



**Modelos de aprendizaje profundo y procesamiento de lenguaje natural para el análisis de tópicos y emociones en YouTube sobre el conflicto palestino-israelí**

Hannan Nayibe Yousef Novoa

Universidad Ean  
Facultad de Ingeniería  
Maestría en Ciencias de Datos  
Bogotá D.C., Colombia  
04/07/2025

Modelos de aprendizaje profundo y procesamiento de lenguaje natural para el análisis de tópicos y emociones en YouTube sobre el conflicto palestino-israelí

2

Modelos de aprendizaje profundo y procesamiento de lenguaje natural para el análisis de tópicos y emociones en YouTube sobre el conflicto palestino-israelí

**Hannan Nayibe Yousef Novoa**

Trabajo de grado presentado como requisito para optar al título de:

**Magister en Ciencias de Datos**

Directora:

Carolina María Luque Zabala

Modalidad:

**Monografía**

Universidad Ean

Facultad de Ingeniería

Maestría en Ciencias de Datos

Bogotá D.C., Colombia

04/07/2025

Nota de aceptación:

---

---

---

---

---

---

Firma del jurado

---

Firma del jurado

---

Firma del director del trabajo de grado

Bogotá D.C., 04/07/2025

Dedico este trabajo a todas las víctimas del conflicto, en reconocimiento de su sufrimiento y en memoria de aquellos cuyas historias han sido marginalizadas en la representación pública del conflicto.

A mi familia, por su acompañamiento, y a mi hijo, por su paciencia involuntaria y por acompañarme, sin saberlo, en cada etapa de este proceso.

### **Agradecimientos**

Expreso mi más sincero agradecimiento a la profesora Carolina María Luque Zabala, docente investigadora de la Universidad EAN, por su acompañamiento riguroso y constante a lo largo de mi proceso formativo. Su compromiso académico, la calidad de su orientación y la confianza depositada en mí fueron fundamentales para la construcción y finalización de este proyecto. Su dedicación y ejemplo reflejan un genuino compromiso con la enseñanza, dejando una huella profunda en mi trayectoria investigativa y en mi crecimiento profesional.

Extiendo igualmente mi gratitud a los profesores del programa de Maestría en Ciencia de Datos, quienes, a través de sus enseñanzas y disposición, facilitaron la apropiación de conocimientos técnicos y metodológicos esenciales para el desarrollo de esta investigación. Su labor docente fue clave en la consolidación de las competencias que hicieron posible este trabajo.

## Resumen

Este estudio analiza las narrativas discursivas publicadas en YouTube por canales de distintas orientaciones informativas sobre el conflicto palestino-israelí, en el periodo comprendido entre el 7 de octubre de 2023 y el 27 de marzo de 2025. Se aplicó un enfoque de análisis no supervisado mediante embeddings generados con el modelo E5-Large-v2, una arquitectura basada en Transformers optimizada para tareas semánticas, junto con el algoritmo de agrupación K-means, para identificar tópicos temáticos diferenciados por categoría de canal. Adicionalmente, se llevó a cabo un fine-tuning de modelos de lenguaje basados en arquitecturas Transformer (RoBERTa, ELECTRA, DeBERTa y XLNet) para la clasificación de emociones personalizadas contextualizadas al conflicto. Los resultados revelan diferencias discursivas significativas entre fuentes informativas, así como la eficacia de modelos modernos como DeBERTa y RoBERTa para capturar matices emocionales complejos en contextos geopolíticos sensibles, alcanzando puntuaciones F1 de 0.89 y 0.87, respectivamente. Esta investigación aporta al análisis computacional del discurso y al estudio de las emociones en entornos digitales altamente complejos.

**Palabras clave:** Conflicto palestino-israelí, YouTube, análisis de discurso, embeddings semánticos, clasificación de emociones, modelos Transformer, procesamiento del lenguaje natural.

### **Abstract**

This study analyzes the discursive narratives published on YouTube by channels with different informational orientations regarding the Israeli–Palestinian conflict, during the period from October 7, 2023, to March 27, 2025. An unsupervised analysis approach was applied using embeddings generated with the E5-Large-v2 model, a Transformer-based architecture optimized for semantic tasks, along with the K-means clustering algorithm to identify thematic topics by channel category. Additionally, fine-tuning was performed on language models based on Transformer architectures (RoBERTa, ELECTRA, DeBERTa, and XLNet) for the classification of context-specific emotional categories. The results reveal significant discursive differences between sources, as well as the effectiveness of modern models such as DeBERTa and RoBERTa in capturing complex emotional nuances in geopolitically sensitive contexts, achieving F1 scores of 0.89 and 0.87, respectively. This research contributes to computational discourse analysis and the study of emotions in highly complex digital environments.

**Keywords:** Israeli–Palestinian conflict, YouTube, discourse analysis, semantic embeddings, emotion classification, Transformer models, natural language processing.

## Tabla de contenido

<b>1. Introducción.....</b>	<b>16</b>
<b>2. Objetivos .....</b>	<b>18</b>
<b>2.1. Objetivo general.....</b>	<b>18</b>
<b>2.2. Objetivos específicos.....</b>	<b>18</b>
<b>3. Justificación .....</b>	<b>19</b>
<b>4. Marco Teórico.....</b>	<b>21</b>
<b>4.1. Conflicto palestino – israelí y su representación en medios digitales.....</b>	<b>21</b>
<b>4.2. Procesamiento de lenguaje natural con Deep Learning y su aplicación en el análisis de medios digitales.....</b>	<b>23</b>
4.2.1. Recolección y selección de datos digitales para análisis con PLN.....	26
4.2.2. Preprocesamiento del texto.....	29
4.2.3. Representación del texto.....	30
4.2.4. Extracción de tópicos con embeddings BERT y agrupamiento no supervisado ..	31
4.2.5. Clasificación de sentimientos personalizada mediante Fine-tuning .....	33
4.2.6. Automatización del flujo de preprocesamiento con <i>pipelines</i> en el ciclo de ciencia de datos.....	39
<b>4.3. Antecedentes en el uso de procesamiento de lenguaje natural y aprendizaje profundo para el análisis de conflictos geopolíticos .....</b>	<b>39</b>

<b>4.4. Brecha de conocimiento y aporte de la investigación .....</b>	<b>46</b>
<b>5. Hipótesis .....</b>	<b>47</b>
<b>6. Variables.....</b>	<b>47</b>
<b>7. Metodología .....</b>	<b>48</b>
<b>7.1. Enfoque y alcance de la investigación.....</b>	<b>48</b>
<b>7.2. Aplicación de la metodología CRISP-DM.....</b>	<b>49</b>
<b>7.3. Población y muestra.....</b>	<b>51</b>
7.3.1. Población .....	51
7.3.2. Muestra .....	51
<b>7.4. Instrumentos de recolección de la información .....</b>	<b>52</b>
<b>7.5. Técnicas para el análisis de la información.....</b>	<b>55</b>
<b>8. Trabajo de Campo.....</b>	<b>61</b>
<b>8.1. Extracción de videos.....</b>	<b>62</b>
8.1.1. Diseño de términos de búsqueda y extracción de canales .....	62
8.1.2. Extracción automatizada y filtrado de canales .....	63
8.1.3. Categorización narrativa de canales .....	64
8.1.4. Recolección automatizada de videos.....	64
8.1.5. Optimización del pipeline y gestión de cuotas .....	65
<b>8.2. Preprocesamiento y limpieza de datos de videos.....</b>	<b>65</b>

Modelos de aprendizaje profundo y procesamiento de lenguaje natural para el análisis de tópicos y emociones en YouTube sobre el conflicto palestino-israelí	10
<b>8.3. Caracterización del corpus</b>	<b>68</b>
<b>8.4. Descripción general del discurso</b>	<b>74</b>
<b>8.5. Modelado de tópicos</b>	<b>84</b>
8.5.1. Estructura discursiva y tópicos predominantes en Palestina	93
8.5.2. Estructura discursiva y tópicos predominantes en Israel	101
8.5.3. Estructura discursiva y tópicos predominantes en Internacional	110
8.5.4. Estructura discursiva y tópicos predominantes en Internacional Medio Oriente	119
<b>8.6. Fine-tuning de comentarios</b>	<b>129</b>
8.6.1. Recolección automatizada de comentarios	129
8.6.2. Definición operativa de emociones clasificadas	129
8.6.3. Etiquetado manual y limpieza de datos	131
8.6.4. Modelos de clasificación emocional	133
<b>9. Discusión</b>	<b>137</b>
<b>10. Conclusiones y Trabajo Futuro</b>	<b>139</b>
<b>10.1. Conclusiones</b>	<b>139</b>
<b>10.2. Trabajo futuro</b>	<b>140</b>
<b>11. Referencias</b>	<b>143</b>

Modelos de aprendizaje profundo y procesamiento de lenguaje natural para el análisis de tópicos y emociones en YouTube sobre el conflicto palestino-israelí	11
---	----

### Tabla de Ilustraciones

Ilustración 1. Metodología CRISP-DM.....	50
Ilustración 2. Diagrama del flujo del pipeline de recolección .....	53
Ilustración 3. Esquema del proceso del modelado de tópicos.....	56
Ilustración 4. Extracción de tópicos con embeddings y selección de clústeres .....	58
Ilustración 5. Etapas del fine-tuning para clasificación de emociones.....	59
Ilustración 6. Distribución de videos por categoría narrativa .....	67
Ilustración 7. Ejemplo ilustrativo del contenido del conjunto de datos.....	69
Ilustración 8. Distribución de videos por canal en cada categoría.....	70
Ilustración 9. Evolución semanal del volumen de videos recolectados.....	71
Ilustración 10. Evolución mensual por categoría narrativa .....	72
Ilustración 11. Longitud de transcripciones por categoría narrativa .....	76
Ilustración 12. Frecuencia normalizada por categoría (Top 10 palabras más frecuentes) .....	79
Ilustración 13. Nube de n-gramas (1,2) por categoría narrativa .....	81
Ilustración 14. Nube de bigramas por categoría narrativa .....	82
Ilustración 15. Términos top-5 por categoría narrativa .....	83
Ilustración 16. Selección del número óptimo de clústeres por categoría .....	85
Ilustración 17. Visualización 2D de clústeres temáticos por categoría.....	87
Ilustración 18. Distribución cuantitativa de tópicos por categoría.....	88
Ilustración 19. Mapas de calor de distancia euclidiana entre centroides UMAP por categoría .....	90
Ilustración 20. Nube de palabras por tópico - Palestina (n-gramas 1,2) .....	93
Ilustración 21. Nubes de bigramas por tópico - Palestina.....	94

Ilustración 22. Top 15 n-gramas por Tópico – Palestina.....	94
Ilustración 23. Distribución de canales por tópico - Palestina.....	98
Ilustración 24. Evolución temporal de los tópicos - Palestina.....	98
Ilustración 25. Nube de palabras por tópico – Israel (n-gramas 1 y 2).....	101
Ilustración 26. Nube de bigramas por tópico - Israel.....	102
Ilustración 27. Top 15 n-gramas por tópico - Israel.....	102
Ilustración 28. Distribución de canales por tópico - Israel.....	107
Ilustración 29. Evolución temporal de los tópicos - Israel.....	108
Ilustración 30. Nube de n-gramas (1,2) por tópico - Internacional.....	111
Ilustración 31. Nube de bigramas por tópico - Internacional.....	111
Ilustración 32. Top 15 n-gramas por tópico - Internacional.....	112
Ilustración 33. Distribución de canales por tópico - Internacional.....	116
Ilustración 34. Evolución temporal de los tópicos - Internacional.....	117
Ilustración 35. Nubes de n-gramas (1,2) - Internacional Medio Oriente.....	120
Ilustración 36. Top 15 n-gramas por tópico - Internacional Medio Oriente.....	120
Ilustración 37. Nubes de bigramas por tópico - Internacional Medio Oriente.....	120
Ilustración 38. Distribución de canales por tópico - Internacional Medio Oriente.....	123
Ilustración 39. Evolución temporal de los tópicos - Internacional Medio Oriente.....	124
Ilustración 40. Mapa de calor de términos más relevantes por categoría.....	128
Ilustración 41. Distribución de emociones de la muestra etiquetada.....	131
Ilustración 42. Distribución de tokens por comentario.....	132
Ilustración 43. Comparación de F1-score por emoción y modelo.....	135
Ilustración 44. Matriz de confusión de los modelos de clasificación.....	136
Ilustración 45. Validation Loss vs F1 Macro.....	137

Modelos de aprendizaje profundo y procesamiento de lenguaje natural para el análisis de tópicos y emociones en YouTube sobre el conflicto palestino-israelí

Ilustración 46. Desempeño óptimo sin overfitting por modelo ..... 137

### Lista de Tablas

Tabla 1. Características técnicas de los modelos evaluados .....	35
Tabla 2. Definición de métricas de evaluación para clasificación emocional .....	38
Tabla 3. Fórmulas de métricas de evaluación para clasificación emocional.....	38
Tabla 4. Revisión de literatura de la aplicación de PLN y DL en conflictos geopolíticos .....	45
Tabla 5. Operacionalización de variables.....	48
Tabla 6. Distribución de videos recolectados por categoría de canal .....	51
Tabla 7. Distribución de emociones en la muestra etiquetada .....	52
Tabla 8. Criterios de inclusión y exclusión de videos considerados en el análisis.....	54
Tabla 9. Criterios de inclusión y exclusión de comentarios analizados.....	55
Tabla 10. Espacio de búsqueda de hiperparámetros con Optuna .....	60
Tabla 11. Palabras clave de búsqueda y extracción de canales .....	62
Tabla 12. Resumen de canales por categoría narrativa, número de menciones y cantidad de suscriptores.....	63
Tabla 13. Interacción por categoría narrativa.....	72
Tabla 14. Comparativa estadística antes y después del preprocesamiento .....	75
Tabla 15. Estadísticas descriptivas de la longitud de transcripciones.....	75
Tabla 16. Términos distintivos por categoría narrativa .....	77
Tabla 17. Índice de riqueza léxica (TTR) por categoría .....	78
Tabla 18. Términos léxicos representativos por categoría narrativa (TF-IDF).....	82
Tabla 19. Distancia media entre centroides UMAP por categoría .....	89
Tabla 20. Métricas de validación interna del agrupamiento temático (calculadas sobre embeddings UMAP).....	91

