM y LR, que alcanzan valores máximos de *accuracy* y *F1-score* de 0.85. En cambio, los modelos RF y KNN muestran un desempeño más bajo, especialmente en hiperparámetros con valores de  $nw$  menores. XGB se encuentra en un punto intermedio, destacándose en parámetros de  $wl = 30$  con una mejora tanto en *accuracy* como en *F1-score*, lo que indica que una profundidad de caminata suficientemente grande captura mejor las relaciones semánticas entre las palabras. Los resultados reflejan que los hiperparámetros para caminos más profundos y mayores números de caminos por nodo tienden a mejorar la representación de los *embeddings*, lo cual es clave para que los clasificadores logren identificar de manera más precisa los patrones de polaridad en el análisis de sentimientos.

#### Resultados usando WordNet con bias de 0.15

Los resultados presentados en las Tablas 5.5 y 5.6 muestran el desempeño en términos de *accuracy* y *F1-score* de diferentes modelos de clasificación con un sesgo bajo ( $b = 0,15$ ) en

Tabla 5.3 Resultados de Accuracy para la propuesta WordNet con 0.95 bias.

Modelo	Parámetros	SVM	RF	LR	XGB	KNN
Propuesta (wordnet)	wl=10, nw=50, b=0.95	0.84	0.79	0.84	0.78	0.73
Propuesta (wordnet)	wl=20, nw=100, b=0.95	0.84	0.76	0.84	0.78	0.74
Propuesta (wordnet)	wl=30, nw=200, b=0.95	0.84	0.78	0.84	0.80	0.68
Propuesta (wordnet)	wl=40, nw=300, b=0.95	0.85	0.79	0.85	0.81	0.71

Tabla 5.4 Resultados de F1-score para la propuesta WordNet con 0.95 bias.

Modelo	Parámetros	SVM	RF	LR	XGB	KNN
Propuesta (wordnet)	wl=10, nw=50, b=0.95	0.84	0.78	0.84	0.79	0.71
Propuesta (wordnet)	wl=20, nw=100, b=0.95	0.84	0.76	0.84	0.78	0.72
Propuesta (wordnet)	wl=30, nw=200, b=0.95	0.83	0.77	0.83	0.80	0.68
Propuesta (wordnet)	wl=40, nw=300, b=0.95	0.85	0.79	0.86	0.81	0.70

las caminatas aleatorias. Se analizan 4 experimentos diferentes de profundidad de caminata ( $wl$ ) y número de caminatas por nodo ( $nw$ ) para evaluar el efecto sobre el rendimiento en la clasificación de sentimientos.

En comparación con el sesgo más alto ( $b = 0,95$  ver Tablas 5.3 y 5.4), los resultados aquí indican una ligera reducción en el rendimiento de clasificación, especialmente en los modelos de RF y KNN, lo que sugiere que estos modelos dependen más de un sesgo que refuerce las relaciones entre palabras con polaridad similar. Sin embargo, los modelos SVM y LR tiene un rendimiento con una *accuracy* entre 0.81 y 0.84, lo que indica que estos modelos tienen una mejor robustez frente a la variación del sesgo ( $b$ ). Los resultados reflejan que el sesgo reducido ( $b = 0,15$ ) disminuye la influencia de la polaridad en las caminatas aleatorias, lo que puede explicar la menor precisión observada en los modelos RF y KNN. Por otro lado, los modelos SVM y LR parecen aprovechar mejor las relaciones semánticas generales capturadas por las caminatas, aun cuando el sesgo de polaridad es reducido. Este comportamiento resalta la importancia de ajustar el sesgo en función del clasificador utilizado para optimizar el análisis de sentimientos.

### Resultados usando ConceptNet con bias de 0.95

Los resultados mostrados en las Tablas 5.7 y 5.8 reflejan el desempeño de diferentes modelos de clasificación generados con ConceptNet, bajo un sesgo alto ( $b = 0,95$ ) en las caminatas aleatorias. Se evaluaron 4 modelos de profundidad de caminata ( $wl$ ) y número de

Tabla 5.5 Resultados de Accuracy para la propuesta usando WordNet con 0.15 bias.

Modelo	Parámetros	SVM	RF	LR	XGB	KNN
Propuesta (wordnet)	wl=10, nw=50, b=0.15	0.82	0.74	0.82	0.76	0.70
Propuesta (wordnet)	wl=20, nw=100, b=0.15	0.81	0.73	0.82	0.76	0.69
Propuesta (wordnet)	wl=30, nw=200, b=0.15	0.83	0.76	0.84	0.77	0.68
Propuesta (wordnet)	wl=40, nw=300, b=0.15	0.83	0.75	0.83	0.77	0.71

Tabla 5.6 Resultados de F1-score para la propuesta usando WordNet con 0.15 bias.

Modelo	Parámetros	SVM	RF	LR	XGB	KNN
Propuesta (wordnet)	wl=10, nw=50, b=0.15	0.83	0.75	0.82	0.76	0.66
Propuesta (wordnet)	wl=20, nw=100, b=0.15	0.81	0.74	0.82	0.79	0.66
Propuesta (wordnet)	wl=30, nw=200, b=0.15	0.83	0.76	0.83	0.78	0.66
Propuesta (wordnet)	wl=40, nw=300, b=0.15	0.84	0.75	0.83	0.78	0.68

camino por nodo ( $nw$ ) para evaluar el rendimiento de clasificación de sentimientos.

En la métrica de *accuracy*, los modelos SVM y LR mantienen un rendimiento consistente a lo largo de las diferentes parámetros, con valores que oscilan entre 0.83 y 0.84. Los modelos basados en XGB también muestran buenos resultados, especialmente con  $wl = 30$  y  $nw = 200$ , alcanzando un valor de 0.81 en *accuracy*. Sin embargo, KNN y RF presentan un rendimiento más bajo, lo que indica que estos modelos no logran aprovechar de manera efectiva las relaciones semánticas complejas capturadas por las caminatas en ConceptNet. En términos de *F1-score*, se observa un comportamiento similar al de la *accuracy*, destacándose los modelos SVM y LR con valores cercanos a 0.85 en la mayoría de los casos. Los modelos XGB muestran ligeras mejoras en  $wl = 30$ . KNN muestra los resultados más bajos, por debajo de 0.66 en la mayoría de hiperparámetros probados. Esto sugiere que, si bien el sesgo alto favorece la preservación de relaciones semánticas de polaridad entre las palabras, algunos modelos como KNN no logran beneficiarse de esta estructura. En ese sentido, estos resultados indican que un sesgo alto ( $b = 0,95$ ) en las caminatas aleatorias en ConceptNet mejora el rendimiento de modelos como SVM, LR y XGBoost, mientras que modelos como KNN y RF no muestran mejoras significativas.

### Resultados usando ConceptNet con bias de 0.15

Los resultados mostrados en las Tablas 5.9 y 5.10 muestran el rendimiento de clasificación con diferentes modelos generados a partir de ConceptNet, con un sesgo bajo ( $b = 0,15$ ) en

Tabla 5.7 Resultados de Accuracy para la propuesta usando ConceptNet con bias de 0.95.

Modelo	Parámetros	SVM	RF	LR	XGB	KNN
Propuesta (conceptnet)	wl=10, nw=50, b=0.95	0.84	0.76	0.83	0.80	0.65
Propuesta (conceptnet)	wl=20, nw=100, b=0.95	0.84	0.78	0.81	0.79	0.69
Propuesta (conceptnet)	wl=30, nw=200, b=0.95	0.84	0.76	0.83	0.81	0.73
Propuesta (conceptnet)	wl=40, nw=300, b=0.95	0.83	0.78	0.82	0.80	0.71

Tabla 5.8 Resultados de F1-score para la propuesta usando ConceptNet con bias de 0.95.

Modelo	Parámetros	SVM	RF	LR	XGB	KNN
Propuesta (conceptnet)	wl=10, nw=50, b=0.95	0.85	0.76	0.83	0.80	0.62
Propuesta (conceptnet)	wl=20, nw=100, b=0.95	0.85	0.76	0.83	0.79	0.65
Propuesta (conceptnet)	wl=30, nw=200, b=0.95	0.84	0.76	0.83	0.82	0.68
Propuesta (conceptnet)	wl=40, nw=300, b=0.95	0.84	0.78	0.83	0.80	0.66

las caminatas aleatorias. Las configuraciones de profundidad de caminata ( $wl$ ) y número de caminatas por nodo ( $nw$ ) fueron variadas para analizar su impacto en la *accuracy* y *F1-score*.

En ese sentido, los resultados muestran que, con un sesgo bajo el rendimiento es ligeramente inferior al obtenido con un sesgo más alto. Los modelos SVM y LR continúan mostrando un desempeño estable, con una *accuracy* que oscila entre 0.81 y 0.82, y un *F1-score* que también tiene valores similares. RF también mantiene un buen rendimiento, destacándose los parámetros con  $wl = 30$  y  $nw = 200$ , con una *accuracy* de 0.78 y un *F1-score* similar. Por otro lado, los modelos KNN y XGBoost presentan variaciones menores, mostrando un rendimiento aceptable pero no tan robusto en comparación de SVM y LR. El valor del sesgo reducido ( $b = 0,15$ ) en las caminatas aleatorias parece ser menos efectivo para capturar relaciones de polaridad, lo que se refleja en una disminución en el rendimiento de todos los modelos. Sin embargo, SVM y LR con  $wl = 40$ ,  $nw = 300$  y  $b = 0,95$  continúan mostrando un rendimiento estable.

### Resultados usando ConceptNet y WordNet con F1-score.

La Figura 5.1 muestra el impacto de la profundidad de la caminata y el número de caminatas por nodo al usar WordNet con dos sesgos diferentes: 0.95 y 0.15. La Figura 5.1, que tiene un alto sesgo hacia la misma polaridad (0.95), se observa un rendimiento superior. Las mejores *F1-score* se logran con SVM (0.85) y LR (0.86) al usar  $wl = 40$  y  $nw = 300$ . Por otro lado, la Figura 5.1, con un bajo sesgo (0.15), muestra un rendimiento ligeramente

Tabla 5.9 Resultados de Accuracy para la propuesta usando ConceptNet con bias de 0.15.

Modelo	Parámetros	SVM	RF	LR	XGB	KNN
Propuesta (conceptnet)	wl=10, nw=50, b=0.15	0.80	0.77	0.81	0.76	0.65
Propuesta (conceptnet)	wl=20, nw=100, b=0.15	0.82	0.75	0.81	0.78	0.70
Propuesta (conceptnet)	wl=30, nw=200, b=0.15	0.81	0.78	0.82	0.77	0.68
Propuesta (conceptnet)	wl=40, nw=300, b=0.15	0.82	0.74	0.82	0.78	0.68

Tabla 5.10 Resultados de F1-score para la propuesta usando ConceptNet con bias de 0.15.

Modelo	Parámetros	SVM	RF	LR	XGB	KNN
Propuesta (conceptnet)	wl=10, nw=50, b=0.15	0.81	0.77	0.81	0.76	0.61
Propuesta (conceptnet)	wl=20, nw=100, b=0.15	0.82	0.75	0.81	0.78	0.67
Propuesta (conceptnet)	wl=30, nw=200, b=0.15	0.81	0.78	0.82	0.78	0.65
Propuesta (conceptnet)	wl=40, nw=300, b=0.15	0.82	0.74	0.82	0.79	0.65

inferior, con SVM y LR alcanzando aproximadamente 0.84 y 0.83, respectivamente, bajo las mismas condiciones de los parámetros. En general, los mejores resultados se obtienen en WordNet con bias 0.95 en los algoritmos SVM y LR usando la mayor profundidad de caminata y el mayor número de caminatas por nodo.

La Figura 5.2 muestra los resultados del *F1-score* según la profundidad de caminata y el número de caminatas por nodo usando ConceptNet con dos sesgos diferentes como 0.95 y 0.15. En la Figura con un sesgo alto de 0.95, el mejor *F1-score* se logra con SVM (0.84) y LR (0.83) al usar  $wl = 40$  y  $nw = 300$ . Por otro lado, en la Figura 5.2 con un sesgo bajo de 0.15, los resultados son ligeramente más bajos, con SVM alcanzando un *F1-score* de 0.81 y LR 0.82 bajo las mismas condiciones. Similar al evaluar el *bias* alto, los resultados mejoran a medida que aumenta el número de caminos y profundidad de caminatas. El mejor rendimiento en general se obtiene en 5.2 con los algoritmos SVM y LR usando la mayor profundidad de caminata y el mayor número de caminatas por nodo.

### 5.2.2. Resultados en el dataset IMDB utilizando embeddings basados en grafos

En la Figura 5.3 y 5.4 se muestran resultados del rendimiento predictivo en diferentes algoritmos de clasificación al aplicar diferentes métodos de embeddings basados en grafos para la clasificación de sentimientos en el *dataset* IMDB *movie*. Se evaluaron 6 métodos: No-




Figura 5.1 Resultados de F1-score usando WordNet bajo un bias de 0.95 y 0.15.




Figura 5.2 Resultados de  $F1$ -score usando ConceptNet bajo un bias de 0.95 y 0.15.

de2Vec, GraphSAGE, GAT, GCN, y el método propuesto en el presente trabajo con WordNet y ConceptNet. Para las propuestas, se utilizaron los parámetros óptimos identificados previamente: profundidad de camino ( $wl = 40$ ), número de caminos por nodo ( $nw = 300$ ) y un sesgo ( $b = 0,95$ ), los cuales demostraron ser más efectivos en las evaluaciones previas.

Durante la evaluación de *accuracy*, los mejores resultados son alcanzados por la propuesta basada en ConceptNet, obteniendo valores cercanos a 0.85 en SVM, RF, y LR, lo que sugiere que los *embeddings* generados a partir de ConceptNet capturan de manera efectiva las relaciones semánticas y de polaridad en el texto. La propuesta basada en WordNet tiene valores cercanos a ConceptNet, también logrando buenos resultados de *accuracy* en todos los algoritmos. En comparación, los modelos que utilizan Node2Vec, GraphSAGE, y GAT muestran un rendimiento inferior, con *accuracy* que varía entre 0.60 y 0.73, lo que indica que estos métodos no logran capturar la información contextual de manera tan eficiente como nuestra propuesta usando bases conceptuales como WordNet y ConceptNet.

Por otro lado, para *F1-score* se observa un patrón similar, con la propuesta usando ConceptNet alcanzando los valores más altos en casi todos los modelos, especialmente en SVM y RF, con valores de 0.85 y 0.79, respectivamente. La propuesta de WordNet también presenta un buen rendimiento, superando a métodos tradicionales como Node2Vec, GraphSAGE, y GAT en todos los casos. Esto resalta que el uso de relaciones semánticas adicionales proporcionadas por ConceptNet y WordNet es clave para mejorar la clasificación de sentimientos, ya que refuerza las conexiones entre nodos de polaridad similar, lo cual es crucial en el contexto del análisis de sentimientos.

En ese sentido los resultados confirman que las propuestas basadas en WordNet y ConceptNet, con caminatas aleatorias con  $b = 0,95$  logran captar de manera más precisa la relación semántica y polaridad

### 5.2.3. Resultados de modelos pre-entrenados de codificación de palabras en el dataset IMDB.

Las Figuras 5.5 y 5.6 comparan el rendimiento de diferentes modelos pre-entrenados de codificación de palabras en el análisis de sentimientos utilizando el *dataset* de IMDB *movie*, evaluando *accuracy* y *F1-score*. Los modelos considerados son Word2Vec, GloVe, FastText y BERT (con dimension de embedding de 300 para los primeros tres y 768 para BERT), así como las propuestas basadas en WordNet y ConceptNet con dimensión 300, generadas con parámetros óptimos de  $wl = 40$ ,  $nw = 300$  y  $b = 0,95$  identificados previamente.

Evaluando el *accuracy*, se observa que la propuesta basada en WordNet logra los mejores resultados en casi todo los algoritmos, alcanzando un valor máximo de 0.85 con SVM y LR,

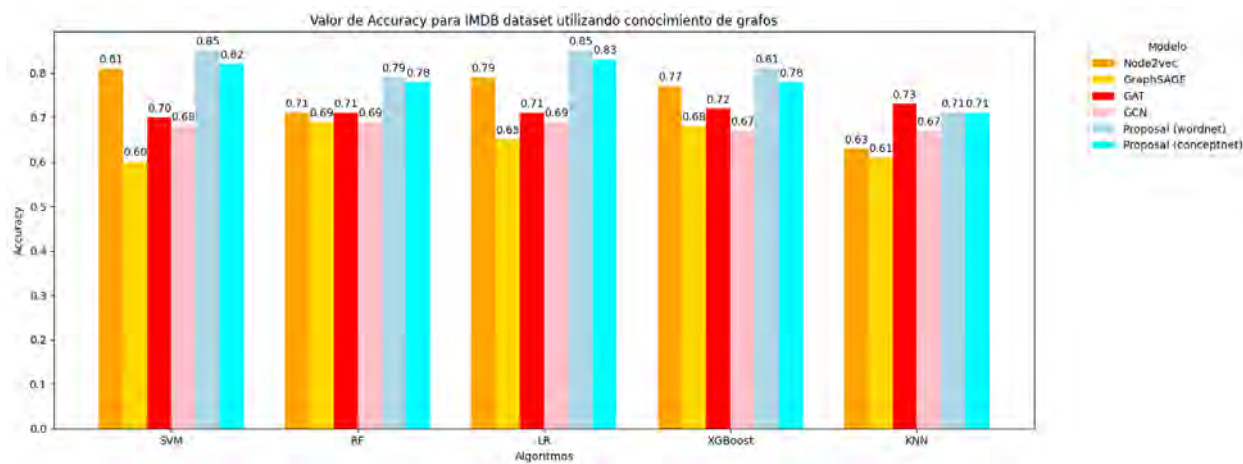


Figura 5.3 Resultados de *Accuracy* en el dataset IMDB para diferentes métodos de codificación de palabras basados en grafos.

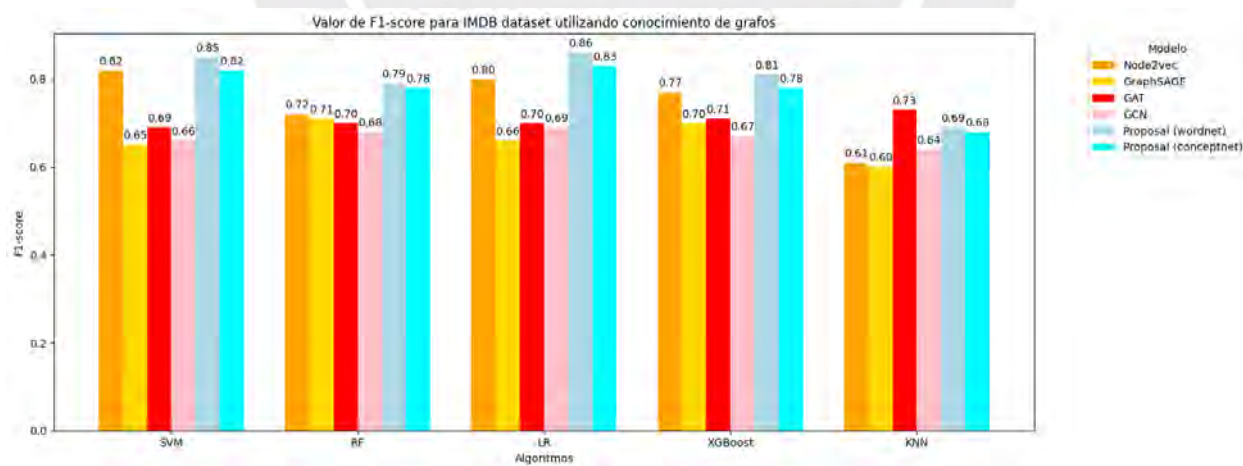


Figura 5.4 Resultados de *F1-score* en el dataset IMDB para diferentes métodos de codificación de palabras basados en grafos.

destacando también en RF con 0.79. Así mismo, en la evaluación de  $F1$ -score muestra un comportamiento similar a *accuracy*. La propuesta basada en WordNet también alcanza el mejor rendimiento, con un valor de 0.85 en SVM y 0.86 en LR, superando a los demás enfoques. La propuesta basada en ConceptNet tiene resultados similares lo cual indica también ser un buen modelo. BERT, aunque presenta una dimensión de mayor capacidad (768), obtiene resultados poco inferiores, especialmente en algoritmos como KNN, donde se observa una *accuracy* de 0.66. Los modelos basados en *embeddings* pre-entrenados como Word2Vec, GloVe y FastText muestran un buen rendimiento, aunque poco inferior a nuestra propuesta usando bases conceptuales como WordNet y ConceptNet.

Estos resultados confirman que las propuestas basadas en WordNet y ConceptNet en dimensión 300, con caminatas aleatorias configuradas con  $b = 0,95$ ,  $wl = 40$ , y  $nw = 300$ , logran un rendimiento superior tanto en *accuracy* como en  $F1$ -score, comparado con modelos pre-entrenados de dominio general como Word2Vec, GloVe, FastText y BERT, debido a su capacidad para capturar relaciones semánticas y de polaridad más precisas en el análisis de sentimientos.




Figura 5.5 Resultados de *Accuracy* para IMDB utilizando modelos pre-entrenados.

#### 5.2.4. Validación cruzada K-Fold

Para evaluar la capacidad de generalización de los modelos, aplicamos una validación cruzada de 5-Fold y utilizando los parámetros óptimos como  $b = 0,95$ ,  $wl = 40$ ,  $nw = 300$  identificados previamente. Los resultados obtenidos se muestran en la tabla 5.11, donde LR y SVM lograron el mejor rendimiento mediante la utilización de relaciones conceptuales de ConceptNet y WordNet. Con WordNet proporcionando una estabilidad ligeramente superior. Estos resultados confirman que ambas fuentes de conocimiento contribuyen a la solidez de

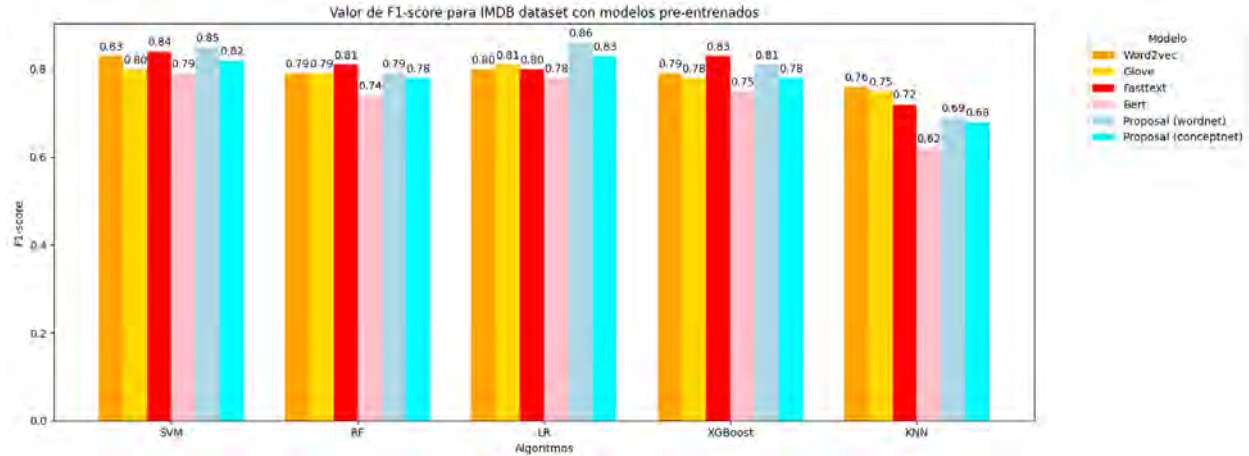


Figura 5.6 Resultados de  $F1$ -score para IMDB utilizando modelos pre-entrenados.

los modelos.

Tabla 5.11 Rendimiento de la validación cruzada con ConceptNet y WordNet

Modelo	Validación cruzada (ConceptNet)	Validación cruzada (WordNet)
SVM	0.83	0.84
LR	0.83	0.85
XGB	0.75	0.76
RF	0.76	0.77
KNN	0.69	0.68

### 5.2.5. Tiempo de ejecución

La experimentación se llevó a cabo en una computadora de AMD Ryzen Threadripper PRO 5955WX (16 núcleos/32 hilos), 252 GB de RAM y 32 CPU lógicas. En la tabla 5.12 se muestra el tiempo de ejecución para la creación de *embeddings*. Utilizando Word2Vec, Glove y FastText que se ejecutan en segundos, mientras que BERT requiere 5 minutos debido al coste de inferencia del *Transformer*. Los enfoques basados en grafos son significativamente más lentos, especialmente con WordNet, lo que refleja la mayor densidad y complejidad de la exploración de grafos léxicos. Debido a que, en primer lugar, la construcción del grafo léxico-conceptual incorpora muchas más aristas con palabras conceptuales. En segundo lugar, las caminatas sesgadas por polaridad requieren recorrer muchos más pasos y ponderar más vecinos en cada salto. Por último, Skip-Gram se entrena sobre un corpus sintético de secuencias (y oraciones aumentadas con conceptos) que suele ser mayor que el texto original.

Tabla 5.12 Tiempo de ejecución con  $b = 0,95$ ,  $wl = 40$ ,  $nw = 300$

Modelo	Tiempo
Word2Vec	2 segundos
Glove	12 segundos
FastText	4 segundos
Bert	5 minutos
Proposal (wordnet)	121.3 minutos
Proposal (conceptnet)	79.54 minutos

### 5.3. Correlación de Spearman y Pearson

Las Tablas 5.13 y 5.14 muestran los resultados de correlación de diferentes modelos de *embedding* en los conjuntos de datos WordSim-353 y SimLex-999 que fueron etiquetados por humanos. Los modelos como Word2vec, GloVe y FastText demuestran bajas correlaciones tanto en Spearman como en Pearson, lo que indica que no capturan correctamente las similitudes semánticas relacionados al sentimiento etiquetado. Además, los altos valores de p-value sugieren una baja significancia de similitud. Por otro lado, BERT tiene un mejor rendimiento en ambos conjuntos de datos, especialmente en WordSim-353, con correlaciones de Spearman y Pearson de 0.33, mostrando una buena capacidad para capturar relaciones semánticas. Sin embargo, su rendimiento disminuye en SimLex-999. Los modelos de codificación propuestos usando WordNet y ConceptNet, particularmente el modelo ConceptNet, muestran un rendimiento aceptable, logrando las correlaciones más altas en ambos conjuntos de datos. El modelo ConceptNet muestra una correlación de Spearman de 0.43 en WordSim-353 y 0.41 en SimLex-999, junto con valores de p-value muy bajos, indicando una fuerte relación entre los embeddings generados y las similitudes humanas. Estos resultados destacan la efectividad de los modelos basados en grafos conceptuales en la captura de relaciones y similitudes semánticas, lo cual es beneficioso para tareas de análisis de sentimientos.

Para garantizar la comparabilidad entre los modelos, se emplearon las mismas dimensiones para el entrenamiento desde cero, como se muestra en las tablas 5.13, 5.14 y 5.15. Los modelos a los que se hace referencia en (1) utilizaron estos algoritmos para generar nuestras incrustaciones con el conjunto de datos IMDB en una dimensión de 300. Las propuestas a las que se hace referencia en (2) para incrustaciones basadas en WordNet y ConceptNet también se generaron con una dimensión de 300, utilizando los parámetros óptimos de  $wl = 40$ ,  $nw = 300$  y  $b = 0,95$ , tal y como se identificó anteriormente.

Tabla 5.13 Resultados de correlación de diferentes modelos de codificación de palabras en el dataset etiquetado WordSim-353.

Modelo	Spearman correlación	Spearman p-value	Pearson correlación	Pearson p-value
Word2vec <sup>1</sup>	0.03	0.03	0.03	0.91
GloVe <sup>1</sup>	0.07	0.37	0.12	0.12
FastText <sup>1</sup>	-0.01	0.83	0.02	0.79
Bert <sup>1</sup>	0.33	3.57E-08	0.33	3.82E-08
Propuesta (wordnet) <sup>2</sup>	0.30	6.55E-07	0.43	2.85E-13
Propuesta (conceptnet) <sup>2</sup>	0.43	7.54E-16	0.51	7.85E-22

<sup>1</sup> Se utilizaron los algoritmos de estos modelos para generar nuestro propio *embeddings* con IMDB *dataset* con dimensión 300.

Propuestas de *embeddings* basadas en WordNet y ConceptNet con dimensión 300, generadas con parámetros óptimos de  $wl = 40$ ,  $nw = 300$  y  $b = 0,95$  identificados previamente.

## 5.4. Similitud de palabras por polaridad

Esta evaluación permite ver si las palabras con la misma polaridad (positivo/negativo) están más cercanas entre sí en el espacio de los *embeddings* que aquellas con polaridades opuestas. Por ejemplo, usando la similitud de coseno, verifica si palabras como *good* y *excellent* están más cerca entre sí que de palabras como *awful* y *horrible*. El objetivo es verificar si las palabras con polaridades similares (positivos/negativos) están más cercanas entre sí en el espacio de los *embeddings* que las palabras con polaridades opuestas. Para la evaluación se consideró el siguiente grupo de palabras.

- **Palabras positivas:** *happy, joy, love, good, excellent, well, beautiful, honestly, amazing, fantastic, wonderful, delightful, glad, great, awesome, positive, perfect, smile, exciting, friendly.*
- **Palabras negativas:** *sad, anger, hate, bad, terrible, stupid, serious, afraid, horrible, awful, disappointing, disgusting, frustrated, nasty, pain, worst, miserable, annoyed, bored, foolish.*

La Tabla 5.15 evalúa la similitud de palabras basada en polaridad (Positivo-Positivo, Negativo-Negativo y Positivo-Negativo) para varios modelos de *embeddings*. Word2Vec, FastText y BERT han logrado los mejores resultados, con FastText destacándose particularmente en capturar relaciones dentro de la misma polaridad (0.86 para Positivo-Positivo y 0.96 para Negativo-Negativo). BERT también se desempeña bien en la categoría Positivo-Negativo

Tabla 5.14 Resultados de correlación de diferentes modelos de codificación de palabras en el dataset etiquetado SimLex-999.

Modelo	Spearman correlación	Spearman p-value	Pearson correlación	Pearson p-value
Word2vec <sup>1</sup>	0.03	0.40	0.08	0.04
GloVe <sup>1</sup>	0.01	0.74	0.01	0.88
FastText <sup>1</sup>	0.06	0.09	0.04	0.18
Bert <sup>1</sup>	0.17	4.39E-07	0.15	1.00E-05
Propuesta (wordnet) <sup>2</sup>	0.22	1.14E-11	0.27	7.74E-17
Propuesta (conceptnet) <sup>2</sup>	0.41	4.20E-40	0.41	1.34E-40

<sup>1</sup> Se utilizaron los algoritmos de estos modelos para generar nuestro propio *embeddings* con IMDB *dataset* con dimensión 300.

Propuestas de *embeddings* basadas en WordNet y ConceptNet con dimensión 300, generadas con parámetros óptimos de  $wl = 40$ ,  $nw = 300$  y  $b = 0,95$  identificados previamente.

(0.81), demostrando su capacidad para diferenciar entre polaridades opuestas. Sin embargo, los modelos propuestos basados en WordNet y ConceptNet muestran un rendimiento menor en todas las categorías, lo que sugiere que, aunque son efectivos en capturar relaciones conceptuales, no son tan precisos en distinguir palabras basadas en polaridad.

Por otro lado, el modelo basado en GloVe y nuestra propuesta con WordNet y ConceptNet muestran una mejor diferenciación entre palabras de polaridades opuestas (Positivo-Negativo), lo que es un buen indicio para encontrar mejores resultados para clasificación en el análisis de sentimientos. Sin embargo, ambos modelos tienen problemas para capturar bien las relaciones dentro de las mismas polaridades especialmente las propuestas con grafos.

Podemos observar una tensión aparente entre la similitud de polaridad a nivel de palabra (ver la tabla 5.15) y el rendimiento de la clasificación a nivel de frase (ver Figuras 5.3-5.4 y 5.8-5.9). No se trata de una contradicción, sino de una diferencia en los objetivos de evaluación. Las métricas intrínsecas cuantifican la proximidad coseno local entre tokens aislados, mientras que nuestra tarea posterior se basa en representaciones composicionales de oraciones y un clasificador supervisado que aprovecha patrones multitoken (por ejemplo, negación, contraste, marcadores discursivos). En consecuencia, un modelo puede obtener puntuaciones modestas en la similitud de polaridad a nivel de palabra, pero obtener un buen rendimiento en la clasificación de oraciones, ya que esta última se beneficia de las interacciones entre varias palabras y los patrones de secuencia inducidos por los paseos aleatorios sesgados por la polaridad.

Tabla 5.15 Resultados de similaridad de palabras por polaridad.

Modelo	Positivo-Positivo	Negativo-Negativo	Positivo-Negativo
Word2vec <sup>1</sup>	0.91	0.91	0.90
GloVe <sup>1</sup>	0.14	0.15	0.11
FastText <sup>1</sup>	0.86	0.96	0.81
Bert <sup>1</sup>	0.82	0.86	0.81
Propuesta (wordnet) <sup>2</sup>	0.20	0.20	0.11
Propuesta (conceptnet) <sup>2</sup>	0.16	0.16	0.11

<sup>1</sup> Se utilizaron los algoritmos de estos modelos para generar nuestro propio *embeddings* con IMDB *dataset* con dimensión 300.

Propuestas de *embeddings* basadas en WordNet y ConceptNet con dimensión 300, generadas con parámetros óptimos de  $wl = 40$ ,  $nw = 300$  y  $b = 0,95$  identificados previamente.

## 5.5. Visualización de polaridad de palabras con T-SNE

Para visualizar las palabras de polaridad se emplearon las propuestas de embeddings basadas en WordNet y ConceptNet con dimensión 300, generadas con parámetros óptimos de  $wl = 40$ ,  $nw = 300$  y  $b = 0,95$  identificados previamente.

Los *embeddings* generados con IMDB *dataset* empleando la metodología propuesta se representan de manera vectorial y la Figura 5.7 muestra las representaciones de palabras utilizando t-SNE con similitud coseno para vectorización de palabras generadas con la propuesta de WordNet (A3) y ConceptNet (B3). En WordNet (A3), podemos observar un mejor agrupamiento de palabras positivas (color verde) como *amazing*, *awesome*, *fantastic*, y *wonderful*, que logran formar grupos adecuados. Además, las palabras negativas (color rojo) como *hate*, *sad*, y *miserable* también tienen la tendencia de agruparse correctamente, pero en algunos casos se dispersan. Por otro lado, mediante la propuesta de ConceptNet (B3), las palabras positivas mantienen buena coherencia, y solo la palabra negativa *annoyed* está muy dispersa. Parece que el modelo de WordNet captura mejor las relaciones semánticas dentro de las polaridades, mientras que el modelo de ConceptNet muestra algo de dispersión, lo que indica que no captura claramente la relación con algunas palabras. En términos de diferenciación de polaridades, el gráfico de WordNet presenta una separación más clara entre palabras positivas y negativas, haciéndolo un poco más adecuado en comparación con el grafo de ConceptNet.

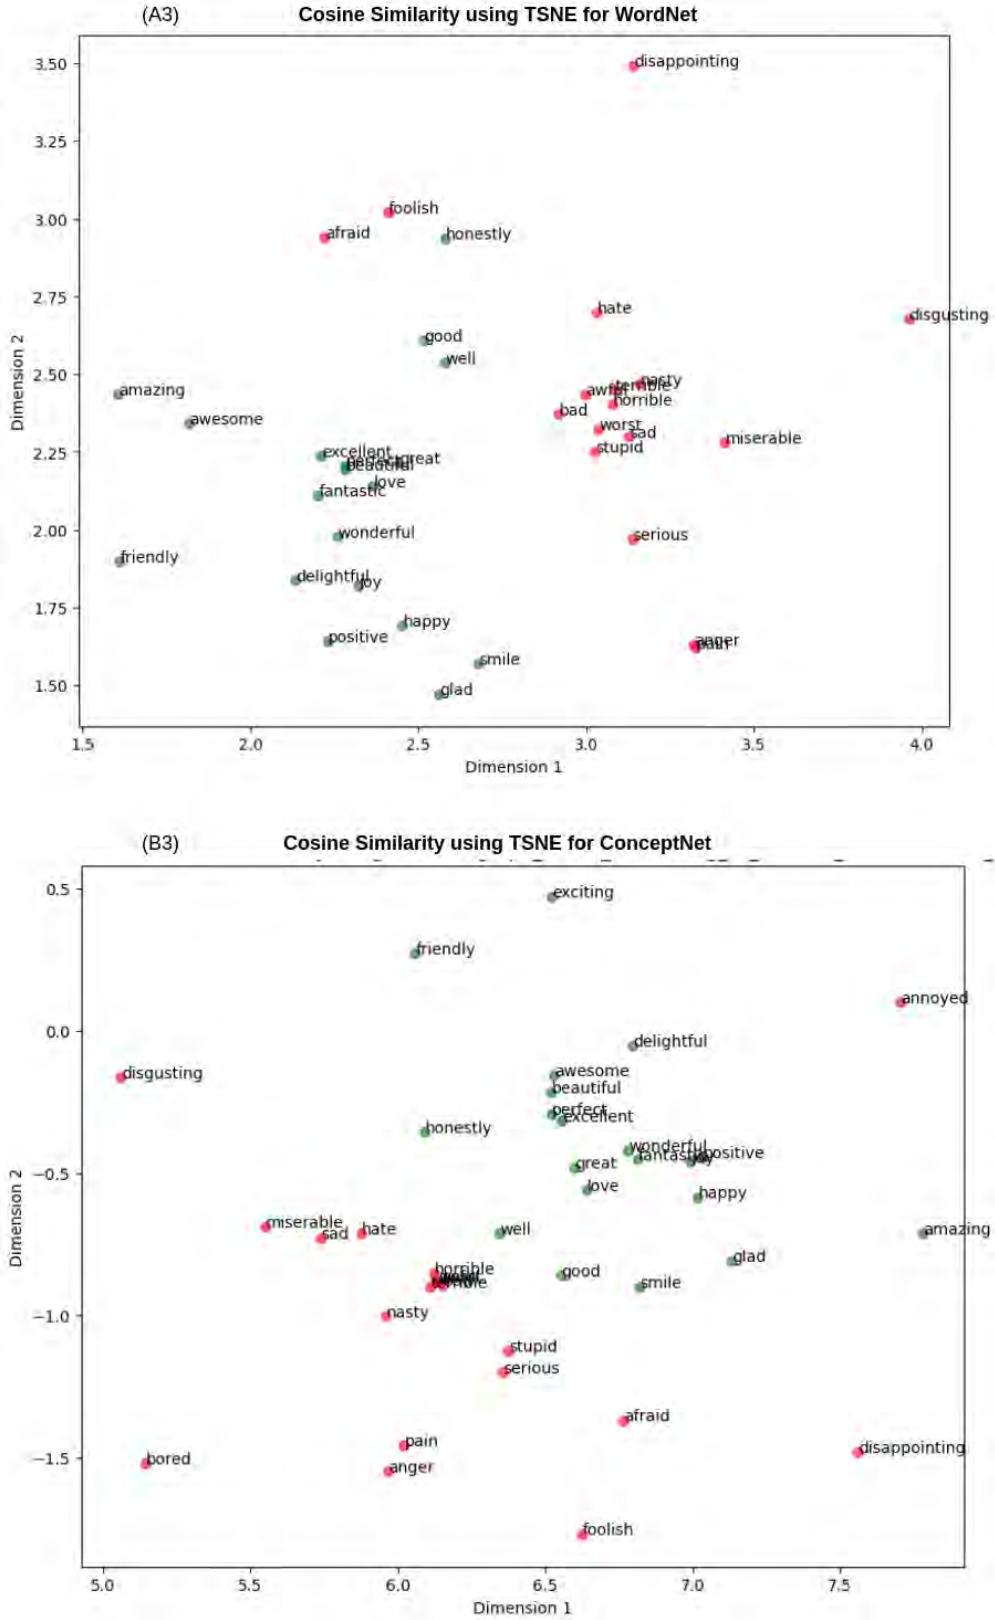


Figura 5.7 Similaridad coseno mediante t-SNE para la propuesta de *embeddings* con WordNet y ConceptNet. Color rojo (palabras negativas) y verde (Palabras positivas).

## 5.6. Resultados de accuracy y f1-score para dominio general y específico

Para evaluar SST2 *dataset* de películas, las propuestas de WordNet y ConceptNet fueron generadas con parámetros óptimos de  $wl = 40$ ,  $nw = 300$ , y  $b = 0,95$ , utilizando una dimensión de 300 para los *embeddings*, lo que permite una comparación equitativa con los modelos de *embeddings* generados con IMDB *dataset* mediante los modelos Word2Vec, GloVe, FastText y BERT con dimensiones 300. Por otro lado, para evaluar el McDonalds dataset (dominio comidas) emplearon modelos pre-entrenados de dominio general, excepto las propuestas con WordNet y ConceptNet que tienen dominio de películas.

### 5.6.1. Resultado dominio específico SST2

Los resultados presentados en las Figuras 5.8 y 5.9 muestran el rendimiento en términos de *accuracy* y *F1-score* de los diferentes modelos de codificación pre-entrenados y los métodos propuestos basados en bases conceptuales como WordNet y ConceptNet en el análisis de sentimientos utilizando el *dataset* SST2 (dominio películas), que también está relacionado con el dominio de películas, al igual que IMDB.