Tabla 21. Métricas semánticas globales por categoría narrativa (basadas en embeddings originales).....	91
Tabla 22. Resumen temático en la categoría Palestina.....	97
Tabla 23. Métricas de coherencia léxica por tópico - Palestina .....	99
Tabla 24. Coherencia semántica por tópico - Palestina.....	100
Tabla 25. Resumen temático en la categoría Israel.....	106
Tabla 26. Métricas de coherencia léxica por tópico - Israel.....	109
Tabla 27. Coherencia semántica por tópico - Israel.....	109
Tabla 28. Resumen temático en la categoría Internacional.....	115
Tabla 29. Métricas de coherencia léxica por tópico - Internacional.....	118
Tabla 30. Coherencia semántica por tópico - Internacional.....	118
Tabla 31. Resumen temático en la categoría Internacional Medio Oriente.....	122
Tabla 32. Métricas de coherencia léxica por tópico - Internacional Medio Oriente ....	124
Tabla 33. Coherencia semántica por tópico - Internacional Medio Oriente.....	125
Tabla 34. Definición operativa de las emociones etiquetadas.....	130
Tabla 35. Hiperparámetros óptimos seleccionados por Optuna por modelo .....	134
Tabla 36. Comparación del rendimiento de modelos de clasificación emocional .....	135

## 1. Introducción

El conflicto palestino – israelí es uno de los más prolongados y complejos de la historia contemporánea, caracterizado por profundas disputas territoriales, políticas y narrativas a nivel global. La decisión de 1947 de la Asamblea General de la ONU a favor de la partición de Palestina en dos estados marcó el inicio del conflicto palestino – israelí, otorgando al Estado judío un territorio más grande que el Estado palestino (Beinin & Hajjar, 2014). Múltiples escaladas han atraído la atención internacional. El 7 de octubre de 2023 marcó un punto de inflexión en su cobertura mediática debido a una escalada sin precedentes. En la era digital, esta cobertura se ha desplazado de los medios tradicionales a plataformas digitales como YouTube, escenario en el que los discursos sobre el conflicto se difunden con mayor rapidez y alcance global (Odera Oguejiofor, 2024). Este fenómeno plantea cuestionamientos acerca de cómo se difunden las narrativas y se configuran las emociones en entornos audiovisuales digitales. El presente estudio de investigación se desarrolla en el campo del análisis computacional del discurso y la clasificación emocional, por medio de técnicas de procesamiento de lenguaje natural (PLN) y aprendizaje profundo, integrando perspectivas de comunicación política, la teoría del encuadre (Entman, 1993) y la teoría de las emociones intergrupales (Sasley, 2011). La teoría del encuadre plantea que los medios no solo informan, sino que estructuran la realidad al enfatizar ciertos elementos y silenciar otros. Por su parte, la teoría de las emociones intergrupales sugiere que los discursos no solo transmiten hechos, sino también emociones compartidas que refuerzan identidades colectivas y movilizan actitudes políticas.

Si bien abundan estudios acerca del conflicto palestino – israelí desde múltiples enfoques, persiste un vacío en la comprensión de las narrativas digitales y su carga emocional. Al ser medios de amplificación de discursos globales, las plataformas digitales son escenarios de disputa simbólica donde los actores involucrados van construyendo legitimidades, identidades y emociones colectivas. Los análisis sistémicos de estas narrativas e identificación emocional en contextos geopolíticos en curso aún siguen siendo limitadas y poco abordadas desde la ciencia de datos.

A partir de ello, surge la pregunta de investigación: ¿Cómo pueden identificarse las narrativas dominantes y analizarse las emociones colectivas en discursos digitales sobre

el conflicto palestino-israelí mediante modelamiento no supervisado de tópicos y modelos Transformer entrenados para clasificación emocional?

El análisis computacional de tópicos y emociones en corpus digitales, como transcripciones de videos y comentarios en plataformas audiovisuales como YouTube, se convierte en una herramienta clave para comprender cómo se configuran y expresan los discursos, así como las dinámicas afectivas colectivas en la esfera pública internacional.

Este estudio adopta un enfoque computacional para el análisis de narrativas de discursos digitales sobre el conflicto palestino-israelí y las emociones colectivas asociadas, centrado en los videos y comentarios publicados en YouTube entre el octubre de 2023 y marzo de 2025. En una primera fase, se aplicó modelamiento de tópicos a partir de técnicas de reducción semántica y agrupamiento no supervisado, lo cual permitió identificar narrativas dominantes diferenciadas según el origen geográfico y político de los canales. A partir de las narrativas identificadas, se extrajeron comentarios representativos para entrenar modelos de clasificación emocional mediante *fine-tuning* manualmente supervisado. Se evaluaron cuatro arquitecturas *Transformer* con el objetivo de seleccionar el modelo más adecuado para este tipo de corpus, aunque su aplicación masiva fue limitada por restricciones computacionales. Aun así, este enfoque combinado, que articula análisis temático y afectivo, ofrece una vía robusta para comprender las dinámicas discursivas y emocionales que emergen en contextos de alta complejidad geopolítica.

El presente documento inicia con un marco teórico que contextualiza el conflicto palestino-israelí en el entorno digital, aborda los fundamentos del procesamiento de lenguaje natural y el aprendizaje profundo, y revisa antecedentes relevantes en el análisis computacional de narrativas. Posteriormente, se describe el proceso de extracción y categorización de videos desde YouTube, seguido por la caracterización del discurso y la aplicación de técnicas no supervisadas de modelamiento de tópicos mediante embeddings semánticos y agrupamiento no supervisado. Una vez evaluado el proceso de clusterización, se detallan las narrativas identificadas por categoría de canal. Posteriormente, se lleva a cabo la recolección automatizada de comentarios asociados a los videos previamente clusterizados y, a partir de esta muestra, se realiza un proceso de etiquetado manual con emociones personalizadas, el cual sirve como base para el *fine-tuning* de modelos de lenguaje basados en arquitecturas *Transformer*. Finalmente, se presenta la comparación del rendimiento entre modelos, el análisis de resultados, la

discusión interpretativa y las conclusiones, incluyendo recomendaciones para futuras investigaciones.

## **2. Objetivos**

### **2.1. Objetivo general**

Aplicar modelos de aprendizaje profundo y técnicas de procesamiento de lenguaje natural, para analizar tópicos y sentimientos en videos de canales de noticias de YouTube sobre el conflicto palestino-israelí, entre octubre de 2023 y marzo de 2025.

### **2.2. Objetivos específicos**

- Realizar una revisión de la literatura sobre el uso de algoritmos de aprendizaje profundo y técnicas de procesamiento de lenguaje natural en el análisis de conflictos geopolíticos en entornos digitales, con el propósito de identificar enfoques metodológicos pertinentes para el análisis de tópicos y sentimientos en plataformas digitales.
- Diseñar e implementar un pipeline automatizado que recopile, filtre y limpie datos de canales de medios de comunicación en YouTube sobre el conflicto palestino-israelí, cubriendo el periodo de octubre de 2023 a marzo de 2025.
- Aplicar técnicas consolidadas de aprendizaje profundo y procesamiento de lenguaje natural para representar semánticamente el contenido y los comentarios de usuarios en canales de medios de comunicación de YouTube sobre el conflicto palestino-israelí, e identificar tópicos emergentes y sentimientos predominantes.
- Evaluar el desempeño de los modelos implementados mediante métricas pertinentes e interpretar los resultados en el marco del conflicto palestino-israelí, destacando su contribución al análisis de patrones discursivos en contextos geopolíticos.

### 3. Justificación

El rol de las plataformas digitales en la configuración de discursos políticos es cada vez más influyente y relevante en el panorama mundial (Borah et al., 2022). El conflicto palestino-israelí, uno de los más prolongados y complejos de la historia contemporánea, ha generado olas de discusión, protestas, movimientos sociales y una creciente producción de contenido mediático que alimenta debates globales en distintos espacios. El acontecimiento del 7 de octubre de 2023 provocó una escalada sin precedentes que generó una ola de contenido discursivo en plataformas digitales como YouTube, donde no solo se reflejan percepciones globales, sino que también se modelan activamente a través de narrativas visuales y afectivas (Amure & Agarwal, 2025).

Comprender estas narrativas construidas y cómo las emociones colectivas se expresan en dichos espacios digitales resulta altamente relevante, especialmente en contextos de alta complejidad geopolítica. Este proyecto de investigación contribuye al campo del análisis computacional del discurso y al estudio de las emociones en contextos sensibles, respondiendo a una necesidad emergente en las relaciones internacionales y la comunicación digital en cuanto a la aplicación de metodologías de ciencia de datos y aprendizaje profundo para analizar fenómenos geopolíticos a gran escala, cuyo volumen de datos supera la capacidad de análisis humano tradicional (Ünver, 2019).

Desde el punto de vista social, este estudio ofrece un aporte significativo al entendimiento de cómo las narrativas digitales pueden influir en la construcción y difusión de emociones colectivas en contextos de conflicto, afectando así percepciones, actitudes y posicionamientos políticos en la opinión pública internacional. El proyecto es viable debido a la flexibilidad de la API de YouTube, que permite una recolección programada y estructurada de datos, así como a la disponibilidad de herramientas computacionales accesibles como Google Colab, bibliotecas de código abierto y modelos preentrenados. A pesar de las limitaciones computacionales, el enfoque incremental y la combinación de técnicas no supervisadas (para el modelamiento de tópicos) y supervisadas (para la clasificación emocional) permiten llevar a cabo un análisis riguroso y escalable dentro del alcance definido para esta investigación. El estudio de caso enriquecerá el cuerpo teórico sobre comunicación política y análisis de plataformas digitales al abordar YouTube como un medio potente en la divulgación de narrativas y en la configuración de percepciones,

Modelos de aprendizaje profundo y procesamiento de lenguaje natural para el análisis de tópicos y sentimientos en YouTube sobre el conflicto palestino-israelí

20

contribuyendo a la discusión sobre el rol de los medios digitales en los conflictos globales y su impacto en la opinión pública contemporánea (Kubin & von Sikorski, 2021; Zeitzoff, 2017).

## 4. Marco Teórico

### 4.1. Conflicto palestino – israelí y su representación en medios digitales

El conflicto palestino-israelí tiene su origen en el siglo XX, especialmente con el Plan de Partición de la ONU en 1947, que introdujo una división territorial profunda y marcó una ruptura decisiva, dando inicio a un conflicto sostenido en la región (Khalidi, 2020). Según Amnistía Internacional (2022), la ocupación de los territorios palestinos figura entre las más prolongadas y con mayores impactos humanitarios de la historia contemporánea. Desde el 7 de octubre de 2023, la crisis se ha intensificado de forma significativa, con un aumento sostenido de víctimas y desplazamientos, lo que ha generado una amplia preocupación a nivel global. Esta grave escalada ha reconfigurado el escenario político y humanitario regional, al mismo tiempo que ha impulsado un debate internacional sobre derechos humanos y seguridad. En respuesta, la Corte Internacional de Justicia emitió en julio de 2024 una opinión consultiva histórica sobre la legalidad de la ocupación, y en septiembre la Asamblea General de la ONU instó formalmente a Israel a poner fin a la ocupación de los territorios palestinos (Amnistía Internacional, 2024). Estos acontecimientos subrayan la relevancia global del conflicto en el contexto actual.

El conflicto entre Israel y Palestina ha copado la atención de medios de todo el mundo, caracterizado por disputas territoriales, enfrentamientos violentos e inestabilidad política prolongada (Ali et al., 2024). En la era de la información globalizada, las redes sociales y YouTube se han consolidado como canales esenciales para la difusión de noticias, opiniones y análisis (Cao, 2024). Desde octubre de 2023, estas plataformas se han convertido en escenarios propicios para intensificar la polarización emocional y moldear la percepción pública global sobre el conflicto palestino-israelí (Antonakaki & Ioannidis, 2025). Los contextos de confrontación regional suelen generar un impacto significativo tanto a nivel local como internacional, debido al carácter urgente y de gran alcance de las tensiones y sus poderosas resonancias emotivas (Cao, 2024).

Las plataformas digitales han contribuido a la democratización de la información al permitir que diversos actores configuren directamente la narrativa internacional del conflicto (Odera Oguejiofor, 2024). En la última década, millones de usuarios han volcado sus opiniones en YouTube, elevando exponencialmente el volumen de datos disponibles

para el análisis de percepciones y sentimientos colectivos (Al-Agha et al., 2019). Estos medios en línea desempeñan un papel decisivo en la formación de la opinión pública ante eventos políticos controvertidos (Al-Sarraj & Lubbad, 2018). Según la teoría del encuadre, los periodistas aplican marcos interpretativos, mediante la selección de lenguaje, fuentes, tono y énfasis, para simplificar y guiar la comprensión de asuntos complejos, constituyendo recursos cognitivos compartidos que configuran sistemas de creencias (Ong, 2025; Salazar, 2019). Dada la capacidad de los algoritmos de recomendación para amplificar narrativas específicas, es imprescindible analizar sistemáticamente el contenido promovido en estas plataformas con el fin de identificar patrones discursivos y evaluar su influencia en la percepción y las emociones de la audiencia.

YouTube, una de las plataformas con mayor número de usuarios activos mensuales a nivel mundial (Muhammad, 2019; Statista, 2024), genera enormes volúmenes de datos sobre usuarios, canales, vídeos y comentarios, lo que posibilita el análisis tanto de la producción y recepción de contenidos como de las interacciones sociales (Deubel et al., 2024). En el ámbito geopolítico, estos datos se han aprovechado para estudiar la difusión de información durante la pandemia de COVID-19 (Li et al., 2020), la radicalización en línea (Ledwich & Zaitsev, 2019), y la comparación de emociones en redes sociales rusas durante la guerra en Ucrania (Dean & Porter, 2024).

Recientes investigaciones subrayan que hashtags como *#FreePalestine*, *#CeasefireNOW* y *#Gaza* han sido determinantes en la construcción del discurso público sobre el conflicto palestino-israelí (Nasereddin, 2024). Asimismo, el análisis de narrativas en redes sociales muestra un contraste terminológico. Por ejemplo, el Ministerio palestino emplea etiquetas como *—gaza\_under\_attack, israeliwarcrimes* u *occupation—*, junto a un vocabulario emotivo *—martyrs, civilians, children, aggression, bombing—*, mientras que el Ministerio israelí enfatiza términos como *hamas, terrorists* y *hostages*, a la vez que convoca a *support, solidarity* y denuncia *attack* y *war* (Celik et al., 2024).