Evaluando el *accuracy*, se observa que la propuesta basada en ConceptNet logra los mejores resultados en la mayoría de los algoritmos, alcanzando un valor máximo de 0.78 con SVM y 0.76 con LR, lo que demuestra la capacidad de este modelo para capturar mejor las relaciones semánticas en el análisis de sentimientos. La propuesta basada en WordNet sigue de cerca, con rendimientos similares, destacando en algoritmos como RF (0.70) y LR (0.76). En comparación, los modelos pre-entrenados como Word2Vec, GloVe, y FastText tienen un rendimiento ligeramente inferior, con resultados de *accuracy* que varían entre 0.59 y 0.69 en la mayoría de los casos. BERT, con su mayor capacidad dimensional, ofrece un rendimiento aceptable, pero se mantiene por debajo de las propuestas de ConceptNet y WordNet, especialmente en algoritmos como KNN, donde obtiene una *accuracy* de 0.62.

Por otro lado, *F1-score*, los resultados siguen un patrón similar al de *accuracy*. La propuesta basada en ConceptNet muestra un rendimiento sobresaliente, alcanzando valores de 0.79 en SVM y 0.77 en LR. La propuesta de WordNet también mantiene un rendimiento competitivo, con valores cercanos a los de ConceptNet en la mayoría de los algoritmos. Nuevamente, los modelos pre-entrenados, aunque proporcionan buenos resultados, no alcanzan el mismo nivel de precisión que las propuestas basadas en grafos, lo que indica que la integración de conocimiento semántico adicional mejora la capacidad de los modelos para capturar la polaridad de los sentimientos en textos. BERT, por su parte, muestra una mejora respec-

to a los otros modelos pre-entrenados, pero sigue estando por debajo de las propuestas en términos de  $F1$ -score, especialmente en KNN, donde su valor es de 0.67.

En ese sentido, los resultados confirman que las propuestas basadas en WordNet y ConceptNet, con caminatas aleatorias utilizando parámetros con  $b = 0,95$ ,  $wl = 40$ , y  $nw = 300$ , logran un rendimiento superior tanto en  $accuracy$  como en  $F1$ -score en comparación con los modelos como Word2Vec, GloVe, FastText y BERT.




Figura 5.8 Resultados de Accuracy para SST2 dataset.

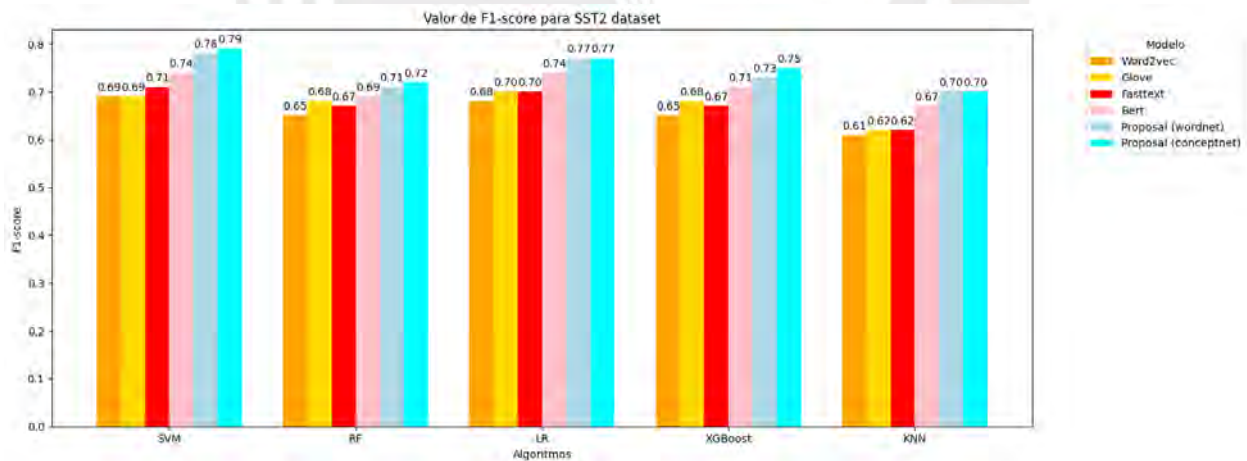


Figura 5.9 Resultados de F1-score para SST2 dataset.

### 5.6.2. Resultado dominio general McDonalds

Las Figuras 5.10 y 5.11 muestran el rendimiento de varios modelos de  $embedding$ , tanto pre-entrenados de dominio general como el metodo propuesto basado en WordNet y ConceptNet, sobre el  $dataset$  de McDonalds, evaluando las métricas de  $accuracy$  y  $F1$ -score. Los

modelos de embeddings basados en WordNet y ConceptNet fueron generadas utilizando el *dataset* de IMDB, que está relacionado con el dominio de películas, mientras que los modelos pre-entrenados como Word2Vec, GloVe, FastText y BERT fueron entrenados sobre datos de dominio general.

Evaluando el *accuracy*, se observa que los modelos pre-entrenados como Word2Vec, GloVe y FastText logran los mejores resultados en casi todos los algoritmos, alcanzando un valor máximo de 0.87 con XGBoost y RF para modelos FastText y Word2vec respectivamente. En comparación, nuestra propuesta usando WordNet y ConceptNet, aunque siguen de cerca la precisión, muestran resultados ligeramente inferiores, con valores de *accuracy* que varían entre 0.80 y 0.84 en los diferentes algoritmos. Así mismo, para *F1-score*, los resultados siguen un patrón similar al observado en *accuracy*. Los modelos pre-entrenados como Word2Vec, GloVe y FastText continúan destacándose, con XGBoost y RF nuevamente alcanzando un máximo de 0.87. Este comportamiento puede deberse a que los embeddings basados en WordNet y ConceptNet fueron generados a partir de datos de un dominio específico (IMDB, películas), mientras que el *dataset* de McDonalds está más relacionado con el análisis de sentimientos en el ámbito de los consumidores de comida rápida, lo que podría explicar el mejor rendimiento de los modelos pre-entrenados de dominio general.

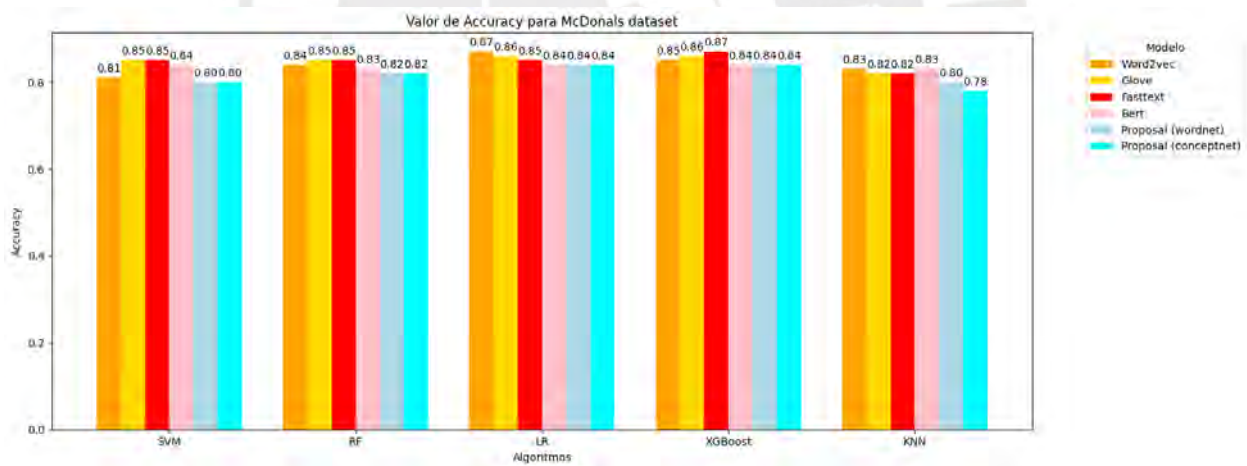


Figura 5.10 Resultados de *Accuracy* para McDonalds dataset.

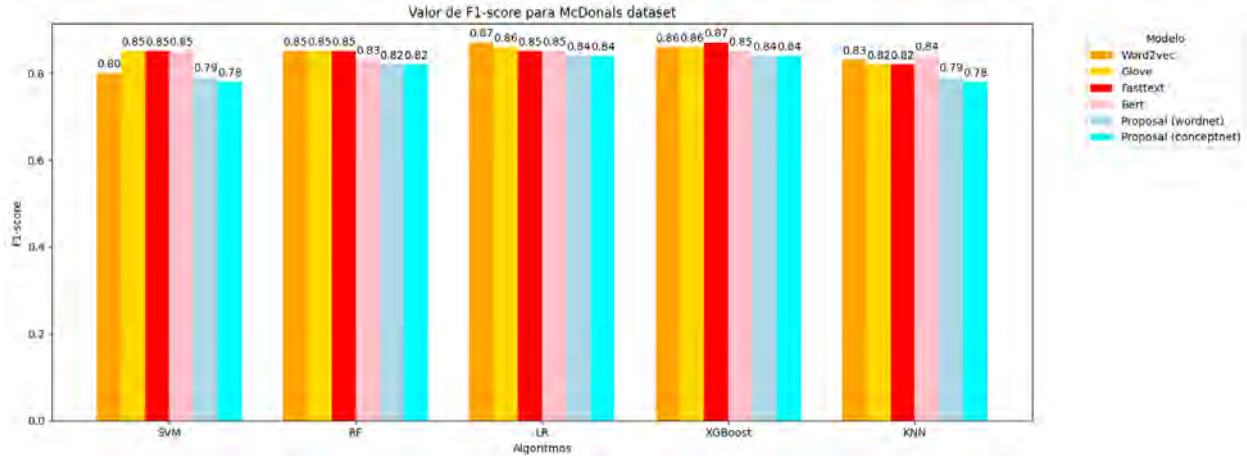


Figura 5.11 Resultados de  $F1$ -score para McDonalds dataset.

## 5.7. Análisis general de resultados

Los conjuntos de datos basado en dominio específico (IMDB utilizado para generar *embeddings* y SST-2 para la evaluación), estos *embeddings* de IMDB enriquecidas con palabras conceptuales, creadas a partir de WordNet/ConceptNet y entrenadas en caminos aleatorios sesgados por polaridad, superan a los modelos de dominio general como: Word2Vec, GloVe, FastText y BERT, en la mayoría de los clasificadores. En tal sentido, los modelos lineales como SVM y LR se benefician de representaciones que codifican relaciones léxico-semánticas junto con polaridades de sentimiento, lo que da como resultado una mayor *accuracy* y *F1-score*. Estas ganancias se alinean con la configuración experimental que resultó más eficaz para la generación de *embeddings* (dimensión = 300, longitud de recorrido  $wl = 40$ , recorridos por nodo  $nw = 300$ , sesgo  $b = 0,95$ ), y respaldan la afirmación de que la integración del conocimiento conceptual con la estructura de polaridad es ventajosa cuando las tareas están alineados hacia el dominio específico.

Desde un punto de vista de análisis cualitativos (por ejemplo, t-SNE) indican que el grafo léxico, especialmente cuando se instancia con WordNet, organiza los vecinos sensibles a la polaridad de forma más clara, mostrando una separación más nítida entre las regiones positivas y negativas y grupos intrapolaridad más compactos que su homólogo ConceptNet. Esta observación es coherente con el papel de un alto sesgo de polaridad ( $b$ ) durante los caminos aleatorios, que aumenta la probabilidad de atravesar regiones homogéneas en cuanto al sentimiento, y con la contribución de los bordes semánticos (por ejemplo, sinonimia, hponimia) que densifican las rutas entre los nodos semánticamente relacionados. En conjunto, estos factores ayudan a explicar por qué los *embeddings* propuestas capturan mejor

la estructura relevante para el sentimiento en la clasificación de polaridad en escenarios de dominio específico.

Por otro lado, el enfoque de la propuesta depende de recursos léxicos (WordNet/ConceptNet) y umbrales VADER, que pueden no abarcar la jerga y los neologismos y pueden estimar erróneamente la polaridad entre dominios. Además, el aumento de palabras conceptuales y el modelado de grafos pueden introducir una confusión en la semántica, a menos que se filtren cuidadosamente los tipos de relación y se ponderan las aristas según la fiabilidad o el tipo de relación. Por último, el uso de *embeddings* de palabras sin aclarar el significado específico podría impedir que el modelo capte plenamente la polisemia y las señales pragmáticas (por ejemplo, negación, intensificación, ironía), lo que limita la precisión de la detección de la polaridad.



# Capítulo 6

## Conclusiones y recomendaciones

En el presente trabajo se ha propuesto y evaluado un método basado en conocimiento de grafos para representar relaciones conceptuales entre palabras mediante la integración de fuentes como WordNet y ConceptNet. Los resultados de los experimentos muestran que este enfoque es eficaz para extraer relaciones semánticas y polaridad de textos. El uso de este enfoque permite generar nuevas oraciones mediante la combinación de palabras conceptuales, manteniendo la coherencia semántica de la oración original. Este método permite enriquecer el análisis de textos y mejorar la identificación de polaridad de sentimientos mediante la exploración de múltiples combinaciones que resalten distintos aspectos de una oración. Asimismo, se puede adaptar a diferentes conjuntos de datos con dominio diferente. Este método no solo capta la semántica inherente a las oraciones, sino que genera nuevas estructuras textuales que permiten la interpretación y análisis de texto. De la misma forma, demuestra que también se pueden utilizar en diferentes tareas dentro del lenguaje de procesamiento natural.

Por otro lado, la metodología desarrollada que permite extraer embeddings mediante representación conceptual de palabras, muestra la efectividad de la técnica de caminatas aleatorias sesgadas por polaridad (*Polarity-biased Random Walks*) conjuntamente con el modelo de Skip-Gram para obtener representación vectorial a partir de grafos con enfoque de polaridad. En ese sentido, el algoritmo 1 *Polarity-biased Random Walks* ayudó a dirigir caminatas entre nodos hacia la misma polaridad, lo que refuerza una mejora en relaciones de sentimientos entre nodos del grafo. Este tipo de enfoque permite mantener la coherencia de sentimientos. Por otra parte, el modelo Skip-Gram contribuyó a transformar la secuencia de palabras obtenidas del grafo en representación vectorial mediante conexiones semánticas. Los resultados obtenidos demuestran que la metodología es eficaz para generar embeddings conceptuales de dominio específico y sentido de polaridad. Se tienen mejores resultados de *accuracy* y *f1-score* en dominios específicos en comparación con conjuntos de datos de

dominio general, mostrando su capacidad para mejorar la clasificación de sentimientos. Sin embargo, los resultados también muestran el rendimiento de *embeddings* conceptuales que pueden ser afectados cuando se aplican a conjuntos de datos de dominios diferentes, como se observa en el análisis en el conjunto de datos de McDonalds donde los *embeddings* pre-entrenados de dominio general demuestran ser más eficaces.

Los resultados obtenidos al evaluar las propuestas basadas en conocimiento de grafos mediante WordNet y ConceptNet en el dominio específico (*embeddings* con IMDB *movie*) y el conjunto de datos SST2 *movie*, demuestran la eficacia de los modelos de *embeddings* conceptuales para capturar la semántica y polaridad. Empleando las relaciones semánticas de ConceptNet se lograron los mejores resultados en términos de *accuracy* y *F1-score*, alcanzando valores de 0.78 en SVM y 0.76 en LR, demostrando que estos modelos son capaces de representar de manera precisa las relaciones semánticas para clasificar polaridad en dominio específico. Por otro lado, WordNet mostró un rendimiento competitivo, aunque ligeramente por debajo de ConceptNet en algunos algoritmos. Esto sugiere que la representación semántica de las palabras mediante grafos es particularmente efectiva en contextos donde el dominio de los datos de entrenamiento y de prueba está alineado en dominio específico, como en este caso con el dominio de películas. En comparación, los modelos pre-entrenados como Word2Vec, GloVe y FastText mostraron un rendimiento ligeramente inferior en el mismo dominio. Aunque estos modelos capturan bien las relaciones semánticas generales, carecen de la especificidad que ofrecen los modelos conceptuales, lo que resulta en una menor capacidad para identificar la polaridad de los textos. BERT, por su parte, presentó resultados aceptables, pero no logró superar a las propuestas basadas en grafos, lo que refuerza la conclusión de que la integración de relaciones conceptuales mejora significativamente el análisis de sentimientos en contextos alineados con el dominio específico durante el entrenamiento.

Por otro lado, la evaluación de propuestas de *embeddings* conceptuales basadas en WordNet y ConceptNet frente a modelos pre-entrenados de dominio general (Word2Vec, GloVe, FastText y BERT), utilizando el conjunto de datos de McDonalds (dominio general opiniones de comida rápida), se observó que los modelos de dominio general lograron un rendimiento superior. Los modelos pre-entrenados como Word2Vec y FastText alcanzaron los mejores resultados, con *accuracy* de 0.87 en algoritmos como XGBoost y RF, mientras que las propuestas basadas en WordNet y ConceptNet tienen resultados cercanos con valores de *accuracy* y *F1-score* entre 0.80 y 0.84 en la mayoría de los algoritmos. Este comportamiento se debe en gran parte a que los *embeddings* basados en WordNet y ConceptNet fueron generados a partir de un dominio específico (opinión de películas), mientras que el dataset de McDonalds se centra en el análisis de sentimientos de consumidores en un contexto de dominio general (opiniones de comida rápida). Los modelos pre-entrenados, al ser de dominio

general, son más versátiles y robustos cuando se aplican a diferentes dominios, lo cual demuestra ser superior en resultados para este caso. Por lo tanto, los resultados sugieren que, si bien las propuestas basadas en grafos conceptuales son efectivas en dominios específicos, los modelos pre-entrenados de dominio general ofrecen un mejor rendimiento en contextos más amplios. También se concluye que, al emplear modelos basados en conocimiento de grafos como Node2Vec, GraphSAGE y GAT, comparados con la propuesta mediante WordNet y ConceptNet, se observó que la propuesta con ConceptNet obtiene mejores resultados con *accuracy* cercanos a 0.85 con algoritmos de SVM y RF.

A partir de los resultados obtenidos, se recomienda utilizar modelos basados en grafos conceptuales como WordNet y ConceptNet en dominios específicos donde la semántica y las relaciones entre conceptos sean clave para mejorar la precisión del análisis de sentimientos. Estos modelos demostraron una capacidad superior para capturar relaciones semánticas y de polaridad en comparación con métodos como Node2Vec o GraphSAGE, gracias a la inclusión de caminatas aleatorias sesgadas que priorizan la coherencia de la polaridad en las palabras. Se sugiere, además, explorar enfoques híbridos que combinen la riqueza semántica de los modelos conceptuales para lograr una mejor representación *embeddings* pre-entrenados. Asimismo, se sugiere evaluar el impacto del tamaño y la calidad de los grafos generados en las métricas de rendimiento, explorando la escalabilidad del enfoque propuesto en conjuntos de datos masivos. Por otro lado, se recomienda implementar un sistema de ponderación dinámica en las conexiones del grafo de co-ocurrencia, donde los pesos de los enlaces entre palabras se ajusten en función de la proximidad semántica y la intensidad de la polaridad, lo que podría aumentar la precisión en la representación de los sentimientos. Otra recomendación es la integración de modelos de atención, como Graph Attention Networks (GAT), para priorizar las conexiones relevantes durante las caminatas aleatorias, permitiendo un aprendizaje más refinado en la estructura del grafo. Finalmente, este trabajo no solo aporta mejoras sustanciales en la clasificación de sentimientos, sino que también abre nuevas perspectivas de conocimiento basado en grafos para resolver problemas en el análisis de texto, surgiendo como una herramienta clave para el desarrollo de nuevos modelos en tareas de lenguaje de procesamiento natural.

# Referencias

- [1] B. Liu, *Sentiment Analysis: Mining Opinions, Sentiments, and Emotions* (Studies in Natural Language Processing), 2.<sup>a</sup> ed. Cambridge University Press, 2020. DOI: 10.1017/9781108639286.
- [2] E. Cambria, «An Introduction to Concept-Level Sentiment Analysis,» en *Advances in Soft Computing and Its Applications*, F. Castro, A. Gelbukh y M. González, eds., Berlin, Heidelberg: Springer Berlin Heidelberg, 2013, págs. 478-483, ISBN: 978-3-642-45111-9.
- [3] R. Studer, V. Benjamins y D. Fensel, «Knowledge engineering: Principles and methods,» *Data & Knowledge Engineering*, vol. 25, n.º 1, págs. 161-197, 1998, ISSN: 0169-023X. DOI: [https://doi.org/10.1016/S0169-023X\(97\)00056-6](https://doi.org/10.1016/S0169-023X(97)00056-6). dirección: <https://www.sciencedirect.com/science/article/pii/S0169023X97000566>.
- [4] D. C. Moreno y M. V. Lombardo, «Ontología y Procesamiento de Lenguaje Natural,» *KnE Engineering*, vol. 3, n.º 2, págs. 492-501, feb. de 2018. DOI: 10.18502/keg.v3i1.1453. dirección: <https://knepublishing.com/index.php/KnE-Engineering/article/view/1453>.
- [5] M. ajgalik, M. Barla y M. Bieliková, «From Ambiguous Words to Key-Concept Extraction,» en *2013 24th International Workshop on Database and Expert Systems Applications*, 2013, págs. 63-67. DOI: 10.1109/DEXA.2013.16.
- [6] T. Mikolov, K. Chen, G. Corrado y J. Dean, *Efficient Estimation of Word Representations in Vector Space*, 2013. DOI: 10.48550/ARXIV.1301.3781. dirección: <https://arxiv.org/abs/1301.3781>.
- [7] J. Pennington, R. Socher y C. Manning, «GloVe: Global Vectors for Word Representation,» en *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, Doha, Qatar: Association for Computational Linguistics, oct. de 2014, págs. 1532-1543. DOI: 10.3115/v1/D14-1162. dirección: <https://nlp.stanford.edu/pubs/glove.pdf>.
- [8] P. Bojanowski, E. Grave, A. Joulin y T. Mikolov, *Enriching Word Vectors with Subword Information*, 2016. DOI: 10.48550/ARXIV.1607.04606. dirección: <https://arxiv.org/abs/1607.04606>.
- [9] M. E. Peters, M. Neumann, M. Iyyer et al., *Deep contextualized word representations*, 2018. DOI: 10.48550/ARXIV.1802.05365. dirección: <https://arxiv.org/abs/1802.05365>.

- [10] J. Devlin, M.-W. Chang, K. Lee y K. Toutanova, *BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding*, 2018. DOI: 10.48550/ARXIV.1810.04805. dirección: <https://arxiv.org/abs/1810.04805>.
- [11] X. Han, Z. Zhang, N. Ding et al., «Pre-trained models: Past, present and future,» *AI Open*, vol. 2, págs. 225-250, 2021, ISSN: 2666-6510. DOI: <https://doi.org/10.1016/j.aiopen.2021.08.002>. dirección: <https://www.sciencedirect.com/science/article/pii/S2666651021000231>.
- [12] J. Lee, W. Yoon, S. Kim et al., «BioBERT: a pre-trained biomedical language representation model for biomedical text mining,» *Bioinformatics*, J. Wren, ed., sep. de 2019. DOI: 10.1093/bioinformatics/btz682. dirección: <https://doi.org/10.1093%5C%2Fbioinformatics%5C%2Fbtz682>.
- [13] I. Beltagy, K. Lo y A. Cohan, «SciBERT: A Pretrained Language Model for Scientific Text,» 2019. DOI: 10.48550/ARXIV.1903.10676. dirección: <https://arxiv.org/abs/1903.10676>.
- [14] P. Ke, H. Ji, S. Liu, X. Zhu y M. Huang, *SentiLARE: Sentiment-Aware Language Representation Learning with Linguistic Knowledge*, 2019. DOI: 10.48550/ARXIV.1911.02493. dirección: <https://arxiv.org/abs/1911.02493>.
- [15] J. Zhang, Y. Zhao, M. Saleh y P. J. Liu, *PEGASUS: Pre-training with Extracted Gap-sentences for Abstractive Summarization*, 2019. DOI: 10.48550/ARXIV.1912.08777. dirección: <https://arxiv.org/abs/1912.08777>.
- [16] Y. Ma y E. Cambria, *Concept-Based Embeddings for Natural Language Processing*, 2018. DOI: 10.48550/ARXIV.1807.05519. dirección: <https://arxiv.org/abs/1807.05519>.
- [17] A. R. Asokan, N. Kumar, A. V. Ragam y S. S. Shylaja, «Interpretability for Multimodal Emotion Recognition using Concept Activation Vectors,» en *2022 International Joint Conference on Neural Networks (IJCNN)*, 2022, págs. 01-08. DOI: 10.1109/IJCNN55064.2022.9892315.
- [18] G. Schreiber, H. Akkermans, A. Anjewierden et al., *Knowledge Engineering and Management: The CommonKADS Methodology*. The MIT Press, dic. de 1999, ISBN: 9780262283236. DOI: 10.7551/mitpress/4073.001.0001. dirección: <https://doi.org/10.7551/mitpress/4073.001.0001>.
- [19] H. T. Phan, N. T. Nguyen y D. Hwang, «Aspect-level sentiment analysis: A survey of graph convolutional network methods,» *Information Fusion*, vol. 91, págs. 149-172, 2023, ISSN: 1566-2535. DOI: <https://doi.org/10.1016/j.inffus.2022.10.004>. dirección: <https://www.sciencedirect.com/science/article/pii/S1566253522001749>.
- [20] J. Johnson, A. Gupta y L. Fei-Fei, «Image Generation from Scene Graphs,» en *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2018, págs. 1219-1228. DOI: 10.1109/CVPR.2018.00133.

- [21] Y. Wang, G. Tan, B. Li et al., «Enhanced NIR photocatalytic of Ag-RGO@010BiVO<sub>4</sub>/RGO@110 BiVO<sub>4</sub> photocatalysts induced by resonance effect of transverse electric of RGO and transverse magnetic of Ag,» *Applied Surface Science*, vol. 489, págs. 1-12, 2019, ISSN: 0169-4332. DOI: <https://doi.org/10.1016/j.apsusc.2019.05.145>. dirección: <https://www.sciencedirect.com/science/article/pii/S0169433219314539>.
- [22] S. Vashishth, M. Bhandari, P. Yadav, P. Rai, C. Bhattacharyya y P. Talukdar, «Incorporating Syntactic and Semantic Information in Word Embeddings using Graph Convolutional Networks,» en *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*, Florence, Italy: Association for Computational Linguistics, jul. de 2019, págs. 3308-3318. DOI: 10.18653/v1/P19-1320. dirección: <https://aclanthology.org/P19-1320>.
- [23] L. Huang, D. Ma, S. Li, X. Zhang y H. Wang, «Text Level Graph Neural Network for Text Classification,» *CoRR*, vol. abs/1910.02356, 2019. arXiv: 1910.02356. dirección: <http://arxiv.org/abs/1910.02356>.
- [24] L. Yao, C. Mao e Y. Luo, «Graph Convolutional Networks for Text Classification,» *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 33, n.º 01, págs. 7370-7377, jul. de 2019. DOI: 10.1609/aaai.v33i01.33017370. dirección: <https://ojs.aaai.org/index.php/AAAI/article/view/4725>.
- [25] T.-J. Fu, P.-H. Li y W.-Y. Ma, «GraphRel: Modeling Text as Relational Graphs for Joint Entity and Relation Extraction,» en *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*, Florence, Italy: Association for Computational Linguistics, jul. de 2019, págs. 1409-1418. DOI: 10.18653/v1/P19-1136. dirección: <https://aclanthology.org/P19-1136>.
- [26] Y. Zhang, P. Qi y C. D. Manning, «Graph Convolution over Pruned Dependency Trees Improves Relation Extraction,» en *Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing*, Brussels, Belgium: Association for Computational Linguistics, nov. de 2018, págs. 2205-2215. DOI: 10.18653/v1/D18-1244. dirección: <https://aclanthology.org/D18-1244>.
- [27] H. Yao, F. Wu, J. Ke et al., «Deep multi-view spatial-temporal network for taxi demand prediction,» en *Proceedings of the AAAI conference on artificial intelligence*, vol. 32, 2018.
- [28] R. v. d. Berg, T. N. Kipf y M. Welling, *Graph Convolutional Matrix Completion*, 2017. DOI: 10.48550/ARXIV.1706.02263. dirección: <https://arxiv.org/abs/1706.02263>.
- [29] J. Li, S. Zhang, T. Liu, C. Ning, Z. Zhang y W. Zhou, «Neural inductive matrix completion with graph convolutional networks for miRNA-disease association prediction,» *Bioinformatics*, vol. 36, n.º 8, págs. 2538-2546, ene. de 2020, ISSN: 1367-4803. DOI: 10.1093/bioinformatics/btz965. eprint: <https://academic.oup.com/bioinformatics/article-pdf/36/8/2538/33116520/btz965.pdf>. dirección: <https://doi.org/10.1093/bioinformatics/btz965>.

- [30] J. Bastings, I. Titov, W. Aziz, D. Marcheggiani y K. Sima'an, «Graph Convolutional Encoders for Syntax-aware Neural Machine Translation,» *CoRR*, vol. abs/1704.04675, 2017. arXiv: 1704.04675. dirección: <http://arxiv.org/abs/1704.04675>.
- [31] D. Marcheggiani e I. Titov, «Encoding Sentences with Graph Convolutional Networks for Semantic Role Labeling,» *CoRR*, vol. abs/1703.04826, 2017. arXiv: 1703.04826. dirección: <http://arxiv.org/abs/1703.04826>.
- [32] S. Vashishth, P. Yadav, M. Bhandari, P. Rai, C. Bhattacharyya y P. Talukdar, «Graph convolutional networks based word embeddings,» *arXiv preprint arXiv:1809.04283*, 2018. DOI: <https://arxiv.org/pdf/1809.04283v1.pdf>.
- [33] E. Cambria, B. Schuller, Y. Xia y C. Havasi, «New Avenues in Opinion Mining and Sentiment Analysis,» *IEEE Intelligent Systems*, vol. 28, n.º 2, págs. 15-21, 2013. DOI: 10.1109/MIS.2013.30.
- [34] Z. Kastrati, F. Dalipi, A. S. Imran, K. Pireva Nuci y M. A. Wani, «Sentiment Analysis of Students' Feedback with NLP and Deep Learning: A Systematic Mapping Study,» *Applied Sciences*, vol. 11, n.º 9, 2021, ISSN: 2076-3417. DOI: 10.3390/app11093986. dirección: <https://www.mdpi.com/2076-3417/11/9/3986>.
- [35] A. Yadollahi, A. G. Shahraki y O. R. Zaiane, «Current State of Text Sentiment Analysis from Opinion to Emotion Mining,» *ACM Comput. Surv.*, vol. 50, n.º 2, mayo de 2017, ISSN: 0360-0300. DOI: 10.1145/3057270. dirección: <https://doi.org/10.1145/3057270>.
- [36] K. Cortis y B. Davis, «Over a decade of social opinion mining: a systematic review,» *Artificial Intelligence Review*, vol. 54, n.º 7, págs. 4873-4965, oct. de 2021, ISSN: 1573-7462. DOI: 10.1007/s10462-021-10030-2. dirección: <https://doi.org/10.1007/s10462-021-10030-2>.
- [37] A. Yadav y D. K. Vishwakarma, «Sentiment analysis using deep learning architectures: a review,» *Artificial Intelligence Review*, vol. 53, n.º 6, págs. 4335-4385, ago. de 2020, ISSN: 1573-7462. DOI: 10.1007/s10462-019-09794-5. dirección: <https://doi.org/10.1007/s10462-019-09794-5>.
- [38] M. Birjali, M. Kasri y A. Beni-Hssane, «A comprehensive survey on sentiment analysis: Approaches, challenges and trends,» *Knowledge-Based Systems*, vol. 226, pág. 107134, 2021, ISSN: 0950-7051. DOI: <https://doi.org/10.1016/j.knosys.2021.107134>. dirección: <https://www.sciencedirect.com/science/article/pii/S095070512100397X>.
- [39] «Embeddings — machine learning,» Google Developers. (), dirección: <https://developers.google.com/machine-learning/crash-course/embeddings/video-lecture> (visitado 08-11-2022).
- [40] «Word embeddings — text,» TensorFlow. (), dirección: [https://www.tensorflow.org/text/guide/word\\_embeddings](https://www.tensorflow.org/text/guide/word_embeddings) (visitado 08-11-2022).

- [41] M. Baroni, G. Dinu y G. Kruszewski, «Don't count, predict! A systematic comparison of context-counting vs. context-predicting semantic vectors,» en *Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, Baltimore, Maryland: Association for Computational Linguistics, jun. de 2014, págs. 238-247. DOI: 10.3115/v1/P14-1023. dirección: <https://aclanthology.org/P14-1023>.
- [42] O. Levy, Y. Goldberg e I. Dagan, «Improving Distributional Similarity with Lessons Learned from Word Embeddings,» *Transactions of the Association for Computational Linguistics*, vol. 3, págs. 211-225, 2015. DOI: 10.1162/tacl\_a\_00134. dirección: <https://aclanthology.org/Q15-1016>.
- [43] T. Mikolov, I. Sutskever, K. Chen, G. Corrado y J. Dean, *Distributed Representations of Words and Phrases and their Compositionality*, 2013. DOI: 10.48550/ARXIV.1310.4546. dirección: <https://arxiv.org/abs/1310.4546>.
- [44] A. Vaswani, N. Shazeer, N. Parmar et al., *Attention Is All You Need*, 2017. DOI: 10.48550/ARXIV.1706.03762. dirección: <https://arxiv.org/abs/1706.03762>.
- [45] Q. Chen, K. Lee, S. Yan, S. Kim, C.-H. Wei y Z. Lu, «BioConceptVec: Creating and evaluating literature-based biomedical concept embeddings on a large scale,» *PLOS Computational Biology*, vol. 16, n.º 4, págs. 1-18, abr. de 2020. DOI: 10.1371/journal.pcbi.1007617. dirección: <https://doi.org/10.1371/journal.pcbi.1007617>.
- [46] X. Jiang, Y. Shen, Y. Wang, X. Jin y X. Cheng, «BaKGraSTeC: A Background Knowledge Graph Based Method for Short Text Classification,» en *2020 IEEE International Conference on Knowledge Graph (ICKG)*, 2020, págs. 360-366. DOI: 10.1109/ICKG50248.2020.00058.
- [47] H. Li, G. Huang, Y. Li, X. Zhang e Y. Wang, «Concept-Based Label Distribution Learning for Text Classification,» *International Journal of Computational Intelligence Systems*, vol. 15, n.º 1, pág. 85, oct. de 2022, ISSN: 1875-6883. DOI: 10.1007/s44196-022-00144-y. dirección: <https://doi.org/10.1007/s44196-022-00144-y>.
- [48] R. Navigli, «Word sense disambiguation: A survey,» *ACM Comput. Surv.*, vol. 41, n.º 2, feb. de 2009, ISSN: 0360-0300. DOI: 10.1145/1459352.1459355. dirección: <https://doi.org/10.1145/1459352.1459355>.
- [49] G. A. Miller, «WordNet: a lexical database for English,» *Commun. ACM*, vol. 38, n.º 11, págs. 39-41, nov. de 1995, ISSN: 0001-0782. DOI: 10.1145/219717.219748. dirección: <https://doi.org/10.1145/219717.219748>.
- [50] R. Speer, J. Chin y C. Havasi, «ConceptNet 5.5: an open multilingual graph of general knowledge,» en *Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence*, ép. AAAI'17, San Francisco, California, USA: AAAI Press, 2017, págs. 4444-4451.
- [51] A. Galland, «Deep learning techniques for graph embedding at different scales,» Theses, Université Paris sciences et lettres, dic. de 2020. dirección: <https://tel.archives-ouvertes.fr/tel-03690033>.

- [52] X. Zhang, *Graph representation learning*, 2022. DOI: 10.32657/10356/155039.
- [53] F. Tong. «Overview of Deep Learning on Graph Embeddings,» Medium. (21 de nov. de 2020), dirección: <https://towardsdatascience.com/overview-of-deep-learning-on-graph-embeddings-4305c10ad4a4> (visitado 14-11-2022).
- [54] S. Cao, W. Lu y Q. Xu, «Deep Neural Networks for Learning Graph Representations,» *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 30, n.º 1, feb. de 2016. DOI: 10.1609/aaai.v30i1.10179. dirección: <https://ojs.aaai.org/index.php/AAAI/article/view/10179>.
- [55] A. Grover y J. Leskovec, «Node2vec: Scalable Feature Learning for Networks,» en *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, ép. KDD '16, San Francisco, California, USA: Association for Computing Machinery, 2016, págs. 855-864, ISBN: 9781450342322. DOI: 10.1145/2939672.2939754. dirección: <https://doi.org/10.1145/2939672.2939754>.
- [56] S. Abu-El-Haija, B. Perozzi y R. Al-Rfou, «Learning Edge Representations via Low-Rank Asymmetric Projections,» en *Proceedings of the 2017 ACM on Conference on Information and Knowledge Management*, ép. CIKM '17, Singapore, Singapore: Association for Computing Machinery, 2017, págs. 1787-1796, ISBN: 9781450349185. DOI: 10.1145/3132847.3132959. dirección: <https://doi.org/10.1145/3132847.3132959>.
- [57] W. L. Hamilton, R. Ying y J. Leskovec, *Inductive Representation Learning on Large Graphs*, 2018. arXiv: 1706.02216 [cs.SI].
- [58] S. Abu-El-Haija, B. Perozzi, R. Al-Rfou y A. A. Alemi, «Watch Your Step: Learning Node Embeddings via Graph Attention,» en *Advances in Neural Information Processing Systems*, S. Bengio, H. Wallach, H. Larochelle, K. Grauman, N. Cesa-Bianchi y R. Garnett, eds., vol. 31, Curran Associates, Inc., 2018. dirección: <https://proceedings.neurips.cc/paper/2018/file/8a94ecfa54dcb88a2fa993bfa6388f9e-Paper.pdf>.
- [59] B. Perozzi, R. Al-Rfou y S. Skiena, «DeepWalk: Online Learning of Social Representations,» en *Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, ép. KDD '14, New York, New York, USA: Association for Computing Machinery, 2014, págs. 701-710, ISBN: 9781450329569. DOI: 10.1145/2623330.2623732. dirección: <https://doi.org/10.1145/2623330.2623732>.
- [60] A. Narayanan, M. Chandramohan, R. Venkatesan, L. Chen, Y. Liu y S. Jaiswal, *graph2vec: Learning Distributed Representations of Graphs*, 2017. DOI: 10.48550/ARXIV.1707.05005. dirección: <https://arxiv.org/abs/1707.05005>.
- [61] H. Chen, B. Perozzi, Y. Hu y S. Skiena, *HARP: Hierarchical Representation Learning for Networks*, 2017. DOI: 10.48550/ARXIV.1706.07845. dirección: <https://arxiv.org/abs/1706.07845>.
- [62] T. N. Kipf y M. Welling, «Semi-Supervised Classification with Graph Convolutional Networks,» *CoRR*, vol. abs/1609.02907, 2016. arXiv: 1609.02907. dirección: <http://arxiv.org/abs/1609.02907>.

- [63] P. Veličković, G. Cucurull, A. Casanova, A. Romero, P. Liò e Y. Bengio, *Graph Attention Networks*, 2018. arXiv: 1710.10903 [stat.ML]. dirección: <https://arxiv.org/abs/1710.10903>.
- [64] V. Anoop, C. Subin Krishna y U. H. Govindarajan, «Graph embedding approaches for social media sentiment analysis with model explanation,» *International Journal of Information Management Data Insights*, vol. 4, n.º 1, pág. 100 221, 2024, ISSN: 2667-0968. DOI: <https://doi.org/10.1016/j.jjime.2024.100221>. dirección: <https://www.sciencedirect.com/science/article/pii/S2667096824000107>.
- [65] Y. Mamani-Coaquira y E. Villanueva, «A Review on Text Sentiment Analysis With Machine Learning and Deep Learning Techniques,» *IEEE Access*, vol. 12, págs. 193 115-193 130, 2024. DOI: 10.1109/ACCESS.2024.3513321.
- [66] H. P. Luhn, «A Statistical Approach to Mechanized Encoding and Searching of Literary Information,» *IBM Journal of Research and Development*, vol. 1, n.º 4, págs. 309-317, 1957. DOI: 10.1147/rd.14.0309.
- [67] K. Sparck Jones, «A Statistical Interpretation of Term Specificity and Its Application in Retrieval,» en *Document Retrieval Systems*. GBR: Taylor Graham Publishing, 1988, págs. 132-142, ISBN: 0947568212.
- [68] A. Radford, K. Narasimhan, T. Salimans, I. Sutskever et al., «Improving language understanding by generative pre-training,» 2018.
- [69] Y. Liu, M. Ott, N. Goyal et al., *RoBERTa: A Robustly Optimized BERT Pretraining Approach*, 2019. DOI: 10.48550/ARXIV.1907.11692. dirección: <https://arxiv.org/abs/1907.11692>.
- [70] Z. Lan, M. Chen, S. Goodman, K. Gimpel, P. Sharma y R. Soricut, *ALBERT: A Lite BERT for Self-supervised Learning of Language Representations*, 2019. DOI: 10.48550/ARXIV.1909.11942. dirección: <https://arxiv.org/abs/1909.11942>.
- [71] C. Raffel, N. Shazeer, A. Roberts et al., *Exploring the Limits of Transfer Learning with a Unified Text-to-Text Transformer*, 2019. DOI: 10.48550/ARXIV.1910.10683. dirección: <https://arxiv.org/abs/1910.10683>.
- [72] Z. Rajabi, M. R. Valavi y M. Hourali, «A Context-Based Disambiguation Model for Sentiment Concepts Using a Bag-of-Concepts Approach,» *Cognitive Computation*, vol. 12, n.º 6, págs. 1299-1312, nov. de 2020, ISSN: 1866-9964. DOI: 10.1007/s12559-020-09729-1. dirección: <https://doi.org/10.1007/s12559-020-09729-1>.
- [73] R. Speer, J. Chin y C. Havasi, «ConceptNet 5.5: An Open Multilingual Graph of General Knowledge,» *CoRR*, vol. abs/1612.03975, 2016. arXiv: 1612.03975. dirección: <http://arxiv.org/abs/1612.03975>.
- [74] T. Nijhawan, G. Attigeri y T. Ananthakrishna, «Stress detection using natural language processing and machine learning over social interactions,» *Journal of Big Data*, vol. 9, n.º 1, pág. 33, mar. de 2022, ISSN: 2196-1115. DOI: 10.1186/s40537-022-00575-6. dirección: <https://doi.org/10.1186/s40537-022-00575-6>.