Estudios académicos recientes han documentado variaciones y sesgos en la narrativa mediática. Ali et al. (2024) evidencian cómo medios internacionales emplean narrativas parciales, imágenes selectivas y un lenguaje deliberado para condicionar la percepción. Por ejemplo, Al Jazeera mantiene un enfoque neutral, mientras que BBC, France24 y la Voz de América tienden a presentar una perspectiva israelí, a menudo desfavorable para Palestina. Philo & Berry (2005) critican a la BBC por contrastar términos como *militants*

frente a *resistance fighters* en Al Jazeera, omitiendo experiencias de ambos bandos. Asimismo, Al-Sarraj & Lubbad (2018) detectan un sesgo pro-israelí en la cobertura de la guerra de Gaza de 2014, mientras que diversos análisis han señalado sesgos pro-palestinos, lo que ha generado cuestionamientos desde distintos sectores sobre la imparcialidad y el encuadre informativo adoptado por diversos medios. Antonakaki & Ioannidis (2025) resaltan la complejidad de la interconexión temática, operaciones militares, impacto civil, actores políticos y geografía, en plataformas digitales. Aunque la mayoría de estos estudios se basan en análisis cualitativos de muestras limitadas, el enfoque cuantitativo con técnicas de inteligencia artificial permite detectar patrones discursivos de modo sistemático y ofrece propuestas metodológicas innovadoras, todavía poco frecuentes en el análisis de conflictos geopolíticos.

#### **4.2. Procesamiento de lenguaje natural con Deep Learning y su aplicación en el análisis de medios digitales**

La inteligencia artificial (IA) se define como la creación de sistemas capaces de emular funciones cognitivas del cerebro humano, como aprender y resolver problemas. El aprendizaje automático (*machine learning*) es un subcampo de la IA dedicado al desarrollo de algoritmos que extraen patrones y conocimiento de grandes volúmenes de datos. A su vez, el aprendizaje profundo (*deep learning*) constituye una rama del aprendizaje automático que emplea redes neuronales profundas para modelar relaciones complejas (Shinde & Shah, 2018). Una de las áreas de investigación de *machine learning* que ha experimentado un crecimiento notable es el Procesamiento de Lenguaje Natural (PLN), el cual ha permitido diseñar modelos de lenguaje más precisos y eficientes, mejorar la comunicación entre máquinas y humanos, automatizar servicios de comunicación, optimizar motores de búsqueda y analizar de forma sistemática patrones textuales (Sharifani & Amini, 2023).

El PLN ofrece múltiples ventajas, entre las que destacan: eficacia en la clasificación de datos lineales y no lineales; excelente capacidad de generalización textual; eficiencia en el manejo de grandes volúmenes de información; aprendizaje de patrones complejos y no lineales; adaptabilidad a diversos tipos de datos y problemas; reconocimiento de características en datos no estructurados; comprensión del contexto y del significado semántico en el texto; identificación de relaciones entre palabras y frases; extracción de

temas y patrones ocultos; y descomposición de textos en tópicos significativos (Salgado Reyes & Elizabeth Trujillo Moreno, 2024).

El análisis de sentimientos es una rama del PLN que extrae y evalúa automáticamente el contenido textual para clasificar sentimientos con polaridad positiva, neutral o negativa, e incluso para detectar emociones específicas como sorpresa, confianza, anticipación, ira, miedo, tristeza, disgusto, alegría, entre otras (Mao et al., 2024). Esta técnica juega un papel clave en el desarrollo de plataformas sociales, el comercio electrónico y las campañas políticas, entre otros ámbitos, pues permite anticipar el estado de ánimo y la disposición de los usuarios en contextos variados (Mao et al., 2024). Gracias a su valiosa aplicación en los sectores empresarial y académico, el PLN ha cobrado gran relevancia en diferentes disciplinas. En particular, ofrece a los politólogos la oportunidad de aprovechar abundantes corpus preexistentes para profundizar en la caracterización de fenómenos políticos y sociales (Wilkerson & Casas, 2017).

El texto ha sido tradicionalmente una fuente fundamental de datos en la ciencia política; lo que ha cambiado en los últimos años es la posibilidad de analizar de forma cuantitativa corpus textuales cada vez más extensos. Ante este exceso de datos, la comunidad investigadora ha respondido mediante el desarrollo de bibliotecas de análisis de texto de código abierto y accesibles, revolucionando la investigación computacional en ciencias políticas (Wilkerson & Casas, 2017). El flujo diario y en constante aumento de datos procedentes de diversas fuentes dificulta la extracción de información verdaderamente valiosa (Supriyono et al., 2024). El Procesamiento de Lenguaje Natural (PLN) permite estudiar en profundidad la opinión pública y detectar patrones lingüísticos en textos digitales que suelen contener lenguaje informal, jerga y errores ortográficos (Mustofa et al., 2025). En sus inicios, el PLN se basaba en sistemas de reglas y enfoques simbólicos centrados en la gramática y la sintaxis (Supriyono et al., 2024); sin embargo, la aparición de modelos basados en transformadores y técnicas de aprendizaje profundo ha demostrado un gran potencial para mejorar la precisión y consistencia de múltiples aplicaciones de PLN (Supriyono et al., 2024). Albanese et al. (2019) proponen combinar herramientas de PLN para medir cuantitativamente la influencia de los medios de comunicación en la opinión pública, partiendo de la premisa de que su capacidad para reflejar la realidad desde su propia perspectiva determina la importancia relativa otorgada a los distintos temas. Este proceso, conocido como *agenda setting*, suele resumirse así:

“Quizá los medios no te digan qué pensar, sino en qué pensar” (Albanese et al., 2019). Diversos autores implementan técnicas de PLN para enfrentar la desinformación en conflictos geopolíticos. Por ejemplo, Singha et al. (2024) proponen un enfoque basado en redes neuronales artificiales para detectar perfiles falsos de Twitter en estos contextos. En su estudio sobre el conflicto palestino israelí, utilizan *embeddings* generados por BERT para representar el texto relacionado con su investigación (Singha et al., 2024).

Entre las plataformas digitales, YouTube destaca por su capacidad de moldear la forma en que los individuos interactúan sobre una amplia variedad de temas. Su influencia trasciende la simple exposición pasiva: los usuarios participan activamente y conforman una comunidad dinámica e interactiva, lo que convierte a la plataforma en un escenario privilegiado para estudiar emociones, opiniones y comportamientos (Tsiourloni et al. 2024). En conjunto, las plataformas digitales han transformado en profundidad el panorama global, desplazando progresivamente los métodos tradicionales de comunicación (Chalkias et al., 2023). Chalkias et al. (2023) muestran que la combinación de técnicas de agrupamiento temático y análisis de sentimientos permite obtener hallazgos significativos, modelar el contenido generado por los usuarios y mejorar la experiencia comunicativa.

Las técnicas de aprendizaje profundo (*deep learning*) han sido transformadoras en la forma en la que se procesan los textos, debido al avance de arquitecturas como las redes neuronales recurrentes (RNN), las redes de atención y los modelos *transformer*. Estos últimos, como BERT (Devlin et al., 2018), RoBERTa (Liu et al., 2019a), y DeBERTa (He et al., 2020), han evidenciado una capacidad extraordinaria para modelar relaciones semánticas complejas mediante representaciones contextuales del lenguaje (*embeddings*), superando de manera significativa a enfoques tradicionales como LDA, SVM o Naive Bayes en tareas como la clasificación de sentimientos, la detección de emociones y la agrupación temática de textos no estructurados (Galke et al., 2022; M. Kumar et al., 2025).

Los modelos basados en *transformers* han demostrado su habilidad para capturar la polisemia, el contexto y las relaciones semánticas entre palabras y frases dentro de un texto, incluso en presencia de lenguaje informal o sarcástico, lo cual resulta especialmente útil en contextos donde los matices del lenguaje natural son fundamentales para una interpretación adecuada (Naseem et al., 2020). A su vez, estudios han demostrado que los modelos basados en BERT superan a otros enfoques en la detección de relaciones

complejas, como el sarcasmo en conversaciones, al capturar de manera eficiente información sintáctica y semántica en contextos conversacionales (Wallace et al., 2020).

Además, el uso de técnicas de reducción de dimensionalidad como UMAP (*Uniform Manifold Approximation and Projection*), en combinación con algoritmos de agrupamiento como KMeans, ha permitido mejorar la identificación de tópicos latentes en corpus extensos y heterogéneos. Por ejemplo, Mersha et al. (2024) aplican UMAP como técnica de reducción de dimensionalidad combinada con *embeddings* basados en modelos *Transformer*, y demuestran cómo mejora notablemente la agrupación de documentos y la extracción de tópicos coherentes. El estudio de Ulloa (2023) refuerza esta metodología de combinación de *embeddings* generados por modelos de aprendizaje profundo como BERT (*Bidirectional Encoder Representations from Transformers*), junto con UMAP y KMeans, cuyos resultados evidencian la efectividad de estas técnicas en la identificación de tópicos latentes en corpus extensos.

En consecuencia, el aprendizaje profundo se posiciona en la literatura especializada como una metodología particularmente adecuada para el análisis automatizado de grandes volúmenes de texto provenientes de medios digitales. Esta capacidad resulta especialmente valiosa en contextos caracterizados por una alta carga emocional y ambigüedad textual, como los conflictos geopolíticos contemporáneos. Investigaciones recientes que han empleado modelos de *deep learning* para explorar la opinión pública, identificar narrativas de desinformación o analizar la emocionalidad expresada en redes sociales, destacan el potencial de estas herramientas para extraer patrones complejos y socialmente significativos desde una perspectiva computacional (Mustofa et al., 2025; Singha et al., 2024).

#### **4.2.1. Recolección y selección de datos digitales para análisis con PLN**

##### **4.2.1.1. Métodos de recolección y procesamiento de datos de YouTube**

El proceso de extracción de datos de YouTube constituye una etapa fundamental para los análisis basados en procesamiento de lenguaje natural (PLN). Esta recolección puede realizarse mediante la API oficial de la plataforma, la cual permite acceder a comentarios, transcripciones y metadatos de los videos. No obstante, en situaciones donde el uso de la API se ve limitado por restricciones técnicas o de acceso, existen alternativas viables como la extracción de datos directamente desde sitios web, técnica conocida como *web scraping*.

Este método facilita la obtención de información significativa desde fuentes en línea (Lotfi et al., 2021), y puede complementarse con herramientas especializadas diseñadas para la recopilación masiva de datos digitales. Una vez obtenida la información, es indispensable transformarla en un formato estructurado que permita su análisis automatizado. En particular, la conversión del texto extraído de videos y comentarios en datos estructurados constituye un paso esencial para su posterior procesamiento mediante técnicas de PLN.

Finalmente, debe destacarse la relevancia de incorporar una perspectiva ética a lo largo de todo el proceso de recolección y análisis. Aspectos como la privacidad de los datos, el consentimiento de los usuarios y la identificación de posibles sesgos deben ser abordados con especial cuidado. En este sentido, Markham & Buchanan (2012) enfatizan que las consideraciones éticas deben estar presentes en todas las etapas de la investigación digital, dado que los datos en línea, aunque accesibles, involucran a personas reales, muchas veces pertenecientes a comunidades vulnerables.

#### **4.2.1.2. *Recolección de datos mediante interfaz de programación de aplicaciones***

Existen diversas alternativas para recolectar datos de redes sociales. El método manual, si bien factible, requiere un esfuerzo humano significativo y no es escalable para volúmenes grandes de información. Por otro lado, el uso de datos disponibles en línea no siempre es adaptable a todas las investigaciones, y la donación de datos por parte de usuarios o empresas puede introducir sesgos que afectan la validez de los resultados. Por otro lado, la técnica de *web scraping*, aunque eficaz en ciertos contextos, presenta restricciones tanto legales como técnicas que pueden limitar su aplicabilidad.

Ante este panorama, las interfaces de programación de aplicaciones (APIs) de YouTube se consolidan como el método más directo y sistemático para la extracción de datos desde la plataforma (Deubel et al., 2024). Estas interfaces son definidas como “mecanismos que permiten a dos componentes de software comunicarse entre sí mediante un conjunto de definiciones y protocolos” (Amazon Web Services [AWS], n.d.). En particular, la *YouTube Data API v3* ofrece acceso a los datos públicos de la plataforma, permitiendo interactuar con recursos como videos, canales, listas de reproducción, suscripciones y comentarios. Las solicitudes se realizan mediante una clave de acceso (*API key*), y es posible aplicar

filtros y parámetros para consultar o modificar datos en función de variables específicas como subtítulos, regiones, idiomas, miembros, entre otros.

No obstante, esta herramienta presenta ciertas limitaciones operativas. Las cuotas y límites de uso establecidos por la API restringen la posibilidad de realizar extracciones masivas, por lo que es fundamental optimizar las consultas a fin de maximizar la eficiencia sin vulnerar las políticas de uso de la plataforma (Google Developers, n.d.). Aunque estas restricciones no impiden el acceso a grandes volúmenes de datos, su existencia evidencia un cambio estructural en la disponibilidad de información digital. Autores como Trezza et al. (2023) advierten que el escándalo de Cambridge Analytica en 2018 marcó el inicio del fin de la llamada "edad dorada de los datos", lo que se ha visto reflejado en un cambio drástico en las políticas de plataformas sociales. Estas nuevas regulaciones han restringido o incluso prohibido el acceso mediante APIs, fenómeno conocido como "APIcalypse". Los autores señalan que estas transformaciones podrían comprometer la calidad, profundidad y replicabilidad de los estudios basados en datos provenientes de redes sociales.

#### **4.2.1.3. Herramientas para la optimización en buscadores en el análisis de audiencia de YouTube**

La búsqueda de palabras clave en línea se ha consolidado como un indicador relevante para analizar tendencias sociales y comprender las dinámicas de comportamiento humano en entornos digitales (Fan et al., 2014). El servicio *Insights for Search*, que anteriormente permitía rastrear términos en el buscador de Google, fue integrado en 2012 en la plataforma Google Trends. Esta herramienta ofrece recuentos relativos sobre la frecuencia de búsqueda de términos o frases, lo que permite inferir el nivel de interés público sobre determinados temas (You et al., 2023).