- [75] A. Chinnalagu y A. K. Durairaj, «Context-based sentiment analysis on customer reviews using machine learning linear models,» *PeerJ Computer Science*, vol. 7, e813, dic. de 2021, ISSN: 2376-5992. DOI: 10.7717/peerj-cs.813. dirección: <https://doi.org/10.7717/peerj-cs.813>.
- [76] A. Khattak, M. Z. Asghar, Z. Ishaq, W. H. Bangyal e I. A. Hameed, «Enhanced concept-level sentiment analysis system with expanded ontological relations for efficient classification of user reviews,» *Egyptian Informatics Journal*, vol. 22, n.º 4, págs. 455-471, 2021, ISSN: 1110-8665. DOI: <https://doi.org/10.1016/j.eij.2021.03.001>. dirección: <https://www.sciencedirect.com/science/article/pii/S1110866521000219>.
- [77] A. H. Hussein, I. F. Moawad y R. M. Badry, «Arabic Sentiment Analysis for Multidialect Text using Machine Learning Techniques,» *International Journal of Advanced Computer Science and Applications*, vol. 12, n.º 12, 2021. DOI: 10.14569/IJACSA.2021.0121286. dirección: <http://dx.doi.org/10.14569/IJACSA.2021.0121286>.
- [78] H. Ali, H. Farman, H. Yar, Z. Khan, S. Habib y A. Ammar, «Deep learning-based election results prediction using Twitter activity,» *Soft Computing*, vol. 26, n.º 16, págs. 7535-7543, ago. de 2022, ISSN: 1433-7479. DOI: 10.1007/s00500-021-06569-5. dirección: <https://doi.org/10.1007/s00500-021-06569-5>.
- [79] B. Gaye, D. Zhang y A. Wulamu, «Sentiment classification for employees reviews using regression vector- stochastic gradient descent classifier (RV-SGDC),» *PeerJ Computer Science*, vol. 7, e712, oct. de 2021, ISSN: 2376-5992. DOI: 10.7717/peerj-cs.712. dirección: <https://doi.org/10.7717/peerj-cs.712>.
- [80] C. Sachin, S. Deepak, S. Niranjana y R. Romil, «Analysis of sentiment based movie reviews using machine learning techniques,» *Journal of Intelligent & Fuzzy Systems*, vol. 41, págs. 5449-5456, 2021, 5, ISSN: 1875-8967. DOI: 10.3233/JIFS-189866. dirección: <https://doi.org/10.3233/JIFS-189866>.
- [81] M. Azam, T. Ahmed, R. Ahmad, A. U. Rehman, F. Sabah y R. M. Asif, «A Two-Step Approach for Improving Sentiment Classification Accuracy,» *Intelligent Automation & Soft Computing*, vol. 30, n.º 3, págs. 853-867, 2021, ISSN: 2326-005X. DOI: 10.32604/iasc.2021.019101. dirección: <http://www.techscience.com/iasc/v30n3/44101>.
- [82] M. M. Ali, «Arabic sentiment analysis about online learning to mitigate covid-19,» *Journal of Intelligent Systems*, vol. 30, n.º 1, págs. 524-540, 2021. DOI: [doi:10.1515/jisys-2020-0115](https://doi.org/10.1515/jisys-2020-0115). dirección: <https://doi.org/10.1515/jisys-2020-0115>.
- [83] U. Younis, M. Z. Asghar, A. Khan, A. Khan, J. Iqbal y N. Jillani, «Applying Machine Learning Techniques for Performing Comparative Opinion Mining,» *Open Computer Science*, vol. 10, n.º 1, págs. 461-477, 2020. DOI: [doi:10.1515/comp-2020-0148](https://doi.org/10.1515/comp-2020-0148). dirección: <https://doi.org/10.1515/comp-2020-0148>.

- [84] Z. M. Zain, A. A. Alhajji, N. S. Alotaibi et al., «Ranking Beauty Clinics in Riyadh using Lexicon-Based Sentiment Analysis and Multiattribute-Utility Theory,» *International Journal of Advanced Computer Science and Applications*, vol. 11, n.º 10, 2020. DOI: 10.14569/IJACSA.2020.0111009. dirección: <http://dx.doi.org/10.14569/IJACSA.2020.0111009>.
- [85] S. MIHI, B. A. B. ALI, I. E. BAZI, S. AREZKI y N. LAACHFOUBI, «MSTD: Moroccan Sentiment Twitter Dataset,» *International Journal of Advanced Computer Science and Applications*, vol. 11, n.º 10, 2020. DOI: 10.14569/IJACSA.2020.0111045. dirección: <http://dx.doi.org/10.14569/IJACSA.2020.0111045>.
- [86] F. M. Plaza-del-Arco, M. T. Martín-Valdivia, L. A. Ureña-López y R. Mitkov, «Improved emotion recognition in Spanish social media through incorporation of lexical knowledge,» *Future Generation Computer Systems*, vol. 110, págs. 1000-1008, 2020, ISSN: 0167-739X. DOI: <https://doi.org/10.1016/j.future.2019.09.034>. dirección: <https://www.sciencedirect.com/science/article/pii/S0167739X1931163X>.
- [87] M. Y. Khan y K. N. Junejo, «Exerting 2D-Space of Sentiment Lexicons with Machine Learning Techniques: A Hybrid Approach for Sentiment Analysis,» *International Journal of Advanced Computer Science and Applications*, vol. 11, n.º 6, 2020. DOI: 10.14569/IJACSA.2020.0110672. dirección: <http://dx.doi.org/10.14569/IJACSA.2020.0110672>.
- [88] L. B. Shyamasundar y P. Jhansi Rani, «A Multiple-Layer Machine Learning Architecture for Improved Accuracy in Sentiment Analysis,» *The Computer Journal*, vol. 63, n.º 3, págs. 395-409, abr. de 2019, ISSN: 0010-4620. DOI: 10.1093/comjnl/bxz038. eprint: <https://academic.oup.com/comjnl/article-pdf/63/3/395/33106408/bxz038.pdf>. dirección: <https://doi.org/10.1093/comjnl/bxz038>.
- [89] B. Metin y H. Köktas, «Sentiment analysis with term weighting and word vectors,» *Int. Arab J. Inf. Technol.*, vol. 16, págs. 953-959, 2019.
- [90] M. B. Alvi, N. A. Mahoto, M. A. Unar y M. A. Shaikh, «An Effective Framework for Tweet Level Sentiment Classification using Recursive Text Pre-Processing Approach,» *International Journal of Advanced Computer Science and Applications*, vol. 10, n.º 6, 2019. DOI: 10.14569/IJACSA.2019.0100674. dirección: <http://dx.doi.org/10.14569/IJACSA.2019.0100674>.
- [91] D. Gamal, M. Alfonse, E.-S. M. El-Horbaty y A.-B. M. Salem, «Analysis of Machine Learning Algorithms for Opinion Mining in Different Domains,» *Machine Learning and Knowledge Extraction*, vol. 1, n.º 1, págs. 224-234, 2019, ISSN: 2504-4990. DOI: 10.3390/make1010014. dirección: <https://www.mdpi.com/2504-4990/1/1/14>.
- [92] M. Ghosh y G. Sanyal, «Analysing sentiments based on multi feature combination with supervised learning,» *International Journal of Data Mining, Modelling and Management*, vol. 11, n.º 4, págs. 391-416, 2019. DOI: 10.1504/IJDM.2019.102728.

- [93] G. Ghosh Monalisa and Sanyal, «An ensemble approach to stabilize the features for multi-domain sentiment analysis using supervised machine learning,» *Journal of Big Data*, vol. 5, n.º 1, pág. 44, nov. de 2018, ISSN: 2196-1115. DOI: 10.1186/s40537-018-0152-5. dirección: <https://doi.org/10.1186/s40537-018-0152-5>.
- [94] S. Alowaidi, M. Saleh y O. Abulnaja, «Semantic Sentiment Analysis of Arabic Texts,» *International Journal of Advanced Computer Science and Applications*, vol. 8, n.º 2, 2017. DOI: 10.14569/IJACSA.2017.080234. dirección: <http://dx.doi.org/10.14569/IJACSA.2017.080234>.
- [95] A. B. Nassif, A. M. Darya y A. Elnagar, «Empirical Evaluation of Shallow and Deep Learning Classifiers for Arabic Sentiment Analysis,» *ACM Trans. Asian Low-Resour. Lang. Inf. Process.*, vol. 21, n.º 1, nov. de 2021, ISSN: 2375-4699. DOI: 10.1145/3466171. dirección: <https://doi.org/10.1145/3466171>.
- [96] S. Ranjan y S. Mishra, «Perceiving university students' opinions from Google app reviews,» *Concurrency and Computation: Practice and Experience*, vol. 34, n.º 10, e6800, 2022. DOI: <https://doi.org/10.1002/cpe.6800>. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/cpe.6800>. dirección: <https://onlinelibrary.wiley.com/doi/abs/10.1002/cpe.6800>.
- [97] A. K. Durairaj y A. Chinnalagu, «Transformer based Contextual Model for Sentiment Analysis of Customer Reviews: A Fine-tuned BERT,» *International Journal of Advanced Computer Science and Applications*, vol. 12, n.º 11, 2021. DOI: 10.14569/IJACSA.2021.0121153. dirección: <http://dx.doi.org/10.14569/IJACSA.2021.0121153>.
- [98] S. M. Mohamed, E. H. Mohamed y M. A. Belal, «Polarity Detection of Dialectal Arabic using Deep Learning Models,» *International Journal of Advanced Computer Science and Applications*, vol. 12, n.º 11, 2021. DOI: 10.14569/IJACSA.2021.0121125. dirección: <http://dx.doi.org/10.14569/IJACSA.2021.0121125>.
- [99] A. K. J, T. E. Trueman y E. Cambria, «A Convolutional Stacked Bidirectional LSTM with a Multiplicative Attention Mechanism for Aspect Category and Sentiment Detection,» *Cognitive Computation*, vol. 13, n.º 6, págs. 1423-1432, nov. de 2021, ISSN: 1866-9964. DOI: 10.1007/s12559-021-09948-0. dirección: <https://doi.org/10.1007/s12559-021-09948-0>.
- [100] P. K. Jain, V. Saravanan y R. Pamula, «A Hybrid CNN-LSTM: A Deep Learning Approach for Consumer Sentiment Analysis Using Qualitative User-Generated Contents,» *ACM Trans. Asian Low-Resour. Lang. Inf. Process.*, vol. 20, n.º 5, jul. de 2021, ISSN: 2375-4699. DOI: 10.1145/3457206. dirección: <https://doi.org/10.1145/3457206>.
- [101] S. Sagnika, B. S. P. Mishra y S. K. Meher, «An attention-based CNN-LSTM model for subjectivity detection in opinion-mining,» *Neural Computing and Applications*, vol. 33, n.º 24, págs. 17425-17438, dic. de 2021, ISSN: 1433-3058. DOI: 10.1007/s00521-021-06328-5. dirección: <https://doi.org/10.1007/s00521-021-06328-5>.

- [102] N. Jamal, C. Xianqiao, F. Al-Turjman y F. Ullah, «A Deep Learning–Based Approach for Emotions Classification in Big Corpus of Imbalanced Tweets,» *ACM Trans. Asian Low-Resour. Lang. Inf. Process.*, vol. 20, n.º 3, mar. de 2021, ISSN: 2375-4699. DOI: 10.1145/3410570. dirección: <https://doi.org/10.1145/3410570>.
- [103] A. R. Pathak, M. Pandey y S. Rautaray, «Topic-level sentiment analysis of social media data using deep learning,» *Applied Soft Computing*, vol. 108, pág. 107 440, 2021, ISSN: 1568-4946. DOI: <https://doi.org/10.1016/j.asoc.2021.107440>. dirección: <https://www.sciencedirect.com/science/article/pii/S156849462100363X>.
- [104] O. Coban, S. A. Ozel y A. Inan, «Deep Learning-based Sentiment Analysis of Facebook Data: The Case of Turkish Users,» *The Computer Journal*, vol. 64, n.º 3, págs. 473-499, ene. de 2021, ISSN: 0010-4620. DOI: 10.1093/comjnl/bxaa172. eprint: <https://academic.oup.com/comjnl/article-pdf/64/3/473/41430049/bxaa172.pdf>. dirección: <https://doi.org/10.1093/comjnl/bxaa172>.
- [105] M. E. Basiri, S. Nemati, M. Abdar, E. Cambria y U. R. Acharya, «ABCDM: An Attention-based Bidirectional CNN-RNN Deep Model for sentiment analysis,» *Future Generation Computer Systems*, vol. 115, págs. 279-294, 2021, ISSN: 0167-739X. DOI: <https://doi.org/10.1016/j.future.2020.08.005>. dirección: <https://www.sciencedirect.com/science/article/pii/S0167739X20309195>.
- [106] H. Elfaik y E. H. Nfaoui, «Deep Bidirectional LSTM Network Learning-Based Sentiment Analysis for Arabic Text,» *Journal of Intelligent Systems*, vol. 30, n.º 1, págs. 395-412, 2021. DOI: doi : 10 . 1515 / jisys - 2020 - 0021. dirección: <https://doi.org/10.1515/jisys-2020-0021>.
- [107] R. Ranjan y D. AK., «A Proposed Hybrid model for Sentiment Classification using CovNet-DualLSTM Techniques,» en, *ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal*, vol. 10, n.º 4, págs. 401-418, 2021.
- [108] G. Singh Chauhan, Y. Kumar Meena, D. Gopalani y R. Nahta, «A two-step hybrid unsupervised model with attention mechanism for aspect extraction,» *Expert Systems with Applications*, vol. 161, pág. 113673, 2020, ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2020.113673>. dirección: <https://www.sciencedirect.com/science/article/pii/S0957417420304978>.
- [109] M. Umer, I. Ashraf, A. Mehmood, S. Kumari, S. Ullah y G. Sang Choi, «Sentiment analysis of tweets using a unified convolutional neural network-long short-term memory network model,» *Computational Intelligence*, vol. 37, n.º 1, págs. 409-434, 2021. DOI: <https://doi.org/10.1111/coin.12415>. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1111/coin.12415>. dirección: <https://onlinelibrary.wiley.com/doi/abs/10.1111/coin.12415>.
- [110] M. Atzeni y D. R. Recupero, «Multi-domain sentiment analysis with mimicked and polarized word embeddings for human–robot interaction,» *Future Generation Computer Systems*, vol. 110, págs. 984-999, 2020, ISSN: 0167-739X. DOI: <https://doi.org/10.1016/j.future.2019.10.012>. dirección: <https://www.sciencedirect.com/science/article/pii/S0167739X19309719>.

- [111] H.-T. Nguyen y L.-M. Nguyen, «ILWAANet: An Interactive Lexicon-Aware Word-Aspect Attention Network for aspect-level sentiment classification on social networking,» *Expert Systems with Applications*, vol. 146, pág. 113 065, 2020, ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2019.113065>. dirección: <https://www.sciencedirect.com/science/article/pii/S0957417419307821>.
- [112] D. Sangeetha K.and Prabha, «RETRACTED ARTICLE: Sentiment analysis of student feedback using multi-head attention fusion model of word and context embedding for LSTM,» *Journal of Ambient Intelligence and Humanized Computing*, vol. 12, n.º 3, págs. 4117-4126, mar. de 2021, ISSN: 1868-5145. DOI: 10.1007/s12652-020-01791-9. dirección: <https://doi.org/10.1007/s12652-020-01791-9>.
- [113] S.-T. Park, D.-Y. Kim y G. Li, «An analysis of environmental big data through the establishment of emotional classification system model based on machine learning: focus on multimedia contents for portal applications,» *Multimedia Tools and Applications*, vol. 80, n.º 26, págs. 34 459-34 477, nov. de 2021, ISSN: 1573-7721. DOI: 10.1007/s11042-020-08818-5. dirección: <https://doi.org/10.1007/s11042-020-08818-5>.
- [114] R. Piryani, B. Piryani, V. K. Singh y D. Pinto, «Sentiment analysis in Nepali: Exploring machine learning and lexicon-based approaches,» *Journal of Intelligent & Fuzzy Systems*, vol. 39, págs. 2201-2212, 2020, 2, ISSN: 1875-8967. DOI: 10.3233/JIFS-179884. dirección: <https://doi.org/10.3233/JIFS-179884>.
- [115] S. Soubaylu y R. Rajalakshmi, «Hybrid convolutional bidirectional recurrent neural network based sentiment analysis on movie reviews,» *Computational Intelligence*, vol. 37, n.º 2, págs. 735-757, 2021. DOI: <https://doi.org/10.1111/coin.12400>. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1111/coin.12400>. dirección: <https://onlinelibrary.wiley.com/doi/abs/10.1111/coin.12400>.
- [116] F. Es-Sabery, A. Hair, J. Qadir, B. Sainz-De-Abajo, B. García-Zapirain e I. D. L. Torre-Díez, «Sentence-Level Classification Using Parallel Fuzzy Deep Learning Classifier,» *IEEE Access*, vol. 9, págs. 17 943-17 985, 2021. DOI: 10.1109/ACCESS.2021.3053917.
- [117] R. Divyapushpalakshmi M.and Ramalakshmi, «An efficient sentimental analysis using hybrid deep learning and optimization technique for Twitter using parts of speech (POS) tagging,» *International Journal of Speech Technology*, vol. 24, n.º 2, págs. 329-339, jun. de 2021, ISSN: 1572-8110. DOI: 10.1007/s10772-021-09801-7. dirección: <https://doi.org/10.1007/s10772-021-09801-7>.
- [118] R. K. Behera, M. Jena, S. K. Rath y S. Misra, «Co-LSTM: Convolutional LSTM model for sentiment analysis in social big data,» *Information Processing and Management*, vol. 58, n.º 1, pág. 102 435, 2021, ISSN: 0306-4573. DOI: <https://doi.org/10.1016/j.ipm.2020.102435>. dirección: <https://www.sciencedirect.com/science/article/pii/S0306457320309286>.

- [119] S. H. Janjua, G. F. Siddiqui, M. A. Sindhu y U. Rashid, «Multi-level aspect based sentiment classification of Twitter data: using hybrid approach in deep learning,» *PeerJ Computer Science*, vol. 7, e433, abr. de 2021, ISSN: 2376-5992. DOI: 10.7717/peerj-cs.433. dirección: <https://doi.org/10.7717/peerj-cs.433>.
- [120] H. S. Sharaf Al-deen, Z. Zeng, R. Al-sabri y A. Hekmat, «An Improved Model for Analyzing Textual Sentiment Based on a Deep Neural Network Using Multi-Head Attention Mechanism,» *Applied System Innovation*, vol. 4, n.º 4, 2021, ISSN: 2571-5577. DOI: 10.3390/asi4040085. dirección: <https://www.mdpi.com/2571-5577/4/4/85>.
- [121] C. Singla, F. N. Al-Wesabi, Y. S. Pathania et al., «An Optimized Deep Learning Model for Emotion Classification in Tweets,» *Computers, Materials & Continua*, vol. 70, n.º 3, págs. 6365-6380, 2022, ISSN: 1546-2226. DOI: 10.32604/cmc.2022.020480. dirección: <http://www.techscience.com/cmc/v70n3/44965>.
- [122] K. L. Tan, C. P. Lee, K. S. M. Anbananthen y K. M. Lim, «RoBERTa-LSTM: A Hybrid Model for Sentiment Analysis With Transformer and Recurrent Neural Network,» *IEEE Access*, vol. 10, págs. 21 517-21 525, 2022. DOI: 10.1109/ACCESS.2022.3152828.
- [123] R. A. Saleh, M. Driss e I. Almomani, «CBiLSTM: A Hybrid Deep Learning Model for Efficient Reputation Assessment of Cloud Services,» *IEEE Access*, vol. 10, págs. 35 321-35 335, 2022. DOI: 10.1109/ACCESS.2022.3163246.
- [124] Y. Didi, A. Walha y A. Wali, «COVID-19 Tweets Classification Based on a Hybrid Word Embedding Method,» *Big Data and Cognitive Computing*, vol. 6, n.º 2, 2022, ISSN: 2504-2289. DOI: 10.3390/bdcc6020058. dirección: <https://www.mdpi.com/2504-2289/6/2/58>.
- [125] O. Iparraguirre-Villanueva, V. Guevara-Ponce, F. Sierra-Linan, S. Beltozar-Clemente y M. Cabanillas-Carbonell, «Sentiment Analysis of Tweets using Unsupervised Learning Techniques and the K-Means Algorithm,» *International Journal of Advanced Computer Science and Applications*, vol. 13, n.º 6, 2022. DOI: 10.14569/IJACSA.2022.0130669. dirección: <http://dx.doi.org/10.14569/IJACSA.2022.0130669>.
- [126] I. Steinke, J. Wier, L. Simon y R. Seetan, «Sentiment Analysis of Online Movie Reviews using Machine Learning,» *International Journal of Advanced Computer Science and Applications*, vol. 13, n.º 9, 2022. DOI: 10.14569/IJACSA.2022.0130973. dirección: <http://dx.doi.org/10.14569/IJACSA.2022.0130973>.
- [127] M. Purba, E. Ermatita, A. Abdiansah et al., «Effect of Random Splitting and Cross Validation for Indonesian Opinion Mining using Machine Learning Approach,» *International Journal of Advanced Computer Science and Applications*, vol. 13, n.º 9, 2022. DOI: 10.14569/IJACSA.2022.0130917. dirección: <http://dx.doi.org/10.14569/IJACSA.2022.0130917>.
- [128] A. Alsanad, «An Improved Arabic Sentiment Analysis Approach using Optimized Multinomial Naïve Bayes Classifier,» *International Journal of Advanced Computer Science and Applications*, vol. 13, n.º 8, 2022. DOI: 10.14569/IJACSA.2022.0130812. dirección: <http://dx.doi.org/10.14569/IJACSA.2022.0130812>.

- [129] W. Aljedaani, F. Rustam, M. W. Mkaouer et al., «Sentiment analysis on Twitter data integrating TextBlob and deep learning models: The case of US airline industry,» *Knowledge-Based Systems*, vol. 255, pág. 109780, 2022, ISSN: 0950-7051. DOI: <https://doi.org/10.1016/j.knosys.2022.109780>. dirección: <https://www.sciencedirect.com/science/article/pii/S0950705122009017>.
- [130] M. Arbane, R. Benlamri, Y. Brik y A. D. Alahmar, «Social media-based COVID-19 sentiment classification model using Bi-LSTM,» *Expert Systems with Applications*, vol. 212, pág. 118710, 2023, ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2022.118710>. dirección: <https://www.sciencedirect.com/science/article/pii/S0957417422017353>.
- [131] M. Venugopalan y D. Gupta, «A reinforced active learning approach for optimal sampling in aspect term extraction for sentiment analysis,» *Expert Systems with Applications*, vol. 209, pág. 118228, 2022, ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2022.118228>. dirección: <https://www.sciencedirect.com/science/article/pii/S0957417422013793>.
- [132] V. Jain y K. L. Kashyap, «Ensemble hybrid model for Hindi COVID-19 text classification with metaheuristic optimization algorithm,» *Multimedia Tools and Applications*, oct. de 2022, ISSN: 1573-7721. DOI: 10.1007/s11042-022-13937-2. dirección: <https://doi.org/10.1007/s11042-022-13937-2>.
- [133] R. Dutta, N. Das, M. Majumder y B. Jana, «Aspect based sentiment analysis using multi-criteria decision-making and deep learning under COVID-19 pandemic in India,» *CAAI Transactions on Intelligence Technology*, vol. n/a, n.º n/a, DOI: <https://doi.org/10.1049/cit2.12144>.
- [134] S. Aslan, «A novel TCNN–Bi-LSTM deep learning model for predicting sentiments of tweets about COVID-19 vaccines,» *Concurrency and Computation: Practice and Experience*, vol. 34, n.º 28, e7387, 2022. DOI: <https://doi.org/10.1002/cpe.7387>. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/cpe.7387>. dirección: <https://onlinelibrary.wiley.com/doi/abs/10.1002/cpe.7387>.
- [135] D. C. Neagu, A. B. Rus, M. Grec, M. A. Boroianu, N. Bogdan y A. Gal, «Towards Sentiment Analysis for Romanian Twitter Content,» *Algorithms*, vol. 15, n.º 10, 2022, ISSN: 1999-4893. DOI: 10.3390/a15100357. dirección: <https://www.mdpi.com/1999-4893/15/10/357>.
- [136] A. Pimpalkar y J. R. Raj R, «MBiLSTM GloVe: Embedding GloVe knowledge into the corpus using multi-layer BiLSTM deep learning model for social media sentiment analysis,» *Expert Systems with Applications*, vol. 203, pág. 117581, 2022, ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2022.117581>. dirección: <https://www.sciencedirect.com/science/article/pii/S0957417422008946>.
- [137] A. Diwali, K. Dashtipour, K. Saeedi, M. Gogate, E. Cambria y A. Hussain, «Arabic sentiment analysis using dependency-based rules and deep neural networks,» *Applied Soft Computing*, vol. 127, pág. 109377, 2022, ISSN: 1568-4946. DOI: <https://doi.org/10.1016/j.asoc.2022.109377>. dirección: <https://www.sciencedirect.com/science/article/pii/S1568494622005269>.

- [138] R. E. Saady, A. E. D. M. El-Ghazaly, E. S. Nasr y M. H. Gheith, «A Novel Hybrid Sentiment Analysis Classification Approach for Mobile Applications Arabic Slang Reviews,» *International Journal of Advanced Computer Science and Applications*, vol. 13, n.º 8, 2022. DOI: 10.14569/IJACSA.2022.0130849. dirección: <http://dx.doi.org/10.14569/IJACSA.2022.0130849>.
- [139] J.-W. Lin, T. D. Thanh y R.-G. Chang, «Multi-channel word embeddings for sentiment analysis,» *Soft Computing*, vol. 26, n.º 22, págs. 12703-12715, nov. de 2022, ISSN: 1433-7479. DOI: 10.1007/s00500-022-07267-6. dirección: <https://doi.org/10.1007/s00500-022-07267-6>.
- [140] K. L. Tan, C. P. Lee, K. M. Lim y K. S. M. Anbananthen, «Sentiment Analysis With Ensemble Hybrid Deep Learning Model,» *IEEE Access*, vol. 10, págs. 103694-103704, 2022. DOI: 10.1109/ACCESS.2022.3210182.
- [141] V. Kumar, «Spatiotemporal sentiment variation analysis of geotagged COVID-19 tweets from India using a hybrid deep learning model,» *Scientific Reports*, vol. 12, n.º 1, pág. 1849, feb. de 2022, ISSN: 2045-2322. DOI: 10.1038/s41598-022-05974-6. dirección: <https://doi.org/10.1038/s41598-022-05974-6>.
- [142] A. Londhe y P. V. R. D. P. Rao, «Incremental Learning based Optimized Sentiment Classification using Hybrid Two-Stage LSTM-SVM Classifier,» *International Journal of Advanced Computer Science and Applications*, vol. 13, n.º 6, 2022. DOI: 10.14569/IJACSA.2022.0130674. dirección: <http://dx.doi.org/10.14569/IJACSA.2022.0130674>.
- [143] E. Omara, M. Mousa y N. Ismail, «Character gated recurrent neural networks for Arabic sentiment analysis,» *Scientific Reports*, vol. 12, n.º 1, pág. 9779, jun. de 2022, ISSN: 2045-2322. DOI: 10.1038/s41598-022-13153-w. dirección: <https://doi.org/10.1038/s41598-022-13153-w>.
- [144] K. Shanmugavadivel, S. H. Sampath, P. Nandhakumar et al., «An analysis of machine learning models for sentiment analysis of Tamil code-mixed data,» *Computer Speech & Language*, vol. 76, pág. 101407, 2022, ISSN: 0885-2308. DOI: <https://doi.org/10.1016/j.cs1.2022.101407>. dirección: <https://www.sciencedirect.com/science/article/pii/S0885230822000420>.
- [145] M. Karim, M. M. Saad Missen, M. Umer et al., «Comprehension of polarity of articles by citation sentiment analysis using TF-IDF and ML classifiers,» *PeerJ Computer Science*, vol. 8, e1107, dic. de 2022, ISSN: 2376-5992. DOI: 10.7717/peerj-cs.1107. dirección: <https://doi.org/10.7717/peerj-cs.1107>.
- [146] N. Aslam, K. Xia, F. Rustam, E. Lee e I. Ashraf, «Self voting classification model for online meeting app review sentiment analysis and topic modeling,» *PeerJ Computer Science*, vol. 8, e1141, dic. de 2022, ISSN: 2376-5992. DOI: 10.7717/peerj-cs.1141. dirección: <https://doi.org/10.7717/peerj-cs.1141>.
- [147] A. Karanikola, G. Davrazos, C. M. Liapis y S. Kotsiantis, «Financial sentiment analysis: Classic methods vs. deep learning models,» *Intelligent Decision Technologies*, vol. 17, págs. 893-915, 2023, 4, ISSN: 1875-8843. DOI: 10.3233/IDT-230478. dirección: <https://doi.org/10.3233/IDT-230478>.

- [148] S. Ounacer, D. Mhamdi, S. Ardchir, A. Daif y M. Azzouazi, «Customer Sentiment Analysis in Hotel Reviews Through Natural Language Processing Techniques,» *International Journal of Advanced Computer Science and Applications*, vol. 14, n.º 1, 2023. DOI: 10.14569/IJACSA.2023.0140162. dirección: <http://dx.doi.org/10.14569/IJACSA.2023.0140162>.
- [149] M. Sha, «A Cloud Based Sentiment Analysis through Logistic Regression in AWS Platform,» *Computer Systems Science and Engineering*, vol. 45, n.º 1, págs. 857-868, 2023. DOI: 10.32604/csse.2023.031321. dirección: <http://www.techscience.com/csse/v45n1/49346>.
- [150] N. E. Aoumeur, Z. Li y E. M. Alshari, «Improving the Polarity of Text through word2vec Embedding for Primary Classical Arabic Sentiment Analysis,» *Neural Processing Letters*, vol. 55, n.º 3, págs. 2249-2264, jun. de 2023, ISSN: 1573-773X. DOI: 10.1007/s11063-022-11111-1. dirección: <https://doi.org/10.1007/s11063-022-11111-1>.
- [151] M. Errami, M. A. Ouassil, R. Rachidi, B. Cherradi, S. Hamida y A. Raihani, «Sentiment Analysis on Moroccan Dialect based on ML and Social Media Content Detection,» *INTERNATIONAL JOURNAL OF ADVANCED COMPUTER SCIENCE AND APPLICATIONS*, vol. 14, n.º 3, págs. 415-425, mar. de 2023.
- [152] M. A. Virgananda, I. Budi, Kamrozi y R. R. Suryono, «Purchase Intention and Sentiment Analysis on Twitter Related to Social Commerce,» *International Journal of Advanced Computer Science and Applications*, vol. 14, n.º 7, 2023. DOI: 10.14569/IJACSA.2023.0140760. dirección: <http://dx.doi.org/10.14569/IJACSA.2023.0140760>.
- [153] D. A. Musleh, I. Alkhwaja, A. Alkhwaja et al., «Arabic Sentiment Analysis of YouTube Comments: NLP-Based Machine Learning Approaches for Content Evaluation,» *Big Data and Cognitive Computing*, vol. 7, n.º 3, 2023, ISSN: 2504-2289. DOI: 10.3390/bdcc7030127. dirección: <https://www.mdpi.com/2504-2289/7/3/127>.
- [154] R. Dutta, N. Das, M. Majumder y B. Jana, «Aspect based sentiment analysis using multi-criteria decision-making and deep learning under COVID-19 pandemic in India,» *CAAI Transactions on Intelligence Technology*, vol. 8, n.º 1, págs. 219-234, 2023. DOI: <https://doi.org/10.1049/cit2.12144>. eprint: <https://ietresearch.onlinelibrary.wiley.com/doi/pdf/10.1049/cit2.12144>. dirección: <https://ietresearch.onlinelibrary.wiley.com/doi/abs/10.1049/cit2.12144>.
- [155] C. Yan, J. Liu, W. Liu y X. Liu, «Sentiment Analysis and Topic Mining Using a Novel Deep Attention-Based Parallel Dual-Channel Model for Online Course Reviews,» *Cognitive Computation*, vol. 15, n.º 1, págs. 304-322, ene. de 2023, ISSN: 1866-9964. DOI: 10.1007/s12559-022-10083-7. dirección: <https://doi.org/10.1007/s12559-022-10083-7>.
- [156] M. M. Abdelgwad, T. H. A. Soliman y A. I. Taloba, «Arabic aspect sentiment polarity classification using BERT,» *Journal of Big Data*, vol. 9, n.º 1, pág. 115, dic. de 2022, ISSN: 2196-1115. DOI: 10.1186/s40537-022-00656-6. dirección: <https://doi.org/10.1186/s40537-022-00656-6>.

- [157] M. M. Samia, A. Rajee, M. R. Hasan, M. O. Faruq y P. C. Paul, «Aspect-based Sentiment Analysis for Bengali Text using Bidirectional Encoder Representations from Transformers (BERT),» *International Journal of Advanced Computer Science and Applications*, vol. 13, n.º 12, 2022. DOI: 10.14569/IJACSA.2022.01312112. dirección: <http://dx.doi.org/10.14569/IJACSA.2022.01312112>.
- [158] M. AL-Smadi, M. M. Hammad, S. A. Al-Zboon, S. AL-Tawalbeh y E. Cambria, «Gated recurrent unit with multilingual universal sentence encoder for Arabic aspect-based sentiment analysis,» *Knowledge-Based Systems*, vol. 261, pág. 107540, 2023, ISSN: 0950-7051. DOI: <https://doi.org/10.1016/j.knosys.2021.107540>. dirección: <https://www.sciencedirect.com/science/article/pii/S0950705121008029>.
- [159] M. Qorich y R. El Ouazzani, «Text sentiment classification of Amazon reviews using word embeddings and convolutional neural networks,» *The Journal of Supercomputing*, vol. 79, n.º 10, págs. 11029-11054, jul. de 2023, ISSN: 1573-0484. DOI: 10.1007/s11227-023-05094-6. dirección: <https://doi.org/10.1007/s11227-023-05094-6>.
- [160] A. Siagh, F. Z. Laallam, O. Kazar y H. Salem, «An improved sentiment classification model based on data quality and word embeddings,» *The Journal of Supercomputing*, vol. 79, n.º 11, págs. 11871-11894, jul. de 2023, ISSN: 1573-0484. DOI: 10.1007/s11227-023-05099-1. dirección: <https://doi.org/10.1007/s11227-023-05099-1>.
- [161] A. Alqarni y A. Rahman, «Arabic Tweets-Based Sentiment Analysis to Investigate the Impact of COVID-19 in KSA: A Deep Learning Approach,» *Big Data and Cognitive Computing*, vol. 7, n.º 1, 2023, ISSN: 2504-2289. DOI: 10.3390/bdcc7010016. dirección: <https://www.mdpi.com/2504-2289/7/1/16>.
- [162] H. Said, B. S. Tawfik y M. A. Makhoul, «A Deep Learning Approach for Sentiment Classification of COVID-19 Vaccination Tweets,» *International Journal of Advanced Computer Science and Applications*, vol. 14, n.º 4, 2023. DOI: 10.14569/IJACSA.2023.0140458. dirección: <http://dx.doi.org/10.14569/IJACSA.2023.0140458>.
- [163] N. Parveen, P. Chakrabarti, B. T. Hung y A. Shaik, «Twitter sentiment analysis using hybrid gated attention recurrent network,» *Journal of Big Data*, vol. 10, n.º 1, pág. 50, abr. de 2023, ISSN: 2196-1115. DOI: 10.1186/s40537-023-00726-3. dirección: <https://doi.org/10.1186/s40537-023-00726-3>.
- [164] C. V. Loc, T. X. Viet, T. H. Viet, L. H. Thao y N. H. Viet, «Pre-Trained Language Model-Based Deep Learning for Sentiment Classification of Vietnamese Feedback,» *International Journal of Computational Intelligence and Applications*, vol. 22, n.º 03, pág. 2350016, 2023. DOI: 10.1142/S1469026823500165. eprint: <https://doi.org/10.1142/S1469026823500165>. dirección: <https://doi.org/10.1142/S1469026823500165>.

- [165] D. A. J. Daniel y M. J. Meena, «Deep learning-based hybrid sentiment analysis with feature selection using optimization algorithm,» *Multimedia Tools and Applications*, vol. 82, n.º 28, págs. 43 273-43 296, nov. de 2023, ISSN: 1573-7721. DOI: 10.1007/s11042-023-14767-6. dirección: <https://doi.org/10.1007/s11042-023-14767-6>.
- [166] A. Baqach y A. Battou, «CLAS: A new deep learning approach for sentiment analysis from Twitter data,» *Multimedia Tools and Applications*, vol. 82, n.º 30, págs. 47 457-47 475, dic. de 2023, ISSN: 1573-7721. DOI: 10.1007/s11042-023-15784-1. dirección: <https://doi.org/10.1007/s11042-023-15784-1>.
- [167] S. Aslan, «A deep learning-based sentiment analysis approach (MF-CNN-BILSTM) and topic modeling of tweets related to the Ukraine–Russia conflict,» *Applied Soft Computing*, vol. 143, pág. 110 404, 2023, ISSN: 1568-4946. DOI: <https://doi.org/10.1016/j.asoc.2023.110404>. dirección: <https://www.sciencedirect.com/science/article/pii/S1568494623004222>.
- [168] Y. Zahidi, Y. Al-Amrani e Y. El Younoussi, «Improving Arabic Sentiment Analysis Using LSTM Based on Word Embedding Models,» *Vietnam Journal of Computer Science*, vol. 10, n.º 03, págs. 391-407, 2023. DOI: 10.1142/S2196888823500069. eprint: <https://doi.org/10.1142/S2196888823500069>. dirección: <https://doi.org/10.1142/S2196888823500069>.
- [169] J. Cao, J. Li, M. Yin e Y. Wang, «Online Reviews Sentiment Analysis and Product Feature Improvement with Deep Learning,» *ACM Trans. Asian Low-Resour. Lang. Inf. Process.*, vol. 22, n.º 8, ago. de 2023, ISSN: 2375-4699. DOI: 10.1145/3522575. dirección: <https://doi.org/10.1145/3522575>.
- [170] S. Angamuthu y P. Trojovský, «Integrating multi-criteria decision-making with hybrid deep learning for sentiment analysis in recommender systems,» *PeerJ Computer Science*, vol. 9, e1497, ago. de 2023, ISSN: 2376-5992. DOI: 10.7717/peerj-cs.1497. dirección: <https://doi.org/10.7717/peerj-cs.1497>.
- [171] K. K. Mohbey, G. Meena, S. Kumar y K. Lokesh, «A CNN-LSTM-Based Hybrid Deep Learning Approach for Sentiment Analysis on Monkeypox Tweets,» *New Generation Computing*, ago. de 2023, ISSN: 1882-7055. DOI: 10.1007/s00354-023-00227-0. dirección: <https://doi.org/10.1007/s00354-023-00227-0>.
- [172] N. Habbat, H. Nouri, H. Anoun y L. Hassouni, «Sentiment analysis of imbalanced datasets using BERT and ensemble stacking for deep learning,» *Engineering Applications of Artificial Intelligence*, vol. 126, pág. 106 999, 2023, ISSN: 0952-1976. DOI: <https://doi.org/10.1016/j.engappai.2023.106999>. dirección: <https://www.sciencedirect.com/science/article/pii/S0952197623011831>.
- [173] L. Dang, C. Wang, M.-H. Tsou, Y.-e. Hou y H. Han, «Sentiment analysis of COVID-19 related social distancing using twitter data based on deep learning,» *Multimedia Tools and Applications*, vol. 83, n.º 11, págs. 32 587-32 612, mar. de 2024, ISSN: 1573-7721. DOI: 10.1007/s11042-023-17011-3. dirección: <https://doi.org/10.1007/s11042-023-17011-3>.