Gracias a la provisión de datos en tiempo real, Google Trends se ha convertido en una herramienta útil para identificar temas de discusión predominantes en plataformas digitales, así como para analizar el comportamiento de los usuarios en torno a dichos temas. A su vez, herramientas como *TubeBuddy* operan directamente sobre la interfaz de YouTube, proporcionando funcionalidades orientadas a la optimización del contenido. Entre sus principales capacidades se incluyen el análisis de rendimiento de videos, la interacción con audiencias, el estudio de palabras clave y la mejora del posicionamiento en los motores de búsqueda internos de la plataforma (TubeBuddy, n.d.).

Autores como Waluyohadi & Lopatka (2022) evidenciaron que las palabras clave asociadas a contenidos educativos sobre sistemas de admisión estudiantil en Indonesia, identificadas mediante TubeBuddy, coincidían con los términos registrados simultáneamente en Google Trends. Este hallazgo valida la eficacia de la herramienta en la detección de tendencias y términos relevantes dentro de YouTube.

Además, otras herramientas como *Keyword Tool*, basada en la función de autocompletado de Google, han sido ampliamente adoptadas tanto en el ámbito del marketing digital como en el análisis de audiencias. Estas soluciones permiten extraer sugerencias de búsqueda relevantes, las cuales son útiles para la creación de contenido estratégico, la optimización de motores de búsqueda y la planificación de campañas publicitarias pagadas (Keyword Tool, n.d.). En conjunto, estas herramientas ofrecen un enfoque integral para el análisis del interés del público, constituyendo recursos valiosos en investigaciones centradas en el comportamiento digital y el posicionamiento de contenido audiovisual.

#### **4.2.2. Preprocesamiento del texto**

El preprocesamiento textual es la primera fase del PLN: parte de un corpus sin depurar y devuelve un conjunto de documentos en el que cada oración se descompone en palabras ya normalizadas (Humayoun & Akhtar, 2022). Esta depuración es imprescindible para que las etapas de análisis y modelado sean eficientes. El proceso comienza con operaciones básicas: convertir todo el texto a minúsculas, eliminar signos de puntuación, caracteres especiales, espacios redundantes, URLs, emoticones y entradas duplicadas. Con ello se evitan inconsistencias entre mayúsculas y minúsculas, se reduce el ruido y se minimizan sesgos (Supriyono et al., 2024). A continuación, se aplica la tokenización, que divide el texto en unidades manejables, y la supresión de stopwords, palabras frecuentes, pero escasamente informativas que, en inglés, pueden representar entre el 20 % y el 30 % de los tokens (Tsz et al., 2005). Para unificar las variantes de un mismo término se recurre al stemming, que recorta prefijos y sufijos hasta la raíz, y a la lematización, que transforma cada palabra en su forma canónica de diccionario (Supriyono et al., 2024). Estas técnicas normalizan el vocabulario y mejoran el rendimiento de tareas como la clasificación, el análisis de sentimientos o la traducción automática. Una vez completadas estas etapas, el

texto queda listo para su representación vectorial —por ejemplo, mediante embeddings— y, en consecuencia, para ser procesado por los modelos de PLN.

#### **4.2.3. Representación del texto**

Durante las décadas de 1980 y 1990, el PLN dio un giro decisivo. Paso de los enfoques basados en reglas a métodos estadísticos que aprovechaban grandes corpus y modelos probabilísticos, lo que allanó el camino para la irrupción del aprendizaje automático y, más recientemente, del aprendizaje profundo y los modelos basados en transformadores (Supriyono et al., 2024). La representación textual, piedra angular del PLN, convierte el texto sin procesar en estructuras numéricas que los algoritmos pueden manejar con eficiencia, preservando el significado semántico de palabras, oraciones y su contexto (Supriyono et al., 2024). El texto se transforma en vectores y después se diseñan modelos capaces de procesarlos. Patil et al. (2022) revisan esta evolución desde la década de 1970 y distinguen cuatro familias de técnicas de generación de embeddings: las basadas en reglas (árboles, grafos y gramáticas), las estadísticas (fundamentadas en fórmulas matemáticas para extraer rasgos), las neuronales (el modelo aprende automáticamente patrones textuales) y las neuronales sensibles al contexto (producen embeddings contextuales y modelos pre entrenados). El recorrido comenzó con la coincidencia exacta mediante Gramáticas Libres de Contexto (CFG) y avanzó hacia métodos estadísticos centrados en la frecuencia de palabras, como el One Hot Encoding, la Bolsa de Palabras y los esquemas TF IDF, cuyo principal reto era la alta dimensionalidad. Ese obstáculo se superó con vectores distribucionales generados por redes neuronales, que asignan a cada término una posición en un espacio vectorial continuo; así surgieron embeddings estáticos como Word2Vec, GloVe y FastText, seguidos de alternativas dinámicas como Context2Vec y CoVe, preludio de los modelos basados en arquitecturas Transformer.

Los modelos basados en transformadores han revolucionado la representación del lenguaje natural. A diferencia de los métodos anteriores que asignaban un único vector fijo a cada palabra sin importar el contexto, estos modelos generan representaciones que varían según el contexto, lo que implica que una misma palabra pueda tener diferentes representaciones vectoriales dependiendo de la oración en la que se encuentre, gracias al mecanismo de atención implementado en las capas del modelo que permite que la palabra sea representada tomando en cuenta las relaciones que mantiene con las demás en la

secuencia. Ethayarajh (2019) demuestra que, en promedio, menos del 5% de la varianza en las representaciones contextualizadas de una palabra puede explicarse mediante una incrustación estática, lo que refuerza la premisa de que los modelos contextuales son más precisos y capturan una riqueza semántica que las representaciones estáticas no pueden replicar.

#### 4.2.4. Extracción de tópicos con embeddings BERT y agrupamiento no supervisado

La representación vectorial del texto puede lograrse mediante *embeddings* contextuales, que capturan tanto el significado de las palabras como sus relaciones semánticas según el contexto, gracias a la arquitectura de *transformers* basada en mecanismos de atención (Vaswani et al., 2017). La fórmula de atención escalada “*self-attention*” se representa de la siguiente manera:

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (1)$$

Donde  $Q, K, V$  son las matrices de consulta (*query*), clave (*key*) y valores (*value*), respectivamente, y  $d_k$  es la dimensión del espacio de claves. Esta operación permite asignar pesos diferenciados a cada palabra en función de su relevancia contextual, mediante la función *softmax*.

Devlin et al. (2019) presentaron un nuevo modelo de representación del lenguaje denominado BERT (*Bidirectional Encoder Representations from Transformers*), diseñado para preentrenar representaciones bidireccionales profundas a partir de texto no etiquetado. Este modelo condiciona simultáneamente el contexto izquierdo y derecho en todas las capas, gracias a la arquitectura *transformer* anteriormente descrita. A diferencia de los modelos de lenguaje tradicionales, que suelen ser unidireccionales, BERT emplea modelos de lenguaje enmascarados que permiten generar representaciones contextuales bidireccionales. Cada palabra del texto se representa mediante un vector único, derivado de la suma de tres componentes: *token embeddings*, *segment embeddings* y *position embeddings*. BERT también introduce el token [CLS], que se antepone a cada secuencia de entrada y cuyo vector resultante se utiliza como representación global del contenido textual.

El modelo E5 es una familia de representaciones semánticas basada en BERT que se adapta a una amplia gama de tareas que requieren codificaciones del texto de alta calidad, como la recuperación de información, la clasificación, la detección de similitud semántica y el agrupamiento. A diferencia de otros modelos preentrenados, E5 fue entrenado de forma contrastiva utilizando pares de texto recolectados a gran escala desde fuentes web semiestructuradas, cuidadosamente filtrados para garantizar su consistencia y relevancia (Wang et al., 2022). Este entrenamiento permite al modelo generar *embeddings* altamente informativos y sensibles al contexto, adecuados para la identificación de patrones latentes en corpus extensos y heterogéneos.

No obstante, los vectores generados por estos modelos suelen habitar espacios de alta dimensionalidad, lo que dificulta su interpretación directa y puede afectar el rendimiento de algoritmos posteriores. Por lo tanto, la técnica UMAP (*Uniform Manifold Approximation and Projection*) ha sido ampliamente adoptada como método de reducción de dimensionalidad que, basado en una teoría matemática robusta, permite preservar tanto la estructura local como global del conjunto de datos. UMAP transforma los embeddings originales en un espacio de menor dimensión optimizado para tareas posteriores, como la visualización o la agrupación no supervisada (Badieah et al., 2024; Jackson, 2019; Ma et al., 2025)

Una vez proyectados en este espacio reducido, es posible aplicar algoritmos como *K-means*, que permite organizar los datos en clústeres temáticamente coherentes. Este algoritmo agrupa los puntos de datos en  $k$  conglomerados mediante la minimización de la distancia cuadrada entre cada punto y el centroide de su grupo correspondiente (Saxena et al., 2017). Su función de costo se expresa matemáticamente como:

$$J = \sum_{j=1}^k \sum_{i=1}^n |x_i^{(j)} - c_j|^2 \quad (2)$$

donde  $J$  representa la suma total de las distancias cuadradas (función de costo),  $k$  es el número de clústeres definidos,  $x_i^{(j)}$  es el punto de datos  $i$  asignado al clúster  $j$ , y  $c_j$  es centroide del clúster correspondiente. La expresión  $|x_i^{(j)} - c_j|^2$  representa la distancia euclídea al cuadrado entre el punto  $x_i^{(j)}$  y su centroide  $c_j$ .

Para determinar el número óptimo de clústeres, se han empleado enfoques como el método del codo, que evalúa la tasa de disminución de la distorsión en función del número

de agrupamientos (Yadav et al., 2025), así como el índice de silueta, que mide la coherencia interna de los clústeres y la separación entre ellos, proporcionando una métrica integral de la calidad de la segmentación (Januzaj et al., 2023).

Numerosos estudios respaldan la eficacia de esta combinación metodológica — *embeddings* contextuales, reducción de dimensionalidad y agrupamiento— para el análisis de textos no estructurados, especialmente en escenarios donde la semántica subyacente es compleja y no lineal. Tal es el caso de V. Kumar & Baghel (2025), quienes demuestran que este enfoque supera a modelos probabilísticos tradicionales como LDA o NMF, tanto en coherencia temática como en capacidad interpretativa.

#### **4.2.5. Clasificación de sentimientos personalizada mediante Fine-tuning**

##### **4.2.5.1. *Fine-tuning* en aprendizaje profundo**

El *fine-tuning* es un proceso de entrenamiento supervisado que se aplica sobre modelos previamente preentrenados, con el objetivo de adaptarlos a tareas específicas mediante el uso de datos etiquetados adicionales. Howard & Ruder (2018) introdujeron esta técnica en el ámbito de los modelos de lenguaje como una estrategia de aprendizaje transferido particularmente eficaz para tareas de procesamiento del lenguaje natural (PLN). El procedimiento inicia con un entrenamiento en un corpus de dominio general, lo cual permite al modelo capturar patrones lingüísticos amplios. Posteriormente, se ajusta de manera específica a un conjunto de datos relacionado con la tarea objetivo, adaptando así el clasificador al nuevo dominio mientras se preserva el conocimiento adquirido durante el preentrenamiento.

Durante esta fase de ajuste fino, los modelos emplean una estructura modular basada en componentes denominados *heads* (cabezas), los cuales se sitúan sobre la arquitectura base del modelo. La *head* original puede ser sustituida por otras variantes diseñadas para tareas concretas, agregando una capa de salida específica y, en algunos casos, una función de pérdida adicional. Esta flexibilidad permite al modelo especializarse en diferentes objetivos sin necesidad de un reentrenamiento completo. La estandarización de arquitecturas y nomenclaturas ha permitido que estos modelos se encuentren disponibles

en repositorios como Hugging Face bajo nombres canónicos, lo que facilita su descarga, almacenamiento y ejecución. Esta accesibilidad permite realizar tareas de *fine-tuning* de manera eficiente, mediante apenas unas líneas de código, lo que democratiza el uso de modelos avanzados en proyectos de investigación y aplicaciones prácticas.

#### **4.2.5.2. Modelos de lenguaje preentrenados basados en la arquitectura Transformer**

En la presente investigación se emplearon cuatro modelos de lenguaje preentrenados basados en la arquitectura Transformer, que ha demostrado ser efectiva para tareas de procesamiento de lenguaje natural (Vaswani et al., 2017), seleccionados por su desempeño en tareas de análisis afectivo y su disponibilidad en la plataforma Hugging Face. Todos los modelos utilizados comparten características que permiten una comparación adecuada. Los modelos están entrenados sobre grandes corpus en inglés, distinguen entre mayúsculas y minúsculas, admiten entradas de hasta 512 tokens, y han sido adoptados mediante la clase *AutoModelForSequenceClassification* de la biblioteca Transformers de Hugging Face para la tarea de clasificación emocional multiclase.

La selección de los modelos incluyó variantes que difieren en el preentrenamiento, como el modelo enmascarado, autoregresivo o basado en detección de reemplazos. Esta decisión metodológica busca controlar la variable de complejidad estructural y enfocar la evaluación en el impacto del preentrenamiento sobre la capacidad de detección emocional en contextos sensibles y complejos como el conflicto geopolítico palestino – israelí.

La Tabla 1 presenta una síntesis de las principales características arquitectónicas de los modelos utilizados en este estudio, incluyendo su número de capas, dimensión oculta, cantidad total de parámetros, tipo de arquitectura y el objetivo de preentrenamiento. En adelante, los modelos serán referenciados utilizando la denominación abreviada indicada en la primera columna.

Tabla 1. Características técnicas de los modelos evaluados

Abreviatura	Nombre del modelo	N. capas	Dimensión oculta	Parámetros	Arquitectura	Objetivo de preentrenamiento
RoBERTa	RoBERTa Base	12	768	125 M	Solo codificador (Encoder-only)	Modelado de lenguaje enmascarado (MLM) dinámico
ELECTRA	ELECTRA Base (Discriminator)	12	768	110 M	Solo codificador (Encoder-only)	Detección de tokens reemplazados (RTD)
DeBERTa	DeBERTa V3 Base	12	768	184 M	Solo codificador (Encoder-only)	RTD + atención desentrelazada + codificación relativa
XLNet	XLNet Base Cased	12	768	110 M	Autoregresivo permutado	Modelado de lenguaje permutado (PLM)

Nota: Elaboración propia a partir de documentación oficial de Hugging Face y los artículos originales de cada modelo.

A continuación, se describen las características de los modelos seleccionados:

**RoBERTa:** Modelo de lenguaje desarrollado por Facebook AI como mejora sobre BERT. Utiliza el objetivo de modelado de lenguaje enmascarado (*Masked Language Modeling, MLM*) (Liu et al., 2019). Tomando una oración, el modelo enmascara aleatoriamente el 15% de los tokens de entrada para ser predichos por el modelo. De estos tokens, el 80% se reemplaza por el marcador <mask>, el 10% por un token aleatorio y el 10% se deja sin modificar. A diferencia de BERT, el enmascaramiento se realiza dinámicamente durante el preentrenamiento, es decir, cambia en cada época y no es fijo. De esta manera el modelo aprende representaciones bidireccionales del lenguaje más robustas para tareas de clasificación.

**ELECTRA:** Modelo de lenguaje desarrollado por Google Research (Clark et al., 2020). El modelo fue entrenado como alternativa más eficiente al preentrenamiento tradicional de BERT por medio de un enfoque de detección de tokens reemplazados (*Replaced Token Detection -RTD-*). En vez de predecir palabras enmascaradas, ELECTRA entrena un discriminador con el fin de determinar si cada token de entrada fue reemplazado o no por un generador auxiliar. Este enfoque permite que el modelo aprenda representaciones contextuales profundas con menor coste computacional y mayor eficiencia.

**DeBERTa:** Modelo de lenguaje desarrollado por Microsoft Research (He et al., 2021), diseñado para superar limitaciones de BERT en representación contextual por medio de la introducción del mecanismo de atención desenredada (*disentangled attention*), que separa explícitamente la codificación del contenido de las palabras y su posición en la oración, y un decodificador de máscara mejorado para incorporar posiciones absolutas en la capa de decodificación y predecir los tokens enmascarados en el preentrenamiento del modelo. La versión V3 del modelo incorpora un preentrenamiento basado en RTD inspirado en ELECTRA, lo que permite que el modelo aprenda representaciones más ricas con menos datos, mejorando la eficiencia en términos computacionales.

**XLNet:** Modelo de lenguaje desarrollado por investigadores de Google Brain y Carnegie Mellon University (Z. Yang et al., 2020). El modelo se entrenó combinando las ventajas del modelo autoregresivo y la capacidad de aprender dependencias bidireccionales mediante un objetivo de modelado de lenguaje permutado (PLM), en el que el orden de los tokens es aleatorio durante el entrenamiento, superando limitaciones del preentrenamiento enmascarado utilizado por modelos como BERT, lo que permite capturar relaciones contextuales complejas sin alterar el texto original. XLNet se basa en la arquitectura Transformer-XL, permitiéndole modelar relaciones de largo plazo en el texto por medio de mecanismos de memoria recursiva. Esto permite que el modelo capture dependencias bidireccionales sin requerir la corrupción explícita del texto evitando discrepancias entre el preentrenamiento y el fine-tuning.

La selección de estos cuatro modelos base está respaldada por su arquitectura robusta, eficiencia computacional y rendimiento demostrado en tareas de clasificación emocional. Estudios como el de Cortiz (2021) han evidenciado que modelos como RoBERTa, XLNet y ELECTRA superan a arquitecturas tradicionales como BERT tanto en precisión como en F1-score, particularmente en contextos que requieren la detección de emociones finas y matizadas. En su estudio comparativo, Khurana & Prabhu (2024) evaluaron estos modelos sobre un corpus anotado con emociones y reportaron que DeBERTa alcanzó el mayor F1 score (0.86084), seguido por RoBERTa (0.85610), superando a modelos como BERT y ALBERT. El modelo DeBERTa-v3 ha demostrado su desempeño en tareas de clasificación emocional, lo cual respalda su idoneidad para tareas de clasificación emocional compleja.

Takenaka (2025) también demuestra la solidez de DeBERTa V3 al reconocer tanto emociones frecuentes como categorías escasas, superando incluso a modelos generativos de gran escala como ChatGPT-4o. En el caso de RoBERTa, Patkar et al. (2023) validan su potencial para la tarea de clasificación emocional, especialmente en contextos con desequilibrio de clases y múltiples emociones, demostrando su eficacia en el procesamiento de textos extensos y destacando su capacidad para abordar los desafíos inherentes al análisis emocional en el lenguaje natural, y superando modelos como BERT. Por su parte, XLNet fue seleccionado como modelo base para este estudio por su rendimiento superior en tareas de clasificación emocional en textos breves y espontáneos como los mensajes de Twitter. Alshahrani et al. (2025) reportaron una precisión de hasta 96.45% en la detección de optimismo y pesimismo, atribuyendo su rendimiento a su arquitectura autoregresiva con codificación permutada. En cuanto a ELECTRA, Gu et al. (2022) demostraron que su preentrenamiento basado en detección de tokens reemplazados (RTD) permite una mejor diferenciación emocional frente a BERT, particularmente en textos literarios con ambigüedad emocional.

Esta selección garantiza una coherencia arquitectónica al mantener la base Transformer en todos los modelos, lo que permite comparaciones controladas sin recurrir a modelos generativos como GPT o T5, cuya naturaleza autoregresiva y mayor coste computacional no se alinean con los objetivos de clasificación del presente estudio. Al aplicar fine-tuning con el corpus específico de comentarios de YouTube relacionados con el conflicto palestino-israelí, estos modelos se presentan como idóneos para abordar tareas de clasificación emocional y pueden ser adaptados a las particularidades discursivas del dominio, asegurando una clasificación emocional precisa y relevante en contextos geopolíticos complejos.

#### **4.2.5.3. Evaluación de modelos en PLN**

En tareas de clasificación multiclase es indispensable contar con métricas que permitan evaluar el rendimiento de los modelos de manera rigurosa y comparativa. Esta evaluación suele basarse en métricas estándar que se calculan a partir de los componentes de la

matriz de confusión, definidos en la Tabla 2 y cuyas fórmulas se presentan en la Tabla 3 (Tsiourlini et al., 2024). Las métricas empleadas en la presente investigación son:

- Exactitud (*Accuracy*): proporción entre las muestras clasificadas correctamente y el número total de muestras en el conjunto de evaluación
- Precisión (*Precision*): proporción de verdaderos positivos entre todos los elementos predichos como positivos.
- Exhaustividad (*Recall*): proporción de verdaderos positivos que fueron identificados correctamente.
- F1-score: media armónica entre precisión y *recall*, penalizando los valores extremos de ambas métricas.

Tabla 2. Definición de métricas de evaluación para clasificación emocional

Término	Significado
TP	Verdaderos positivos: la clase fue predicha correctamente como positiva.
FP	Falsos positivos: la clase fue predicha como positiva, pero en realidad era negativa.
FN	Falsos negativos: la clase real era positiva, pero el modelo no la predijo.
TN	Verdaderos negativos: la clase fue predicha correctamente como negativa.

Nota: Elaboración propia. Adaptado de Tsiourlini et al. (2024).

Tabla 3. Fórmulas de métricas de evaluación para clasificación

Métrica	Fórmula
Accuracy	$\frac{TP+TN}{TP+TN+FP+FN}$
Precision	$\frac{TP}{TP+FP}$
Recall	$\frac{TP}{TP+FN}$
F1 Score	$\frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}$

Nota: Elaboración propia. Adaptado de Tsiourlini et al. (2024)

#### **4.2.6. Automatización del flujo de preprocesamiento con *pipelines* en el ciclo de ciencia de datos**

Las etapas secuenciales de la ciencia de datos, desde la adquisición hasta la limpieza, modelado y despliegue se conocen como *Pipeline* en la ciencia de datos, y puede constar de varias etapas y conexiones entre ellas que se definen para realizar tareas específicas y se conectan con otras etapas mediante relaciones de entrada y salida. Esta automatización de procesos de extracción transformación, combinación validación o carga de datos mediante *Pipelines* facilita el flujo de datos, minimizando errores y agilizando procesos de principio a fin (Biswas et al., 2022). Una canalización de datos, conocida técnicamente como “pipeline”, es una secuencia compleja de actividades que manipula datos convirtiendo la salida de un componente en la entrada de otro (Raj et al., 2020). Los procesos relacionados a los datos durante todo su ciclo de vida deben ser monitoreados. La automatización de procesos de extracción, transformación, combinación, validación o carga de datos a través de los *pipelines* facilita la fluidez del ciclo de los datos en cualquiera de sus aplicaciones, como una herramienta de visualización o modelos de aprendizaje, además de minimizar los errores y acelerar los procesos de datos de extremo a extremo (Raj et al., 2020). La implementación de la transformación de datos mediante estos canalizadores se ha vuelto imprescindible dado el crecimiento exponencial de la cantidad de datos generados y consumidos (Georgiev et al., 2024). Este mecanismo desempeña un rol importante en la era actual y se ha convertido en un componente fundamental de las infraestructuras de tecnología e información empresariales. Al recopilar, procesar y transferir datos permiten utilizar la creciente cantidad de información para obtener información valiosa y tomar mejores decisiones (Foidl et al., 2023).

#### **4.3. Antecedentes en el uso de procesamiento de lenguaje natural y aprendizaje profundo para el análisis de conflictos geopolíticos**

El volumen masivo de datos en tiempo real generado por plataformas digitales como YouTube en los contextos geopolíticos contemporáneos, desde múltiples regiones e idiomas, contiene una carga emocional, semántica y política significativa, lo que convierte a estos espacios en fuentes valiosas de información para su análisis mediante técnicas de procesamiento de lenguaje natural (PLN) y aprendizaje profundo. Estas técnicas permiten

comprender dinámicas como la polarización, la desinformación o la percepción pública de actores y eventos (Manuel Hernández López & Cuellar, 2025).

Van Niekerk & Maharaj (2013) señalan que las redes sociales han ejercido un rol determinante en la configuración de escenarios políticos tanto nacionales como globales, como lo evidencian los conflictos postelectorales en Irán en 2009 o las protestas en el norte de África y Medio Oriente en 2011, momentos en los que las plataformas digitales facilitaron la difusión masiva e inmediata de información desde múltiples perspectivas.

El alto volumen de información, la inmediatez y la diversidad de fuentes disponibles en estas plataformas ha despertado el interés de investigadores que aplican técnicas de PLN y aprendizaje profundo para extraer hallazgos relevantes a partir de los datos. La literatura reciente ha empezado a integrar modelos avanzados como BERT, LSTM, y arquitecturas especializadas como ConflIBERT, superando a los modelos tradicionales en tareas complejas como clasificación de eventos violentos y predicción electoral, demostrando que los modelos de lenguaje entrenados con datos específicos del dominio pueden ofrecer mejoras en tareas complejas como el análisis de conflictos políticos (Oyewola et al., 2023; W. Yang et al., 2023). Un gran ejemplo es el estudio de Hu et al. (2022), que introdujeron ConflIBERT, un modelo de lenguaje preentrenado específico para el dominio de violencia política y conflicto, construido mediante un preentrenamiento desde cero y preentrenamiento continuo, utilizando un corpus de textos especializados en conflictos y violencia política.

Diversos estudios han evidenciado la utilidad de estas plataformas para el análisis de contextos geopolíticos mediante PLN y aprendizaje profundo, especialmente a través de una amplia variedad de tareas específicas. Entre estas tareas se encuentra el análisis de sentimientos, la detección de tópicos y narrativas dominantes, la identificación de polarización ideológica y la predicción de resultados electorales.

El análisis de sentimientos ha adquirido una creciente relevancia en el PLN aplicado a contextos geopolíticos, dado que permite identificar emociones dominantes en el discurso público durante situaciones de conflicto. En el contexto de la guerra entre Rusia y Ucrania, por ejemplo, Sinha et al. (2024) emplearon modelos de aprendizaje automático para detectar sentimientos predominantes, y afirman que el entendimiento del comportamiento humano y sus emociones podría ser una ruta o guía para promover la paz en la región, pues en su análisis hallaron que predomina la tensión, ira y frustración en el discurso digital

en la escalada de la guerra en estudio. De manera complementaria, Ramos & Chang (2023) analizaron más de 600.000 tuits vinculados al mismo conflicto, utilizando modelos de aprendizaje profundo para mapear emociones en tiempo real. Esta tendencia en escenarios multilingües también ha sido explorada por Filip et al. (2024), quienes demostraron la eficacia de ajustar modelos de aprendizaje profundo para analizar sentimientos en idiomas de Europa del Este. De igual forma, Imtiaz et al. (2024) aplicaron modelos de aprendizaje profundo a datos extraídos de la red social X para observar las reacciones colectivas en Pakistán tras la destitución del primer ministro Imran Khan, revelando patrones emocionales asociados a la indignación política. Otros conflictos, como el caso sirio, también ha sido objeto de estudio. Lucić et al. (2020) evidenciaron cómo las emociones expresadas en redes sociales asociadas al conflicto sirio influyen en la construcción de percepciones políticas contemporáneas. Finalmente, investigaciones como la de Manuel Hernández López & Cuellar (2025) han llevado el análisis al ámbito de YouTube, donde analizaron más de 250.000 comentarios en YouTube relacionados con el conflicto palestino-israelí, utilizando modelos de aprendizaje profundo para clasificar las posturas ideológicas de los usuarios, permitiendo identificar patrones discursivos y posicionamientos emocionales en YouTube. Estos estudios demuestran que la clasificación emocional permite comprender la evolución del conflicto desde perspectivas sociales y discursivas.

Otro uso importante del PLN en el ámbito sociopolítico es la detección de tópicos y narrativas dominantes, útil en contextos marcados por la violencia o el conflicto. En el contexto colombiano, Vargas-Calderón et al. (2019) desarrollaron un método para descubrir tópicos latentes en tuits de cuentas de noticias para identificar eventos prominentes relacionados con seguridad, crimen y violencia. El estudio reveló el potencial del PLN en el mapeo de dinámica sociales en contextos de alta conflictividad. Asimismo, Liang et al. (2023) desarrollaron el modelo CANTM-AI, un modelo basado en arquitectura de aprendizaje profundo que combina clasificación de información sobre conflictos y descubrimiento de tópicos, incorporando análisis de interpretabilidad. Su propuesta representa un avance significativo en la comprensión estructural de los discursos en eventos conflictivos. Pöhlmann et al. (2025) analizaron documentos de políticas públicas de 23 países utilizando el modelo BERTopic. Este enfoque permitió identificar y comparar narrativas políticas predominantes a nivel nacional, proporcionando una comprensión más

profunda de cómo se construyen y comunican las políticas en diferentes contextos políticos.