- [174] M. S. Ba ĉarslan y F. Kayaalp, «Sentiment analysis using a deep ensemble learning model,» *Multimedia Tools and Applications*, oct. de 2023, ISSN: 1573-7721. DOI: 10.1007/s11042-023-17278-6. direcci3n: <https://doi.org/10.1007/s11042-023-17278-6>.
- [175] M. Wankhade, C. S. R. Annavarapu y A. Abraham, «CBMAFM: CNN-BiLSTM Multi-Attention Fusion Mechanism for sentiment classification,» *Multimedia Tools and Applications*, nov. de 2023, ISSN: 1573-7721. DOI: 10.1007/s11042-023-17437-9. direcci3n: <https://doi.org/10.1007/s11042-023-17437-9>.
- [176] R. Ghasemi y S. Momtazi, «How a Deep Contextualized Representation and Attention Mechanism Justifies Explainable Cross-Lingual Sentiment Analysis,» *ACM Trans. Asian Low-Resour. Lang. Inf. Process.*, vol. 22, n.º 11, nov. de 2023, ISSN: 2375-4699. DOI: 10.1145/3626094. direcci3n: <https://doi.org/10.1145/3626094>.
- [177] I. N. Yulita, A. F. Al-Auza'i, A. S. Prabuwo et al., «Bidirectional Long Short-Term Memory for Analysis of Public Opinion Sentiment on Government Policy During the COVID-19 Pandemic,» *International Journal of Advanced Computer Science and Applications*, vol. 14, n.º 11, 2023. DOI: 10.14569/IJACSA.2023.0141189. direcci3n: <http://dx.doi.org/10.14569/IJACSA.2023.0141189>.
- [178] W. Chang y M. Zhu, «Sentiment analysis method of consumer comment text based on BERT and hierarchical attention in e-commerce big data environment,» *Journal of Intelligent Systems*, vol. 32, n.º 1, p3g. 20 230 025, 2023. DOI: doi:10.1515/jisys-2023-0025. direcci3n: <https://doi.org/10.1515/jisys-2023-0025>.
- [179] H. Murfi, Syamsyuriani, T. Gowandi, G. Ardaneswari y S. Nurrohmah, «BERT-based combination of convolutional and recurrent neural network for indonesian sentiment analysis,» *Applied Soft Computing*, vol. 151, p3g. 111 112, 2024, ISSN: 1568-4946. DOI: <https://doi.org/10.1016/j.asoc.2023.111112>. direcci3n: <https://www.sciencedirect.com/science/article/pii/S1568494623011304>.
- [180] V. Jain y K. L. Kashyap, «Ensemble hybrid model for Hindi COVID-19 text classification with metaheuristic optimization algorithm,» *Multimedia Tools and Applications*, vol. 82, n.º 11, p3gs. 16 839-16 859, mayo de 2023, ISSN: 1573-7721. DOI: 10.1007/s11042-022-13937-2. direcci3n: <https://doi.org/10.1007/s11042-022-13937-2>.
- [181] I. Kanwal, F. Wahid, S. Ali, A.-U. Rehman, A. Alkhayyat y A. Al-Radaei, «Sentiment Analysis Using Hybrid Model of Stacked Auto-Encoder-Based Feature Extraction and Long Short Term Memory-Based Classification Approach,» *IEEE Access*, vol. 11, p3gs. 124 181-124 197, 2023. DOI: 10.1109/ACCESS.2023.3313189.
- [182] P. Thiengburanathum y P. Charoenkwan, «SETAR: Stacking Ensemble Learning for Thai Sentiment Analysis Using RoBERTa and Hybrid Feature Representation,» *IEEE Access*, vol. 11, p3gs. 92 822-92 837, 2023. DOI: 10.1109/ACCESS.2023.3308951.
- [183] C. Ahle Touate, R. El Ayachi y M. Biniz, «Classification of Sentiment Using Optimized Hybrid Deep Learning Model,» *COMPUTING AND INFORMATICS*, vol. 42, n.º 3, p3gs. 651-666, ago. de 2023. DOI: 10.31577/cai\_2023\_3\_651. direcci3n: [https://www.cai.sk/ojs/index.php/cai/article/view/2023\\_3\\_651](https://www.cai.sk/ojs/index.php/cai/article/view/2023_3_651).

- [184] J. Khan, N. Ahmad, S. Khalid, F. Ali e Y. Lee, «Sentiment and Context-Aware Hybrid DNN With Attention for Text Sentiment Classification,» *IEEE Access*, vol. 11, págs. 28 162-28 179, 2023. DOI: 10.1109/ACCESS.2023.3259107.
- [185] B. B. Al-onazi, A. Q. A. Hassan, M. K. Nour et al., «Quantum Particle Swarm Optimization with Deep Learning-Based Arabic Tweets Sentiment Analysis,» *Computers, Materials & Continua*, vol. 75, n.º 2, págs. 2575-2591, 2023, ISSN: 1546-2226. DOI: 10.32604/cmc.2023.033531. dirección: <http://www.techscience.com/cmc/v75n2/52029>.
- [186] W. Ahmad, H. U. Khan, T. Iqbal y S. Iqbal, «Attention-Based Multi-Channel Gated Recurrent Neural Networks: A Novel Feature-Centric Approach for Aspect-Based Sentiment Classification,» *IEEE Access*, vol. 11, págs. 54 408-54 427, 2023. DOI: 10.1109/ACCESS.2023.3281889.
- [187] R. Vatambeti, S. V. Mantena, K. V. D. Kiran, M. Manohar y C. Manjunath, «Twitter sentiment analysis on online food services based on elephant herd optimization with hybrid deep learning technique,» *Cluster Computing*, vol. 27, n.º 1, págs. 655-671, feb. de 2024, ISSN: 1573-7543. DOI: 10.1007/s10586-023-03970-7. dirección: <https://doi.org/10.1007/s10586-023-03970-7>.
- [188] G. Kaur y A. Sharma, «A deep learning-based model using hybrid feature extraction approach for consumer sentiment analysis,» *Journal of Big Data*, vol. 10, n.º 1, pág. 5, ene. de 2023, ISSN: 2196-1115. DOI: 10.1186/s40537-022-00680-6. dirección: <https://doi.org/10.1186/s40537-022-00680-6>.
- [189] R. K. Dey y A. K. Das, «Modified term frequency-inverse document frequency based deep hybrid framework for sentiment analysis,» *Multimedia Tools and Applications*, vol. 82, n.º 21, págs. 32 967-32 990, sep. de 2023, ISSN: 1573-7721. DOI: 10.1007/s11042-023-14653-1. dirección: <https://doi.org/10.1007/s11042-023-14653-1>.
- [190] M. Irfan, N. Ayub, Q. A. Ahmed et al., «AQSA: Aspect-Based Quality Sentiment Analysis for Multi-Labeling with Improved ResNet Hybrid Algorithm,» *Electronics*, vol. 12, n.º 6, 2023, ISSN: 2079-9292. DOI: 10.3390/electronics12061298. dirección: <https://www.mdpi.com/2079-9292/12/6/1298>.
- [191] M. Berrimi, M. Oussalah, A. Moussaoui y M. Saidi, «Attention Mechanism Architecture for Arabic Sentiment Analysis,» *ACM Trans. Asian Low-Resour. Lang. Inf. Process.*, vol. 22, n.º 4, mar. de 2023, ISSN: 2375-4699. DOI: 10.1145/3578265. dirección: <https://doi.org/10.1145/3578265>.
- [192] S. S y P. K. V, «Hybrid Deep Learning Approach for Sentiment Classification of Malayalam Tweets,» *International Journal of Advanced Computer Science and Applications*, vol. 13, n.º 4, 2022. DOI: 10.14569/IJACSA.2022.01304103. dirección: <http://dx.doi.org/10.14569/IJACSA.2022.01304103>.

- [193] X. Zhang e Y. Ma, «An ALBERT-based TextCNN-Hatt hybrid model enhanced with topic knowledge for sentiment analysis of sudden-onset disasters,» *Engineering Applications of Artificial Intelligence*, vol. 123, pág. 106-136, 2023, ISSN: 0952-1976. DOI: <https://doi.org/10.1016/j.engappai.2023.106136>. dirección: <https://www.sciencedirect.com/science/article/pii/S0952197623003202>.
- [194] C.-H. Lin y U. Nuha, «Sentiment analysis of Indonesian datasets based on a hybrid deep-learning strategy,» *Journal of Big Data*, vol. 10, n.º 1, pág. 88, mayo de 2023, ISSN: 2196-1115. DOI: 10.1186/s40537-023-00782-9. dirección: <https://doi.org/10.1186/s40537-023-00782-9>.
- [195] K. B. Muhammad y S. M. A. Burney, «Innovations in Urdu Sentiment Analysis Using Machine and Deep Learning Techniques for Two-Class Classification of Symmetric Datasets,» *Symmetry*, vol. 15, n.º 5, 2023, ISSN: 2073-8994. DOI: 10.3390/sym15051027. dirección: <https://www.mdpi.com/2073-8994/15/5/1027>.
- [196] M. Mujahid, K. Kanwal, F. Rustam, W. Aljedaani e I. Ashraf, «Arabic ChatGPT Tweets Classification Using RoBERTa and BERT Ensemble Model,» *ACM Trans. Asian Low-Resour. Lang. Inf. Process.*, vol. 22, n.º 8, ago. de 2023, ISSN: 2375-4699. DOI: 10.1145/3605889. dirección: <https://doi.org/10.1145/3605889>.
- [197] A. S. Talaat, «Sentiment analysis classification system using hybrid BERT models,» *Journal of Big Data*, vol. 10, n.º 1, pág. 110, jun. de 2023, ISSN: 2196-1115. DOI: 10.1186/s40537-023-00781-w. dirección: <https://doi.org/10.1186/s40537-023-00781-w>.
- [198] F. Alemayehu, M. Meshesha y J. Abate, «Amharic political sentiment analysis using deep learning approaches,» *Scientific Reports*, vol. 13, n.º 1, pág. 17982, oct. de 2023, ISSN: 2045-2322. DOI: 10.1038/s41598-023-45137-9. dirección: <https://doi.org/10.1038/s41598-023-45137-9>.
- [199] H. Tang y R. Zhang, *Research on Chinese microblog sentiment classification based on Textcnn-BILSTM model*, dic. de 2023. dirección: <https://jips-k.org/digital-library/2023/19/6/842>.
- [200] N. Singh y U. C. Jaiswal, «Sentiment analysis based on Urdu reviews using hybrid deep learning models,» *Applied Computer Systems*, vol. 28, n.º 2, págs. 258-265, dic. de 2023. DOI: 10.2478/acss-2023-0026.
- [201] Y. Jin y A. Zhao, «Bert-based graph unlinked embedding for sentiment analysis,» *Complex & Intelligent Systems*, vol. 10, n.º 2, págs. 2627-2638, abr. de 2024, ISSN: 2198-6053. DOI: 10.1007/s40747-023-01289-9. dirección: <https://doi.org/10.1007/s40747-023-01289-9>.
- [202] M. Wankhade, C. S. R. Annavarapu y M. K. Verma, «CBVoSD: context based vectors over sentiment domain ensemble model for review classification,» *The Journal of Supercomputing*, vol. 78, n.º 5, págs. 6411-6447, abr. de 2022.
- [203] E. H. Mohamed, M. E. Moussa y M. H. Haggag, «An Enhanced Sentiment Analysis Framework Based on Pre-Trained Word Embedding,» *International Journal of Computational Intelligence and Applications*, vol. 19, n.º 04, pág. 2050031, 2020. DOI: 10.1142/S1469026820500315.

- [204] S. Siddiqui, M. A. Rehman, S. M. Daudpota y A. Waqas, «Opinion Mining: An Approach to Feature Engineering,» *International Journal of Advanced Computer Science and Applications*, vol. 10, n.º 3, 2019. DOI: 10.14569/IJACSA.2019.0100320. dirección: <http://dx.doi.org/10.14569/IJACSA.2019.0100320>.
- [205] S. Symeonidis, D. Effrosynidis y A. Arampatzis, «A comparative evaluation of pre-processing techniques and their interactions for twitter sentiment analysis,» *Expert Systems with Applications*, vol. 110, págs. 298-310, 2018, ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2018.06.022>. dirección: <https://www.sciencedirect.com/science/article/pii/S0957417418303683>.
- [206] F. H. Khan, U. Qamar y S. Bashir, «Lexicon based semantic detection of sentiments using expected likelihood estimate smoothed odds ratio,» *Artificial Intelligence Review*, vol. 48, n.º 1, págs. 113-138, jun. de 2017, ISSN: 1573-7462. DOI: 10.1007/s10462-016-9496-4. dirección: <https://doi.org/10.1007/s10462-016-9496-4>.
- [207] M. Kamyab, G. Liu, A. Rasool y M. Adjeisah, «ACR-SA: attention-based deep model through two-channel CNN and Bi-RNN for sentiment analysis,» *PeerJ Computer Science*, vol. 8, e877, mar. de 2022, ISSN: 2376-5992. DOI: 10.7717/peerj-cs.877. dirección: <https://doi.org/10.7717/peerj-cs.877>.
- [208] H. Suresh y G. R. S, «An innovative and efficient method for Twitter sentiment analysis,» *International Journal of Data Mining, Modelling and Management*, vol. 11, n.º 1, págs. 1-18, 2019. DOI: 10.1504/IJDM.2019.096543. eprint: <https://www.inderscienceonline.com/doi/pdf/10.1504/IJDM.2019.096543>. dirección: <https://www.inderscienceonline.com/doi/abs/10.1504/IJDM.2019.096543>.
- [209] M. Liu Hanand Cocea, «Fuzzy information granulation towards interpretable sentiment analysis,» *Granular Computing*, vol. 2, n.º 4, págs. 289-302, dic. de 2017, ISSN: 2364-4974. DOI: 10.1007/s41066-017-0043-8. dirección: <https://doi.org/10.1007/s41066-017-0043-8>.
- [210] V. Rupapara, F. Rustam, A. Amaar, P. B. Washington, E. Lee e I. Ashraf, «Deepfake tweets classification using stacked Bi-LSTM and words embedding,» *PeerJ Computer Science*, vol. 7, e745, oct. de 2021, ISSN: 2376-5992. DOI: 10.7717/peerj-cs.745. dirección: <https://doi.org/10.7717/peerj-cs.745>.
- [211] A. Suciati e I. Budi, «Aspect-Based Sentiment Analysis and Emotion Detection for Code-Mixed Review,» *International Journal of Advanced Computer Science and Applications*, vol. 11, n.º 9, 2020. DOI: 10.14569/IJACSA.2020.0110921. dirección: <http://dx.doi.org/10.14569/IJACSA.2020.0110921>.
- [212] D. Sharmin Sadiaand Chakma, «Attention-based convolutional neural network for Bangla sentiment analysis,» *AI & SOCIETY*, vol. 36, n.º 1, págs. 381-396, mar. de 2021, ISSN: 1435-5655. DOI: 10.1007/s00146-020-01011-0. dirección: <https://doi.org/10.1007/s00146-020-01011-0>.

- [213] M. L. Barrón Estrada, R. Zatarain Cabada, R. Oramas Bustillos y M. Graff, «Opinion mining and emotion recognition applied to learning environments,» *Expert Systems with Applications*, vol. 150, pág. 113 265, 2020, ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2020.113265>. dirección: <https://www.sciencedirect.com/science/article/pii/S0957417420300907>.
- [214] B. Gaye, D. Zhang y A. Wulamu, «A Tweet Sentiment Classification Approach Using a Hybrid Stacked Ensemble Technique,» *Information*, vol. 12, n.º 9, 2021, ISSN: 2078-2489. DOI: 10.3390/info12090374. dirección: <https://www.mdpi.com/2078-2489/12/9/374>.
- [215] N. Capuano, L. Greco, P. Ritrovato y M. Vento, «Sentiment analysis for customer relationship management: an incremental learning approach,» *Applied Intelligence*, vol. 51, n.º 6, págs. 3339-3352, jun. de 2021, ISSN: 1573-7497. DOI: 10.1007/s10489-020-01984-x. dirección: <https://doi.org/10.1007/s10489-020-01984-x>.
- [216] O. Gokalp, E. Tasci y A. Ugur, «A novel wrapper feature selection algorithm based on iterated greedy metaheuristic for sentiment classification,» *Expert Systems with Applications*, vol. 146, pág. 113 176, 2020, ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2020.113176>. dirección: <https://www.sciencedirect.com/science/article/pii/S0957417420300026>.
- [217] S. Madasu Avinashand Elango, «Efficient feature selection techniques for sentiment analysis,» *Multimedia Tools and Applications*, vol. 79, n.º 9, págs. 6313-6335, mar. de 2020, ISSN: 1573-7721. DOI: 10.1007/s11042-019-08409-z. dirección: <https://doi.org/10.1007/s11042-019-08409-z>.
- [218] H. Zheng Lijuanand Wang y S. Gao, «Sentimental feature selection for sentiment analysis of Chinese online reviews,» *International Journal of Machine Learning and Cybernetics*, vol. 9, n.º 1, págs. 75-84, ene. de 2018, ISSN: 1868-808X. DOI: 10.1007/s13042-015-0347-4. dirección: <https://doi.org/10.1007/s13042-015-0347-4>.
- [219] M. I. A. Latiffi, M. R. Yaakub e I. S. Ahmad, «Flower Pollination Algorithm for Feature Selection in Tweets Sentiment Analysis,» *International Journal of Advanced Computer Science and Applications*, vol. 13, n.º 5, 2022. DOI: 10.14569/IJACSA.2022.0130551. dirección: <http://dx.doi.org/10.14569/IJACSA.2022.0130551>.
- [220] A. Nasser y H. Sever, «A concept-based Sentiment Analysis approach for Arabic,» en, *int. Arab j. inf. technol.*, vol. 17, n.º 5, págs. 778-788, sep. de 2020.
- [221] P. Q. Tran, N. T. Trieu, N. V. Dao, H. T. Nguyen y H. X. Huynh, «Effective Opinion Words Extraction for Food Reviews Classification,» *International Journal of Advanced Computer Science and Applications*, vol. 11, n.º 7, 2020. DOI: 10.14569/IJACSA.2020.0110755. dirección: <http://dx.doi.org/10.14569/IJACSA.2020.0110755>.
- [222] C. Catal y M. Nangir, «A sentiment classification model based on multiple classifiers,» *Applied Soft Computing*, vol. 50, págs. 135-141, 2017, ISSN: 1568-4946. DOI: <https://doi.org/10.1016/j.asoc.2016.11.022>. dirección: <https://www.sciencedirect.com/science/article/pii/S1568494616305919>.

- [223] M. Giatsoglou, M. G. Vozalis, K. Diamantaras, A. Vakali, G. Sarigiannidis y K. C. Chatzisavvas, «Sentiment analysis leveraging emotions and word embeddings,» *Expert Systems with Applications*, vol. 69, págs. 214-224, 2017, ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2016.10.043>. dirección: <https://www.sciencedirect.com/science/article/pii/S095741741630584X>.
- [224] B. Al sari, R. Alkhalidi, D. Alsaffar et al., «Sentiment analysis for cruises in Saudi Arabia on social media platforms using machine learning algorithms,» *Journal of Big Data*, vol. 9, n.º 1, pág. 21, feb. de 2022, ISSN: 2196-1115. DOI: 10.1186/s40537-022-00568-5. dirección: <https://doi.org/10.1186/s40537-022-00568-5>.
- [225] A. Mohasseb, M. Bader-El-Den y M. Cocea, «A customised grammar framework for query classification,» *Expert Systems with Applications*, vol. 135, págs. 164-180, 2019, ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2019.06.010>. dirección: <https://www.sciencedirect.com/science/article/pii/S0957417419304105>.
- [226] R. Chiha, M. B. Ayed y C. d. C. Pereira, «A complete framework for aspect-level and sentence-level sentiment analysis,» *Applied Intelligence*, abr. de 2022, ISSN: 1573-7497. DOI: 10.1007/s10489-022-03279-9. dirección: <https://doi.org/10.1007/s10489-022-03279-9>.
- [227] M. Sadr Hosseinand Nazari Soleimandarabi, «ACNN-TL: attention-based convolutional neural network coupling with transfer learning and contextualized word representation for enhancing the performance of sentiment classification,» *The Journal of Supercomputing*, vol. 78, n.º 7, págs. 10 149-10 175, mayo de 2022, ISSN: 1573-0484. DOI: 10.1007/s11227-021-04208-2. dirección: <https://doi.org/10.1007/s11227-021-04208-2>.
- [228] R. Yan, Y. Yu y D. Qiu, «Emotion-enhanced classification based on fuzzy reasoning,» *International Journal of Machine Learning and Cybernetics*, vol. 13, n.º 3, págs. 839-850, mar. de 2022, ISSN: 1868-808X. DOI: 10.1007/s13042-021-01356-y. dirección: <https://doi.org/10.1007/s13042-021-01356-y>.
- [229] N. Gozuacik, C. O. Sakar y S. Ozcan, «Social media-based opinion retrieval for product analysis using multi-task deep neural networks,» *Expert Systems with Applications*, vol. 183, pág. 115 388, 2021, ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2021.115388>. dirección: <https://www.sciencedirect.com/science/article/pii/S0957417421008125>.
- [230] S. Al-Dabet, S. Tedmori y M. AL-Smadi, «Enhancing Arabic aspect-based sentiment analysis using deep learning models,» *Computer Speech and Language*, vol. 69, pág. 101 224, 2021, ISSN: 0885-2308. DOI: <https://doi.org/10.1016/j.csl.2021.101224>. dirección: <https://www.sciencedirect.com/science/article/pii/S0885230821000310>.
- [231] F. Huang, X. Li, C. Yuan, S. Zhang, J. Zhang y S. Qiao, «Attention-Emotion-Enhanced Convolutional LSTM for Sentiment Analysis,» *IEEE Transactions on Neural Networks and Learning Systems*, págs. 1-14, 2021. DOI: 10.1109/TNNLS.2021.3056664.