El PLN también se ha implementado en la identificación de patrones de polarización ideológica en plataformas digitales. La predicción de inclinaciones políticas de usuarios en plataformas digitales es útil para pronósticos electorales, modelos de dinámica de opinión y para estudiar la dimensión política de la polarización y la desinformación (Fagni & Cresci, 2022). Belcastro et al. (2020) aplicaron redes neuronales iterativas para analizar la polarización discursiva de los usuarios durante campañas electorales, observando una radicalización creciente en los discursos digitales. Además, Fagni & Cresci (2022) propusieron una técnica no supervisada con redes neuronales profundas para aprender representaciones latentes de ideologías políticas a partir del contenido textual en redes sociales, permitiendo proyectar a los usuarios en un espacio ideológico de baja dimensión y facilitando su agrupación según su inclinación política. Asimismo, Hofmann et al. (2022) combinan redes neuronales de grafos con aprendizaje estructurado de dispersión para detectar conceptos polarizados en foros de discusión en línea como Reddit, proporcionando una comprensión profunda de las dinámicas discursivas en comunidades digitales.

Otro campo emergente es la predicción electoral mediante PLN. Oyewola et al. (2023) propusieron el modelo de memoria a corto y largo plazo residual en dos etapas (TSRLSTM), entrenado con datos de Twitter para analizar el sentimiento en las elecciones presidenciales de Nigeria en 2023, con el fin de anticipar resultados electorales. Igualmente, Hashemi (2023) aplicó una red neuronal profunda basada en LSTM, junto con técnicas de PLN y sistemas de información geográfica para clasificar más de 1.3 millones de tuits generados durante las elecciones presidenciales de los EE. UU de 2020. Este enfoque demostró cómo el análisis en plataformas digitales mediante PLN y aprendizaje profundo puede revelar patrones discursivos y relaciones geopolíticas en procesos electorales contemporáneos.

Por último, la clasificación de eventos violentos resulta crucial para las acciones humanitarias. Un ejemplo notable es el estudio de Mohammadi et al. (2023), quienes utilizaron el modelo BERT para clasificar eventos del conflicto armado en Afganistán como fatales o no fatales, basándose en descripciones textuales del conjunto de datos ACLED. Su modelo logró un F1 score de 98,82%, una precisión del 99,6%, y un recall del 98,05%,

demostrando un rendimiento robusto en la detección automatizada de fatalidades. Este enfoque destaca el potencial del PLN y el aprendizaje profundo para abordar tareas críticas de clasificación en contextos de alta conflictividad, permitiendo extraer patrones significativos sin requerir preprocesamientos complejos y generando salidas directamente a partir del texto crudo. Los autores destacan que este tipo de modelos puede contribuir a la formulación de políticas, la asignación de ayuda y la toma de decisiones estratégicas en regiones afectadas por conflictos armados.

Existen desafíos técnicos que afectan la precisión y aplicabilidad de modelos en contextos geopolíticos. Uno de los principales obstáculos es la escasez de conjuntos de datos etiquetados, particularmente en idiomas minoritarios o contextos específicos como conflictos regionales. W. Yang et al. (2023) señalan que los modelos generalistas como BERT presentan limitaciones al aplicarse a tareas especializadas dado que no están entrenados con corpus del dominio de violencia política. A su vez, Imtiaz et al. (2024) resaltan que el análisis de sentimientos presenta desafíos importantes en la etapa del preprocesamiento, como el sesgo inherente durante la etapa de etiquetado de sentimientos.

De igual manera, surgen dilemas éticos en el uso del PLN en el análisis de conflictos geopolíticos. Singh et al. (2024) resaltan preocupaciones relacionadas con la privacidad de los datos, transparencia de los algoritmos y el uso indebido de la tecnología, especialmente en campañas electorales polarizadas. Sumado a esto, surgen críticas en torno al uso de datos abiertos. Voytek (2017) advierte que existe el riesgo de que investigadores sin relación con el diseño original del estudio utilicen información recopilada por terceros para fines distintos, sin respetar principios de consentimiento o colaboración. A su vez, Romero-Rodríguez et al. (2021) alertan sobre el refuerzo de sesgos ideológicos mediante algoritmos de recomendación, que contribuyen a la fragmentación discursiva y a la creación de burbujas filtro. De Faveri et al. (2023) analizaron la influencia de bots en Twitter durante las elecciones generales italianas de 2022, y revelaron cómo estas cuentas automatizadas amplificaron narrativas asociadas al conflicto entre Rusia y Ucrania y contribuyeron a la polarización política. Además de los riesgos asociados a la privacidad y la transparencia, también se plantean preocupaciones sobre el impacto del PLN y los algoritmos sociales en la calidad del debate público. Kaiser et al. (2022) afirman que existe un crecimiento en la inquietud en torno al deterioro del discurso político en línea, motivando

a investigadores sobre si los medios sociales realmente promueven la democracia liberal o, por el contrario, contribuyen a la polarización y a la reducción del espacio para el entendimiento mutuo, aspectos clave a tener en cuenta cuando se aplican modelos de PLN para intervenir, clasificar o amplificar discursos en contextos de conflicto. Estos aspectos evidencian que el PLN en entornos digitales debe considerar tanto la eficiencia técnica como las implicaciones sociales, políticas y éticas.

La revisión de la literatura (ver Tabla 4) evidencia que el PLN está adquiriendo relevancia en el análisis de contextos geopolíticos. Diversas investigaciones han demostrado que los modelos de aprendizaje profundo superan a los modelos tradicionales de aprendizaje automático en tareas complejas de clasificación de texto, análisis de sentimientos y detección de tópicos. Este avance representa una oportunidad significativa para los investigadores en ciencia política y estudios internacionales, al permitir una exploración más precisa y automatizada de las dinámicas discursivas en redes sociales. Petridis (2024) evaluó el rendimiento de modelos basados en transformers frente a algoritmos tradicionales, observando mejoras sustanciales en métricas de precisión y F1. Particularmente, el modelo BERT alcanzó una precisión del 85.16%, evidenciando su capacidad para capturar información contextual y su eficacia en tareas complejas de PLN. Estos resultados refuerzan el papel de los modelos preentrenados como herramientas clave en el análisis automatizado del discurso político en plataformas digitales. Sin embargo, pocos estudios han aplicado técnicas de PLN y aprendizaje profundo al modelamiento de tópicos o a la clasificación emocional en plataformas como YouTube, específicamente en el caso del conflicto palestino-israelí en idioma español. Esta brecha evidencia una oportunidad para futuras investigaciones que aborden el análisis de narrativas geopolíticas desde una perspectiva multilingüe y multimodal.

Tabla 4. Revisión de literatura de la aplicación de PLN y DL en conflictos geopolíticos

Autor	Año	Conflicto	Fuente de datos	Modelo	Tarea
Hu et al.	2022	Violencia política general	Twitter + corpus especializado	ConflBERT	Clasificación de eventos violentos
Sinha et al.	2024	Rusia-Ucrania	Twitter	Modelos ML tradicionales	Análisis de sentimientos
Ramos & Chang	2023	Rusia-Ucrania	Twitter	Deep learning	Análisis emocional en tiempo real
Filip et al.	2024	Rusia-Ucrania	Multilingüe (Europa del Este)	Deep learning multilingüe	Análisis de sentimientos
Imtiaz et al.	2024	Pakistán - Crisis política	Twitter	Deep learning	Análisis emocional colectivo
Lucić et al.	2020	Siria	Redes sociales	Modelos tradicionales	Percepciones emocionales
Manuel Hernández López & Cuellar	2025	Palestina-Israel	YouTube	Modelos de aprendizaje profundo	Clasificación ideológica y emocional
Vargas Calderón et al.	2019	Colombia - Seguridad/Violencia	Twitter	PLN (descubrimiento de tópicos)	Detección de tópicos latentes
Liang et al.	2023	Conflictos generales	Varios (documentos + redes)	CANTM-AI (Transformer híbrido)	Descubrimiento de tópicos y clasificación
Pöhlmann et al.	2025	Políticas públicas	Documentos oficiales	BERTopic	Comparación de narrativas nacionales
Fagni & Cresci	2022	Elecciones polarizadas	Twitter	Red neuronal profunda	Predicción ideológica
Belcastro et al.	2020	Campañas electorales	Twitter	Redes neuronales iterativas	Polarización discursiva
Hofmann et al.	2022	Debates online (Reddit)	Reddit	Graph Neural Networks	Detección de conceptos polarizados
Oyewola et al.	2023	Nigeria - Elecciones 2023	Twitter	TSRLSTM	Predicción electoral
Hashemi	2023	EE.UU. - Elecciones 2020	Twitter	LSTM + PLN + GIS	Clasificación electoral
Singha et al.	2024	Palestina-Israel	Twitter	BERT + embeddings	Detección de perfiles falsos
Mersha et al.	2024	General	Corpus temáticos	Transformers + UMAP + KMeans	Agrupación de documentos
Ulloa	2023	General	Corpus temáticos	BERT + UMAP + KMeans	Detección de tópicos latentes
Mohammadi et al.	2023	Conflicto Afganistán	ACLED	BERT	Clasificación de eventos fatales

Nota: Elaboración propia

#### **4.4. Brecha de conocimiento y aporte de la investigación**

La investigación representa un avance significativo en el uso de técnicas de PLN y aprendizaje profundo para el análisis de conflictos geopolíticos en plataformas digitales. Si bien existe un desarrollo metodológico considerable en el área del PLN y la clasificación de emociones mediante modelos basados en aprendizaje profundo, su aplicación sistemática en el estudio de conflictos continúa siendo limitada, especialmente en el ámbito hispanohablante. La mayoría de los estudios disponibles están escritos en inglés y se enfocan principalmente en la red social X (antes Twitter), debido a su uso extendido en la esfera política y a la accesibilidad de sus datos. Esta tendencia ha dejado de lado otras plataformas digitales, como YouTube, así como perspectivas más amplias e integrales sobre los conflictos. Asimismo, son escasos los trabajos que emplean modelos tipo Transformer para el análisis combinado de narrativas temáticas y emociones multiclase en plataformas audiovisuales, particularmente en idioma español y en contextos complejos como el conflicto palestino-israelí. A pesar de la creciente disponibilidad de modelos preentrenados, pocos estudios han explorado su aplicación integrada en flujos automatizados que permitan detectar, visualizar y analizar patrones discursivos y afectivos en simultáneo. Por lo tanto, la presente investigación propone un enfoque computacional riguroso y contextualizado que busca reducir dicho vacío. Se desarrolló un pipeline robusto, replicable y modular que integra técnicas de PLN, aprendizaje profundo, análisis semántico y una etapa avanzada de fine-tuning supervisado de modelos Transformer para la clasificación de emociones personalizadas, adaptadas al contexto específico del conflicto. Este fine-tuning se realizó sobre un conjunto curado y balanceado de aproximadamente 2.300 ejemplos etiquetados, logrando métricas destacadas en validación, lo cual respalda la viabilidad técnica del modelo. Sin embargo, dado el tamaño limitado del conjunto de entrenamiento, el modelo no se aplicó a la totalidad del corpus de comentarios reales extraídos desde YouTube, pues los resultados no serían suficientemente confiables para el análisis a gran escala. Esta decisión metodológica refleja un enfoque ético y riguroso, evitando generalizaciones inapropiadas y reconociendo los límites de extrapolación de modelos entrenados con datos reducidos. El análisis sí abarcó las narrativas construidas en los videos y el mapeo temático mediante embeddings contextuales, reducción de dimensionalidad y clustering, lo que permitió captar con mayor precisión la estructura

discursiva en una plataforma altamente influyente, pero aún poco explorada en estudios computacionales sobre conflictos. Además, la incorporación de una estructura categorial por tipo de canal ofrece un marco de comparación valioso para examinar divergencias y convergencias discursivas entre distintos emisores. Por lo tanto, se demuestra que es posible aplicar técnicas avanzadas provenientes de la ciencia de datos para observar cómo se construye y segmenta el discurso digital en torno a un conflicto geopolítico. Este trabajo contribuye a la literatura académica en español mediante una propuesta técnica, ética y aplicada, con potencial de ser replicada y escalada en futuros estudios que cuenten con anotaciones emocionales más extensas. Asimismo, promueve un enfoque sensible y responsable en el análisis de datos originados en contextos marcados por la violencia, la polarización y la disputa narrativa.

## **5. Hipótesis**

El uso de métodos de procesamiento de lenguaje natural y aprendizaje profundo permitirá agrupar los temas predominantes en las noticias de YouTube sobre el conflicto palestino-israelí y analizar las emociones de los usuarios interactuantes, facilitando la identificación de tendencias discursivas y diferencias en la forma en que se presenta y se percibe la información en la plataforma.

## **6. Variables**

Se definieron las variables para analizar la narrativa relacionada con el conflicto palestino-israelí en la plataforma digital YouTube. El análisis se estructuró a partir de dos conceptos fundamentales. Por un lado, la narrativa en plataformas digitales, entendida como la forma en que individuos, organizaciones y otras entidades utilizan entornos digitales para construir y difundir mensajes sobre acontecimientos sociopolíticos (Zogan et al., 2024). Por otro lado, la detección de emociones, definida como la tarea de identificar automáticamente valencia, emociones y otros estados afectivos expresados en el texto mediante técnicas de procesamiento del lenguaje natural (Mohammad, 2015). A partir de estos conceptos, se identificaron tres variables principales: tópico dominante, narrativa dominante y emoción predominante, cuyas dimensiones, indicadores, tipo de dato y clasificación dentro del modelo de análisis se presentan en la Tabla 5.

*Tabla 5. Operacionalización de variables*

Concepto	Dimensión	Variable	Tipo de dato	Indicador	Clasificación	Definición operacional
Narrativa en plataformas digitales	Contenido temático	Tópico dominante	Cualitativa nominal	Clúster semántico	Independiente	Agrupamiento de videos según embeddings BERT + reducción UMAP + K-means
	Perspectiva narrativa	Narrativa dominante	Cualitativa nominal	Interpretación discursiva del clúster	Dependiente	Análisis cualitativo del enfoque discursivo presente en cada clúster
Percepción emocional	Emoción	Emoción predominante	Cualitativa nominal	Etiqueta emocional	Dependiente	Clasificación automática de emociones mediante modelo fine-tuned con datos etiquetados

*Nota: Elaboración propia*

En el modelo propuesto, el tópico dominante se considera la variable independiente, ya que agrupa los videos en función de patrones semánticos latentes extraídos con modelos de lenguaje (embeddings BERT), reducción de dimensionalidad (UMAP) y agrupamiento (K-means). A partir de estos tópicos, se identifica la narrativa dominante como una variable dependiente, determinada mediante interpretación cualitativa del discurso predominante en cada grupo temático. Finalmente, la emoción predominante se clasifica también como variable dependiente, pues se cuantifica en los comentarios vinculados a cada video y se espera que varíe en función tanto del tópico como de la narrativa interpretada.

## 7. Metodología

### 7.1. Enfoque y alcance de la investigación

Esta investigación adopta un enfoque mixto que integra métodos cuantitativos y cualitativos para analizar las noticias de YouTube sobre el conflicto palestino-israelí. En el plano cuantitativo, se aplicaron técnicas de procesamiento de lenguaje natural para extraer, estructurar y analizar el contenido textual de los videos, mientras que, en el ámbito cualitativo, la revisión teórica y la interpretación de resultados permiten explorar los significados y enfoques discursivos presentes en el corpus.

El estudio se desarrolló en dos etapas principales. En primer lugar, se implementó un modelo de tópicos para identificar y caracterizar las narrativas predominantes en los videos noticiosos, diferenciadas según la categoría del emisor. A partir de esa segmentación, se extrajeron los comentarios asociados a los videos de cada clúster temático. Sobre una muestra representativa de esos comentarios, se realizó un proceso de etiquetado manual de emociones, que sirvió como base para entrenar y ajustar cuatro modelos de clasificación emocional mediante técnicas de aprendizaje profundo. El objetivo de esta segunda fase fue comparar el desempeño de distintas arquitecturas y determinar cuál se adapta mejor al análisis afectivo de discursos digitales en contextos de conflicto. Cabe destacar que, si bien los modelos fueron entrenados mediante *fine-tuning* con éxito, no se aplicaron de forma masiva al corpus completo, ya que el enfoque de esta etapa fue principalmente evaluativo y exploratorio.

El análisis se limita a noticias publicadas entre el 7 de octubre de 2023 y el 27 de marzo de 2025, periodo especialmente relevante por su intensidad informativa. Se incluyeron únicamente videos clasificados como noticias, con sus respectivas transcripciones, comentarios y metadatos, excluyendo contenido de entretenimiento, desinformación o discursos personales. Con esta estrategia metodológica, se busca ofrecer una caracterización integral de las narrativas y emociones que circulan en torno al conflicto, y sentar las bases para futuras investigaciones en el campo de las narrativas digitales y el análisis afectivo automatizado.

## **7.2. Aplicación de la metodología CRISP-DM**

Este trabajo se desarrolla bajo la metodología CRISP-DM (Cross Industry Standard Process for Data Mining) (Schröer et al., 2021), ampliamente adoptada en proyectos de análisis de datos por su enfoque estructurado y adaptable a distintas industrias, incluyendo el análisis de contenidos digitales. CRISP-DM se escogió por su estructura robusta y la integración de fases de comprensión del negocio, modelado y evaluación, fundamental para el análisis de la presenta investigación. consta de seis fases, de las cuales en este estudio se implementaron cinco (ver Ilustración 1). A continuación, se describen brevemente:

Ilustración 1. Ciclo de vida de la metodología CRISP-DM.



Nota: Tomado del Instituto de Ingeniería del Conocimiento (IIC, 2021)

**1. Entendimiento del negocio:** Se contextualiza el conflicto palestino-israelí y se examina su representación y debate en la plataforma YouTube.

**2. Entendimiento de los datos:** Se exploran videos y comentarios para identificar patrones discursivos, fuentes recurrentes y características generales del contenido.

**3. Preparación de los datos:** Se recolecta, limpia y preprocesa el corpus textual. Los comentarios son normalizados y etiquetados con categorías emocionales.

**4. Modelado:** Se aplican técnicas de procesamiento de lenguaje natural (PLN), como BERT embeddings para la representación semántica, UMAP para reducción de dimensionalidad y K-Means para el agrupamiento temático. Además, se entrenan y comparan cuatro modelos preentrenados de arquitectura *transformer* para la clasificación emocional.

**5. Evaluación:** Se analiza la coherencia temática de los clústeres y la precisión de los modelos clasificadores, considerando la pertinencia de los hallazgos respecto al contexto del conflicto.

La fase de despliegue, que implica la integración de los modelos en sistemas productivos, no fue considerada dentro del alcance de esta investigación.

### 7.3. Población y muestra

#### 7.3.1. Población

La población de la presente investigación abarca todo el conjunto de videos y comentarios en idioma inglés relacionados con el conflicto palestino-israelí en la plataforma digital YouTube. La población comprende el contenido de canales digitales publicados desde el 7 de octubre de 2023 hasta el 27 de marzo de 2025

#### 7.3.2. Muestra

La muestra se generó mediante recolección automatizada y muestreo estratificado por canal de YouTube, con el fin de asegurar representatividad temática y equilibrio de fuentes. Se recopilieron 8.566 videos sobre el conflicto palestino-israelí, aplicando filtros de calidad y límite de videos por canal (máximo 20 diarios y 5 por iteración). Los canales fueron clasificados manualmente en cuatro categorías (palestinos, israelíes, internacionales e internacionales con enfoque regional) y se resumen en la Tabla 6 junto con el número de videos recolectados por canal.

Tabla 6. Distribución de videos recolectados por categoría de canal

Canal	Cantidad de videos
Canales internacionales regionales	3.814
Canales internacionales	2.364
Canales palestinos	1.345
Canales israelíes	1.043
<b>Total</b>	<b>8.566</b>

Nota: Elaboración propia

Tras aplicar técnicas de modelado temático no supervisado a las transcripciones, se identificaron tópicos discursivos y se seleccionaron aleatoriamente hasta 50 videos por tópico y categoría. De estos videos, se extrajeron hasta 80 comentarios relevantes mediante la API de YouTube, filtrando por interacción, calidad lingüística y pertinencia. La muestra final para el fine-tuning estuvo compuesta por 2.283 comentarios únicos (ver Tabla 7), los cuales fueron curados manualmente y etiquetados según un esquema emocional personalizado desarrollado para esta investigación. Dicho tamaño se definió

estratégicamente considerando tanto la viabilidad computacional del entrenamiento supervisado como el compromiso ético con la calidad del etiquetado manual, aspectos desarrollados en los apartados “Brecha de conocimiento” y “Discusión”.

*Tabla 7. Distribución de emociones en la muestra etiquetada*

<b>Emoción</b>	<b>Cantidad de comentarios</b>
Ira	512
Tristeza	494
Esperanza	454
Sarcasmo	453
Resistencia	370
<b>Total</b>	<b>2.283</b>

*Nota: Elaboración propia*

#### **7.4. Instrumentos de recolección de la información**

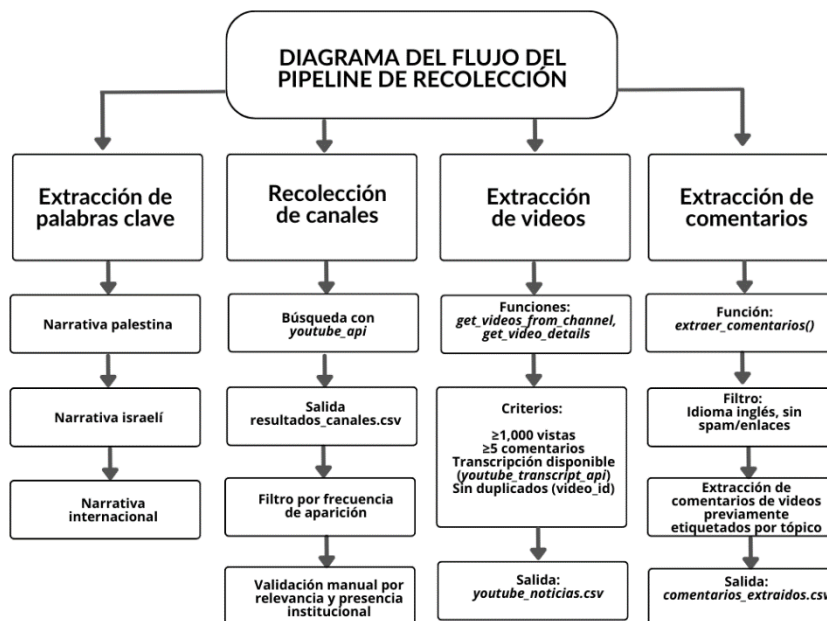
La recolección de información se llevó a cabo mediante la combinación de herramientas digitales de extracción de palabras clave, la API de YouTube y librerías especializadas de Python como *googleapiclient* y *youtube\_transcript\_api*.

Las herramientas *TubeBuddy*, *Keywordtool.io* y *Google Trends* permitieron obtener un conjunto inicial de palabras clave asociadas al conflicto palestino-israelí. Inspirado en enfoques del análisis crítico del discurso (Van Dijk, 1999) y en estudios sobre la construcción de narrativas en contextos de crisis (Rheindorf & Wodak, 2018), se realizó una clasificación manual de dichas palabras clave en tres categorías semánticas discursivas: términos alineados con la narrativa palestina, términos alineados con la narrativa israelí, y términos de carácter internacional o neutral, frecuentemente utilizados por organismos multilaterales o medios globales. Esta categorización se empleó como base para identificar y clasificar los canales de YouTube más representativos, y se detalla en la sección 8.1. A partir de dichas palabras clave identificadas, se diseñó un pipeline que ejecutó búsquedas automáticas en YouTube con el fin de identificar canales relevantes categorizados con base en su contenido predominante. Los resultados se almacenaron en el archivo **extracción\_canales.csv** y se depuraron manualmente considerando tanto la

frecuencia de aparición como la trayectoria del medio en la cobertura del conflicto. Dada la ausencia de estudios sistemáticos comparativos de canales en YouTube con relación al conflicto en estudio, se priorizaron medios con una trayectoria reconocida en cobertura del conflicto israelí-palestino y que representan distintas posiciones geopolíticas, lo cual permite una mayor diversidad narrativa.

El proceso completo de recolección, desde la extracción de palabras clave hasta la obtención de comentario, se resume de forma esquemática en la Ilustración 2, que presenta el flujo del pipeline de recolección implementado para esta investigación.

Ilustración 2. Diagrama del flujo del pipeline de recolección



Nota: Elaboración propia

Posterior a la selección de los canales representativos, se ejecutó un pipeline automatizado que empleó *Google API Client* para la extracción de videos, metadatos (ID único del video, título, nombre del canal, fecha de publicación, número total de visualizaciones, número total de “me gusta”, número total de comentarios, transcripción del video y URL) y transcripciones automáticas desde el 7 de octubre de 2023, fecha que marcó el inicio del conflicto contemporáneo, hasta el 27 de marzo de 2025. Se definieron umbrales mínimos de interacción (al menos 1.000 vistas y 5 comentarios por video), y se

descartaron videos sin transcripción disponible. Para evitar duplicados, se implementó un sistema de identificadores únicos (*video\_id*) y puntos de control incrementales (*checkpoints*). Además, se utilizó una rotación de 14 claves API para optimizar el uso de la cuota de consultas. El flujo completo se estructuró en funciones específicas como: *get\_youtube\_service*, *get\_transcription*, *get\_videos\_from\_channel*, *get\_video\_details*, y *main*. La Tabla 8 resume los criterios de inclusión y exclusión de los videos seleccionados.

Tabla 8. Criterios de inclusión y exclusión de videos considerados en el análisis

Criterios de inclusión	Criterios de exclusión
Publicado a partir del 7 de octubre de 2023	Publicado antes del 7 de octubre de 2023
Idioma inglés	Otros idiomas
Transcripción disponible	Transcripción no disponible
Más de 1.000 visualizaciones	Menos de 1.000 visualizaciones
Más de 5 comentarios	Menos de 5 comentarios
Canales preseleccionados	Canales sin cobertura del conflicto

Nota: Elaboración propia

A partir de los videos previamente categorizados y etiquetados temáticamente mediante el modelado no supervisado, se aplicó una extracción de comentarios. Para cada uno de los videos seleccionados por tópico y categoría (hasta 50 videos por tópico), se descargaron hasta 80 comentarios por video, priorizando aquellos con mayor interacción. El filtrado de calidad textual excluyó comentarios irrelevantes o vacíos de contenido como aquellos con enlaces, spam, hashtags promocionales o menciones, así como textos en idiomas distintos al inglés. No se aplicó un umbral rígido de longitud, pero si se descartaron comentarios excesivamente breves, sin carga semántica o sin coherencia gramatical mínima. La detección de idioma se llevó a cabo con *langdetect* y se evitó la duplicación mediante control de identificadores únicos (*comment\_id*) y registros acumulativos de extracción incremental.

Como resultado, se extrajo un corpus inicial de 164.123 comentarios únicos, almacenados en el archivo *comentarios\_extraidos.csv*. Para el proceso de etiquetado, se

seleccionó una muestra de 8.830 comentarios, distribuidos según la representación combinada de tópicos y categorías de canal. Esta muestra se generó con la finalidad de preservar la proporcionalidad discursiva de cada grupo temático, evitando sesgos. La tabla 9 resume los criterios de inclusión y exclusión de los comentarios seleccionados para el modelamiento de emociones.