- [232] K. Chen y W. Ke, «A hierarchical neural model for target-based sentiment analysis,» *Concurrency and Computation: Practice and Experience*, vol. 33, n.º 10, e6184, 2021, e6184 CPE-20-1304.R1. DOI: <https://doi.org/10.1002/cpe.6184>. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/cpe.6184>. dirección: <https://onlinelibrary.wiley.com/doi/abs/10.1002/cpe.6184>.
- [233] K. Chen y W. Ke, «A hierarchical neural model for target-based sentiment analysis,» *Concurrency and Computation: Practice and Experience*, vol. 33, n.º 10, e6184, 2021, e6184 CPE-20-1304.R1. DOI: <https://doi.org/10.1002/cpe.6184>. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/cpe.6184>. dirección: <https://onlinelibrary.wiley.com/doi/abs/10.1002/cpe.6184>.
- [234] J. Yang, X. Zou, W. Zhang y H. Han, «Microblog sentiment analysis via embedding social contexts into an attentive LSTM,» *Engineering Applications of Artificial Intelligence*, vol. 97, pág. 104048, 2021, ISSN: 0952-1976. DOI: <https://doi.org/10.1016/j.engappai.2020.104048>. dirección: <https://www.sciencedirect.com/science/article/pii/S0952197620303213>.
- [235] K. Ayyub, S. Iqbal, M. W. Nisar, S. G. Ahmad y E. U. Munir, «Stance detection using diverse feature sets based on machine learning techniques,» *Journal of Intelligent & Fuzzy Systems*, vol. 40, págs. 9721-9740, 2021, 5, ISSN: 1875-8967. DOI: 10.3233/JIFS-202269. dirección: <https://doi.org/10.3233/JIFS-202269>.
- [236] M. Kasri, M. Birjali y A. Beni-Hssane, «Word2Sent: A new learning sentiment-embedding model with low dimension for sentence level sentiment classification,» *Concurrency and Computation: Practice and Experience*, vol. 33, n.º 9, e6149, 2021, e6149 CPE-20-0699.R1. DOI: <https://doi.org/10.1002/cpe.6149>. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/cpe.6149>. dirección: <https://onlinelibrary.wiley.com/doi/abs/10.1002/cpe.6149>.
- [237] L.-C. Chen, C.-M. Lee y M.-Y. Chen, «Exploration of social media for sentiment analysis using deep learning,» *Soft Computing*, vol. 24, n.º 11, págs. 8187-8197, jun. de 2020, ISSN: 1433-7479. DOI: 10.1007/s00500-019-04402-8. dirección: <https://doi.org/10.1007/s00500-019-04402-8>.
- [238] F. Mehmood, M. U. Ghani, M. A. Ibrahim, R. Shahzadi, W. Mahmood y M. N. Asim, «A Precisely Xtreme-Multi Channel Hybrid Approach for Roman Urdu Sentiment Analysis,» *IEEE Access*, vol. 8, págs. 192740-192759, 2020. DOI: 10.1109/ACCESS.2020.3030885.
- [239] M. U. Salur e I. Aydin, «A Novel Hybrid Deep Learning Model for Sentiment Classification,» *IEEE Access*, vol. 8, págs. 58080-58093, 2020. DOI: 10.1109/ACCESS.2020.2982538.
- [240] C. N. Dang, M. N. Moreno-García y F. De la Prieta, «Hybrid Deep Learning Models for Sentiment Analysis,» *Complexity*, vol. 2021, pág. 9986920, ago. de 2021, ISSN: 1076-2787. DOI: 10.1155/2021/9986920. dirección: <https://doi.org/10.1155/2021/9986920>.

- [241] T. Li, H. Xu, Z. Liu et al., «A spatiotemporal multi-feature extraction framework for opinion mining,» *Neurocomputing*, vol. 490, págs. 337-346, 2022, ISSN: 0925-2312. DOI: <https://doi.org/10.1016/j.neucom.2021.11.098>. dirección: <https://www.sciencedirect.com/science/article/pii/S0925231221018105>.
- [242] F. Alotaibi y V. Gupta, «Sentiment Analysis System using Hybrid Word Embeddings with Convolutional Recurrent Neural Network,» en-gb, *INTERNATIONAL ARAB JOURNAL OF INFORMATION TECHNOLOGY*, n.º 3, mayo de 2022. DOI: <https://doi.org/10.34028/iajit/19/3/6>.
- [243] H. Yang, A. Alsadoon, T. Prasad P. W. C. and Al-Dala'in, T. A. Rashid, A. Maag y O. H. Alsadoon, «Deep learning neural networks for emotion classification from text: enhanced leaky rectified linear unit activation and weighted loss,» *Multimedia Tools and Applications*, vol. 81, n.º 11, págs. 15 439-15 468, mayo de 2022, ISSN: 1573-7721. DOI: 10.1007/s11042-022-12629-1. dirección: <https://doi.org/10.1007/s11042-022-12629-1>.
- [244] O. Alharbi, «A Deep Learning Approach Combining CNN and Bi-LSTM with SVM Classifier for Arabic Sentiment Analysis,» *International Journal of Advanced Computer Science and Applications*, vol. 12, n.º 6, 2021. DOI: 10.14569/IJACSA.2021.0120618. dirección: <http://dx.doi.org/10.14569/IJACSA.2021.0120618>.
- [245] J. Zhou, J. X. Huang, Q. V. Hu y L. He, «Is position important? deep multi-task learning for aspect-based sentiment analysis,» *Applied Intelligence*, vol. 50, n.º 10, págs. 3367-3378, oct. de 2020, ISSN: 1573-7497. DOI: 10.1007/s10489-020-01760-x. dirección: <https://doi.org/10.1007/s10489-020-01760-x>.
- [246] N. Liu y B. Shen, «ReMemNN: A novel memory neural network for powerful interaction in aspect-based sentiment analysis,» *Neurocomputing*, vol. 395, págs. 66-77, 2020, ISSN: 0925-2312. DOI: <https://doi.org/10.1016/j.neucom.2020.02.018>. dirección: <https://www.sciencedirect.com/science/article/pii/S0925231220301934>.
- [247] A. Onan, «Sentiment analysis on product reviews based on weighted word embeddings and deep neural networks,» *Concurrency and Computation: Practice and Experience*, vol. 33, n.º 23, e5909, 2021, e5909 CPE-20-0130.R1. DOI: <https://doi.org/10.1002/cpe.5909>. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/cpe.5909>. dirección: <https://onlinelibrary.wiley.com/doi/abs/10.1002/cpe.5909>.
- [248] G. Lu, J. Gan, J. Yin, Z. Luo, B. Li y X. Zhao, «Multi-task learning using a hybrid representation for text classification,» *Neural Computing and Applications*, vol. 32, n.º 11, págs. 6467-6480, jun. de 2020, ISSN: 1433-3058. DOI: 10.1007/s00521-018-3934-y. dirección: <https://doi.org/10.1007/s00521-018-3934-y>.
- [249] G. Lu, X. Zhao, J. Yin, W. Yang y B. Li, «Multi-task learning using variational auto-encoder for sentiment classification,» *Pattern Recognition Letters*, vol. 132, págs. 115-122, 2020, Multiple-Task Learning for Big Data (MTL4BD), ISSN: 0167-8655. DOI: <https://doi.org/10.1016/j.patrec.2018.06.027>. dirección: <https://www.sciencedirect.com/science/article/pii/S0167865518302769>.

- [250] G. Liu, X. Huang, X. Liu y A. Yang, «A Novel Aspect-based Sentiment Analysis Network Model Based on Multilingual Hierarchy in Online Social Network,» *The Computer Journal*, vol. 63, n.º 3, págs. 410-424, mayo de 2019, ISSN: 0010-4620. DOI: 10.1093/comjnl/bxz031. eprint: <https://academic.oup.com/comjnl/article-pdf/63/3/410/33106360/bxz031.pdf>. dirección: <https://doi.org/10.1093/comjnl/bxz031>.
- [251] H.-j. Park, M. Song y K.-S. Shin, «Deep learning models and datasets for aspect term sentiment classification: Implementing holistic recurrent attention on target-dependent memories,» *Knowledge-Based Systems*, vol. 187, pág. 104825, 2020, ISSN: 0950-7051. DOI: <https://doi.org/10.1016/j.knosys.2019.06.033>. dirección: <https://www.sciencedirect.com/science/article/pii/S0950705119303004>.
- [252] J. Ramaswamy Srividhya Lakshmiand Chinnappan, «RecogNet-LSTM+CNN: a hybrid network with attention mechanism for aspect categorization and sentiment classification,» *Journal of Intelligent Information Systems*, vol. 58, n.º 2, págs. 379-404, abr. de 2022, ISSN: 1573-7675. DOI: 10.1007/s10844-021-00692-3. dirección: <https://doi.org/10.1007/s10844-021-00692-3>.
- [253] L. Bao, P. Lambert y T. Badia, «Improving aspect-based neural sentiment classification with lexicon enhancement, attention regularization and sentiment induction,» *Natural Language Engineering*, págs. 1-30, 2022. DOI: 10.1017/S1351324922000432.
- [254] L.-C. Cheng, Y.-L. Chen e Y.-Y. Liao, «Aspect-based sentiment analysis with component focusing multi-head co-attention networks,» *Neurocomputing*, vol. 489, págs. 9-17, 2022, ISSN: 0925-2312. DOI: <https://doi.org/10.1016/j.neucom.2022.03.027>. dirección: <https://www.sciencedirect.com/science/article/pii/S092523122200296X>.
- [255] M. E. Basiri, S. Nemati, M. Abdar, S. Asadi y U. R. Acharya, «A novel fusion-based deep learning model for sentiment analysis of COVID-19 tweets,» *Knowledge-Based Systems*, vol. 228, pág. 107242, 2021, ISSN: 0950-7051. DOI: <https://doi.org/10.1016/j.knosys.2021.107242>. dirección: <https://www.sciencedirect.com/science/article/pii/S0950705121005049>.
- [256] X. Tao Jieand Fang, «Toward multi-label sentiment analysis: a transfer learning based approach,» *Journal of Big Data*, vol. 7, n.º 1, pág. 1, ene. de 2020, ISSN: 2196-1115. DOI: 10.1186/s40537-019-0278-0. dirección: <https://doi.org/10.1186/s40537-019-0278-0>.
- [257] C. N. Dang, M. N. Moreno-García y F. De la Prieta, «Using Hybrid Deep Learning Models of Sentiment Analysis and Item Genres in Recommender Systems for Streaming Services,» *Electronics*, vol. 10, n.º 20, 2021, ISSN: 2079-9292. DOI: 10.3390/electronics10202459. dirección: <https://www.mdpi.com/2079-9292/10/20/2459>.
- [258] N. Liu y B. Shen, «Aspect term extraction via information-augmented neural network,» *Complex & Intelligent Systems*, jul. de 2022, ISSN: 2198-6053. DOI: 10.1007/s40747-022-00818-2. dirección: <https://doi.org/10.1007/s40747-022-00818-2>.

- [259] S. Vernikou, A. Lyras y A. Kanavos, «Multiclass sentiment analysis on COVID-19-related tweets using deep learning models,» *Neural Computing and Applications*, vol. 34, n.º 22, págs. 19615-19627, nov. de 2022, ISSN: 1433-3058. DOI: 10.1007/s00521-022-07650-2. dirección: <https://doi.org/10.1007/s00521-022-07650-2>.
- [260] C. Yan, J. Liu, W. Liu y X. Liu, «Research on public opinion sentiment classification based on attention parallel dual-channel deep learning hybrid model,» *Engineering Applications of Artificial Intelligence*, vol. 116, pág. 105448, 2022, ISSN: 0952-1976. DOI: <https://doi.org/10.1016/j.engappai.2022.105448>. dirección: <https://www.sciencedirect.com/science/article/pii/S0952197622004389>.
- [261] K. Shrivastava y S. Kumar, «A SENTIMENT ANALYSIS SYSTEM FOR THE HINDI LANGUAGE BY INTEGRATING GATED RECURRENT UNIT WITH GENETIC,» en *The International Arab Journal of Information Technology (IAJIT)*, vol. 6, 2020. DOI: 10.34028/iajit/17/6/14. dirección: <http://dx.doi.org/10.34028/iajit/17/6/14>.
- [262] K. Dashtipour, M. Gogate, J. Li, F. Jiang, B. Kong y A. Hussain, «A hybrid Persian sentiment analysis framework: Integrating dependency grammar based rules and deep neural networks,» *Neurocomputing*, vol. 380, págs. 1-10, 2020, ISSN: 0925-2312. DOI: <https://doi.org/10.1016/j.neucom.2019.10.009>. dirección: <https://www.sciencedirect.com/science/article/pii/S0925231219313815>.
- [263] A. Vohra y R. Garg, «Deep learning based sentiment analysis of public perception of working from home through tweets,» *Journal of Intelligent Information Systems*, ago. de 2022, ISSN: 1573-7675. DOI: 10.1007/s10844-022-00736-2. dirección: <https://doi.org/10.1007/s10844-022-00736-2>.
- [264] A. Muslim, A. B. Mutiara, R. Refianti, C. M. Karyati y G. Setiawan, «Comparison of Accuracy between Long Short-Term Memory-Deep Learning and Multinomial Logistic Regression-Machine Learning in Sentiment Analysis on Twitter,» *International Journal of Advanced Computer Science and Applications*, vol. 11, n.º 2, 2020. DOI: 10.14569/IJACSA.2020.0110294. dirección: <http://dx.doi.org/10.14569/IJACSA.2020.0110294>.
- [265] F. A. Lovera, Y. C. Cardinale y M. N. Homsí, «Sentiment Analysis in Twitter Based on Knowledge Graph and Deep Learning Classification,» *Electronics*, vol. 10, n.º 22, 2021, ISSN: 2079-9292. DOI: 10.3390/electronics10222739. dirección: <https://www.mdpi.com/2079-9292/10/22/2739>.
- [266] H. Yu, G. Lu, Q. Cai e Y. Xue, «A KGE Based Knowledge Enhancing Method for Aspect-Level Sentiment Classification,» *Mathematics*, vol. 10, n.º 20, 2022, ISSN: 2227-7390. DOI: 10.3390/math10203908. dirección: <https://www.mdpi.com/2227-7390/10/20/3908>.
- [267] P. Naresh A. and Venkata Krishna, «An efficient approach for sentiment analysis using machine learning algorithm,» *Evolutionary Intelligence*, vol. 14, n.º 2, págs. 725-731, jun. de 2021, ISSN: 1864-5917. DOI: 10.1007/s12065-020-00429-1. dirección: <https://doi.org/10.1007/s12065-020-00429-1>.

- [268] W. Muhammad, M. Mushtaq, K. N. Junejo y M. Y. Khan, «SENTIMENT ANALYSIS OF PRODUCT REVIEWS IN THE ABSENCE OF LABELLED DATA USING SUPERVISED LEARNING APPROACHES,» *Malaysian Journal of Computer Science*, vol. 33, n.º 2, págs. 118-132, abr. de 2020. DOI: 10.22452/mjcs.vol33no2.3. dirección: <https://ejournal.um.edu.my/index.php/MJCS/article/view/23528>.
- [269] Z. Wang Zhaoxiaand Lin, «Optimal Feature Selection for Learning-Based Algorithms for Sentiment Classification,» *Cognitive Computation*, vol. 12, n.º 1, págs. 238-248, ene. de 2020, ISSN: 1866-9964. DOI: 10.1007/s12559-019-09669-5. dirección: <https://doi.org/10.1007/s12559-019-09669-5>.
- [270] I. Safder, Z. Mahmood, R. Sarwar et al., «Sentiment analysis for Urdu online reviews using deep learning models,» *Expert Systems*, vol. 38, n.º 8, e12751, 2021. DOI: <https://doi.org/10.1111/exsy.12751>. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1111/exsy.12751>. dirección: <https://onlinelibrary.wiley.com/doi/abs/10.1111/exsy.12751>.
- [271] O. Appel, F. Chiclana, J. Carter y H. Fujita, «Cross-ratio uninorms as an effective aggregation mechanism in sentiment analysis,» *Knowledge-Based Systems*, vol. 124, págs. 16-22, 2017, ISSN: 0950-7051. DOI: <https://doi.org/10.1016/j.knosys.2017.02.028>. dirección: <https://www.sciencedirect.com/science/article/pii/S0950705117301120>.
- [272] L. C. y Mathias Etcheverry y Aiala Rosá, «Sentiment analysis in Spanish tweets: Some experiments with focus on neutral tweets,» *Procesamiento del Lenguaje Natural*, vol. 64, n.º 0, págs. 109-116, 2020, ISSN: 1989-7553. dirección: <http://journal.sepln.org/sepln/ojs/ojs/index.php/pln/article/view/6202>.
- [273] T. Dhanalakshmi R.and Sri Devi, «Adaptive cognitive intelligence in analyzing employee feedback using LSTM,» *Journal of Intelligent & Fuzzy Systems*, vol. 39, págs. 8069-8078, 2020, 6, ISSN: 1875-8967. DOI: 10.3233/JIFS-189129. dirección: <https://doi.org/10.3233/JIFS-189129>.
- [274] Q. Cheng, Y. Ke y A. Abdelmouty, «Negative emotion diffusion and intervention countermeasures of social networks based on deep learning,» *Journal of Intelligent & Fuzzy Systems*, vol. 39, págs. 4935-4945, 2020, 4, ISSN: 1875-8967. DOI: 10.3233/JIFS-179979. dirección: <https://doi.org/10.3233/JIFS-179979>.
- [275] Ankita, S. Rani, A. K. Bashir, A. Alhudhaif, D. Koundal y E. S. Gunduz, «An efficient CNN-LSTM model for sentiment detection in #BlackLivesMatter,» *Expert Systems with Applications*, vol. 193, pág. 116256, 2022, ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2021.116256>. dirección: <https://www.sciencedirect.com/science/article/pii/S0957417421015657>.
- [276] T. Pasupa Kitsuchartand Seneewong Na Ayutthaya, «Hybrid Deep Learning Models for Thai Sentiment Analysis,» *Cognitive Computation*, vol. 14, n.º 1, págs. 167-193, ene. de 2022, ISSN: 1866-9964. DOI: 10.1007/s12559-020-09770-0. dirección: <https://doi.org/10.1007/s12559-020-09770-0>.

- [277] Y. Long, R. Xiang, Q. Lu, C.-R. Huang y M. Li, «Improving Attention Model Based on Cognition Grounded Data for Sentiment Analysis,» *IEEE Transactions on Affective Computing*, vol. 12, n.º 4, págs. 900-912, 2021. DOI: 10.1109/TAFFC.2019.2903056.
- [278] Y. Mamani-Coaquira y E. Villanueva, «An Unsupervised Model Based on Knowledge Graph and Concepts for Sentiment Analysis,» *IEEE Open Journal of the Computer Society*, vol. 6, págs. 1561-1574, 2025. DOI: 10.1109/OJCS.2025.3616329.
- [279] C.-O. Truica, F. Radulescu y A. Boicea, «Comparing Different Term Weighting Schemas for Topic Modeling,» en *2016 18th International Symposium on Symbolic and Numeric Algorithms for Scientific Computing (SYNASC)*, 2016, págs. 307-310. DOI: 10.1109/SYNASC.2016.055.
- [280] C.-O. Truică y C. Leordeanu, «Classification of an Imbalanced Data Set using Decision Tree Algorithms,» *University Politehnica of Bucharest Scientific Bulletin Series C - Electrical Engineering and Computer Science*, vol. 79, págs. 69-, dic. de 2017.
- [281] L. A. Jeni, J. F. Cohn y F. De La Torre, «Facing Imbalanced Data—Recommendations for the Use of Performance Metrics,» en *2013 Humaine Association Conference on Affective Computing and Intelligent Interaction*, 2013, págs. 245-251. DOI: 10.1109/ACII.2013.47.
- [282] M. Abdelhamid y A. Desai, *Balancing the Scales: A Comprehensive Study on Tackling Class Imbalance in Binary Classification*, 2024. arXiv: 2409.19751 [cs.LG]. dirección: <https://arxiv.org/abs/2409.19751>.