*Tabla 9. Criterios de inclusión y exclusión de comentarios analizados*

<b>Criterios de inclusión</b>	<b>Criterios de exclusión</b>
Idioma inglés	Comentarios en otros idiomas
Comentarios únicos	Comentarios duplicados o vacíos
Contenido textual claro, relevante y procesable	Texto irrelevante, con ruido, spam o solo emojis
Comentarios dentro de categorías temáticas y clústeres semánticos previamente definidos	Comentarios fuera del universo temático (videos no seleccionados)

*Nota: Elaboración propia*

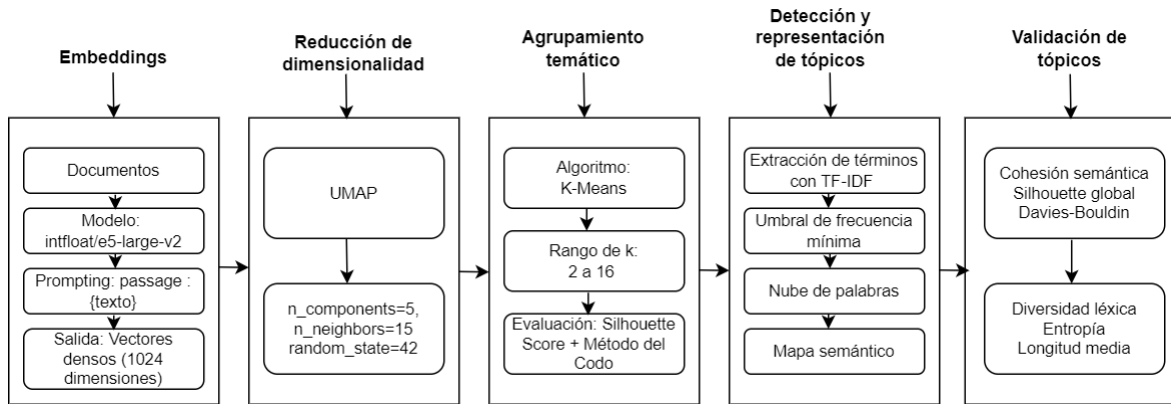
Tras el proceso de limpieza y procesamiento, se procedió al ajuste fino (*fine-tuning*) del modelo utilizando los 2.283 comentarios únicos previamente descritos en la sección 7.3.2, los cuales fueron curados manualmente y etiquetados según un esquema emocional personalizado.

### **7.5. Técnicas para el análisis de la información**

El proceso de análisis se estructuró en dos fases. En la primera fase, se aplicaron técnicas de modelado de tópicos para descubrir patrones temáticos latentes en los datos mediante algoritmos no supervisados. Esta etapa permitió agrupar las transcripciones de los videos según su contenido semántico dominante, generando una representación estructurada del corpus. En la segunda parte, a partir de los tópicos previamente detectados, se extrajeron comentarios representativos de cada grupo temático y se aplicó una serie de modelos de clasificación emocional, entrenados mediante fine-tuning, con el fin de analizar los aspectos afectivos de las narrativas.

La implementación del modelado de tópicos se realizó por medio de un pipeline estructurado por categorías previamente clasificadas en el conjunto de datos (ver Ilustración 3)

Ilustración 3. Esquema del proceso del modelado de tópicos



Nota: Elaboración propia

El proceso fue diseñado para transformar las transcripciones de los videos en vectores semánticos, reducir su dimensionalidad y agruparlos temáticamente mediante un algoritmo de aprendizaje no supervisado. Se implementó el modelo de lenguaje preentrenado intfloat/e5-large-v2, disponible en Hugging Face bajo el usuario intfloat y cargado mediante la librería *transformers*. Este Transformer de 24 capas, entrenado con *weakly-supervised contrastive pre-training*, genera embeddings de 1.024 dimensiones óptimos para recuperación de información, similitud semántica y clustering de documentos. El procesamiento se ejecutó sobre GPU para acelerar la inferencia, y se empleó la plantilla de prompting «*passage:{texto}*», lo que refuerza la captación del contexto semántico; la entrada se limitó a 512 tokens y el modelo devolvió vectores densos normalizados que se comparan mediante similitud coseno. Se eligió este modelo por su alto rendimiento abierto ( $\approx 335$  M parámetros), su robustez frente a datos ruidosos y su integración directa con *transformers* y *sentence-transformers*, lo que evita entrenamientos costosos desde cero. Los embeddings resultantes alimentaron la reducción de dimensionalidad y el agrupamiento para la detección de tópicos, proporcionando una representación semántica coherente de transcripciones.

La reducción de la dimensionalidad se realizó con UMAP (*Uniform Manifold Approximation and Projection*), fijando  $n\_components=5$  y  $n\_neighbors=15$ , lo que permitió preservar la estructura local y generar una proyección compacta adecuada para el agrupamiento posterior. Estas configuraciones fueron adoptadas siguiendo experiencias

previas en investigaciones temáticas basadas en embeddings, donde se ha demostrado que dicha combinación proporciona un equilibrio eficaz entre la estructura local y global de los datos. Navarro & Homayouni (2023) justifican este uso afirmando que “ $n\_components=5$  ayuda en la visualización y análisis mientras preserva la estructura esencial de los datos”, y que “ $n\_neighbors=15$  proporciona un equilibrio entre estructura local y global, permitiendo que se revelen patrones significativos” en tareas de clusterización temática a partir de textos embebidos. Se estableció  $random\_state=42$  para asegurar reproducibilidad. Para el agrupamiento temático se utilizó K-Means sobre la proyección reducida. Se evaluaron valores de  $k$  desde 2 hasta 16 mediante el Silhouette Score y la Suma de Errores Cuadráticos (SSE). La selección óptima del número de clústeres por categoría se realizó con ayuda del método del codo (KneeLocator), considerando tanto métricas objetivas como criterios de interpretabilidad. Posteriormente, se entrenó el modelo final con el mejor valor de  $k$  por categoría. La validación se completó mediante análisis temporal de tópicos, generación de nubes de palabras (bi-gramas) y revisión cualitativa de fragmentos representativos por tópico utilizando distancias euclídeas y coseno. Para evaluar la calidad semántica de los tópicos se calcularon múltiples métricas complementarias: cohesión mediante distancias euclídeas y coseno, separabilidad de centroides, y métricas de clusterización como Davies-Bouldin y Silhouette global. En el plano lingüístico, se calcularon la diversidad léxica, la longitud promedio de las transcripciones, y la entropía léxica por tópico, permitiendo caracterizar el lenguaje de cada grupo. Además, se midió la dominancia narrativa, es decir, el peso relativo del tópico más frecuente dentro de cada categoría. A su vez, se calcularon las palabras más representativas por cada tópico con una estrategia basada en TF-IDF con unigramas y bigramas, empleando un umbral de frecuencia mínima relativa para evitar términos poco representativos. Estas etiquetas fueron también validadas mediante el cálculo de coherencia semántica (*Coherence Score  $c_v$* ), utilizando diccionarios de Gensim.

Finalmente, los resultados se visualizaron con nubes de palabras por tópico, mapas semánticos UMAP en 2D, gráficos de evolución temporal y heatmaps comparativos de bigramas por categoría. La Ilustración 4 describe el proceso de análisis del modelamiento de tópicos.

*Ilustración 4. Extracción de tópicos con embeddings y selección de clústeres*

---

```

1: Entrada: Conjunto de documentos  $D = \{d_1, d_2, \dots, d_N\}$  con etiquetas de
   categoría  $C$ 
2: Inicializar modelo de embeddings  $f : d_i \mapsto \mathbf{e}_i \in \mathbb{R}^d$ 
3: Definir funciones de limpieza  $g$ , lematización  $l$  y filtrado  $s$ 
4: for cada categoría  $c \in C$  do
5:    $D_c \leftarrow \{d_i \in D \mid \text{categoría}(d_i) = c\}$ 
6:    $D_c \leftarrow g(l(s(D_c)))$  ▷ Limpieza, lematización y filtrado
7:    $D_c \leftarrow \{d_i \in D_c \mid \text{idioma}(d_i) = \text{inglés}\}$ 
8:   for cada  $d_i \in D_c$  do
9:      $\mathbf{e}_i \leftarrow f(d_i)$  ▷ Obtener embedding con prompting passage:
10:   end for
11:    $E \leftarrow \{\mathbf{e}_1, \dots, \mathbf{e}_n\}$ 
12:    $E_{\text{red}} \leftarrow \text{UMAP}(E)$  con  $n\_components = 5$ ,  $n\_neighbors = 15$ 
13:   for  $k = 2$  hasta 15 do
14:     Aplicar KMeans con  $k$  clústeres para obtener etiquetas  $\mathbf{z}_k$ 
15:     Calcular silueta  $s(k) = \text{silhouette}(E_{\text{red}}, \mathbf{z}_k)$ 
16:     Calcular inercia  $J(k) = \sum_{i=1}^n \|\mathbf{e}_i - \mu_{z_k(i)}\|^2$ 
17:   end for
18:    $k^{\text{sil}} \leftarrow \arg \max_k s(k)$ ;  $k^{\text{codo}} \leftarrow \text{knee}(J(k))$ 
19:   Seleccionar  $k_{\text{final}}$  según la lógica de categoría
20:   Aplicar KMeans con  $k_{\text{final}}$  para obtener tópicos  $T = \{t_1, \dots, t_k\}$ 
21:   for cada tópico  $t_j$  do
22:     Calcular centroide  $\mathbf{c}_j = \frac{1}{|t_j|} \sum_{d_i \in t_j} \mathbf{e}_i$ 
23:     Calcular distancia euclídea y coseno entre  $\mathbf{c}_j$  y cada  $\mathbf{e}_i$ 
24:     Seleccionar top-5 documentos más cercanos por métrica
25:     Calcular TF-IDF de bigramas:  $\mathbf{B} \in \mathbb{R}^{n_j \times m}$ 
26:     Extraer top- $b$  bigramas con mayor peso medio
27:     Evaluar coherencia semántica  $c_v$  con Gensim
28:   end for
29:   Visualizar UMAP 2D, evolución temporal, nubes de palabras y heatmaps
30:   Guardar resumen de resultados,  $k$ , criterio y distribución de tópicos
31: end for
32: Salida: Conjunto  $\{T_c\}$  de tópicos por categoría con ejemplos representativos

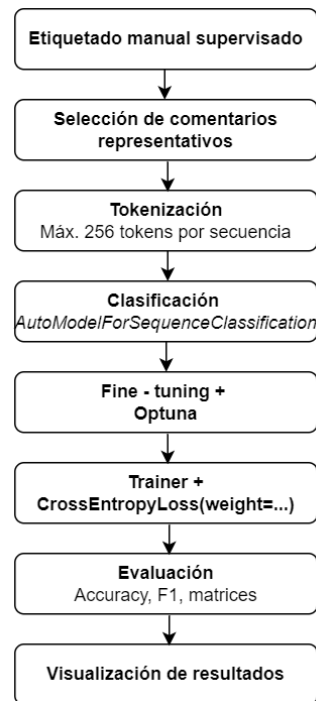
```

---

*Nota: Elaboración propia. Adaptado de (Mersha et al., 2024)*

En la segunda fase, tras la detección de tópicos temáticos, se construyó un pipeline de fine-tuning para clasificar las emociones presentes en los comentarios de los videos previamente clusterizados (ver Ilustración 5).

Ilustración 5. Etapas del fine-tuning para clasificación de emociones



Nota: Elaboración propia

Para tal fin, se emplearon los modelos de lenguaje previamente descritos en la sección 8.2.5.2, ajustados mediante fine-tuning sobre una muestra manualmente etiquetada descrita en la sección 7.2.2. El conjunto de datos se dividió en 80 % para entrenamiento y 20 % para validación, utilizando un muestreo estratificado para asegurar la representación proporcional de cada emoción en ambos subconjuntos. Para optimizar el desempeño de los modelos, se integraron múltiples técnicas avanzadas de ajuste y evaluación. Los modelos fueron entrenados sobre un conjunto de datos balanceado descrito en la sección 8.6.3, utilizando los tokenizadores nativos de cada modelo y la clase *AutoModelForSequenceClassification* de la librería Transformers.

En primer lugar, se utilizó la biblioteca Optuna para realizar la búsqueda de hiperparámetros. Optuna es una biblioteca diseñada específicamente para facilitar la

búsqueda automática y eficiente de combinaciones óptimas en modelos de aprendizaje automático que permite definir un espacio de búsqueda y emplear algoritmos de optimización para maximizar el rendimiento del modelo de forma automática (Akiba et al., 2019). El espacio de búsqueda definido incluyó cuatro parámetros clave (Ver tabla 10). Para cada combinación, se ejecutaron pruebas con el objetivo de maximizar el F1-score-macro, seleccionando los mejores hiperparámetros para cada arquitectura. La selección de estos rangos de búsqueda se fundamentó en las configuraciones por defecto y recomendaciones provistas en Hugging Face.

Tabla 10. Espacio de búsqueda de hiperparámetros con Optuna

Hiperparámetro	Descripción y valores explorados
<code>learning_rate</code>	Tasa de aprendizaje ajustada en escala logarítmica en el rango $[1e-5, 5e-5]$ .
<code>per_device_train_batch_size</code>	Tamaño de lote por dispositivo, con valores discretos: {4, 8, 16}.
<code>num_train_epochs</code>	Número de épocas de entrenamiento, explorado en el rango [5, 10].
<code>weight_decay</code>	Coficiente de regularización L2 aplicado al optimizador, con valores entre 0.01 y 0.1.

Nota: Elaboración propia

El entrenamiento se configuró mediante la clase *TrainingArguments*, habilitando evaluación y guardado por época (*evaluation\_strategy='epoch'*, *save\_strategy='epoch'*), con almacenamiento limitado de checkpoints (*save\_total\_limit=1*) y recuperación automática del mejor modelo (*load\_best\_model\_at\_end=True*). Para reducir el riesgo de sobreajuste, se implementó la técnica de *early stopping*, estableciendo un umbral de paciencia de dos épocas (*early\_stopping\_patience=2*), lo que interrumpió el entrenamiento si no se observaba mejora en la métrica F1, evitando que el modelo aprenda prolongadamente y memorice ejemplos poco representativos.

Durante el entrenamiento, se personalizó el *Trainer* de Hugging Face, adaptando la función de pérdida ponderada (*CrossEntropyLoss (weight=...)*), ajustada según la frecuencia relativa de cada clase, permitiendo compensar el desequilibrio de etiquetas dado que penaliza con mayor intensidad los errores sobre clases minoritarias permitiendo que el modelo mejore su sensibilidad sin sacrificar precisión en clases mayoritarias, convirtiéndose en una opción eficaz para modelar los costos reales de errores de

clasificación en contextos desbalanceados (Ho & Wookey, 2019). Para la tokenización y predicción, se limitaron las entradas a 256 tokens por secuencia, asegurando uniformidad y eficiencia computacional durante el procesamiento por lotes. Esta estrategia se apoya en Krell et al. (2021), quienes demuestran que la longitud variable de secuencias resulta en hasta un 50% de tokens de padding, resultando en un uso ineficiente del cómputo.

La evaluación se llevó a cabo mediante las métricas estándar globales para tareas de clasificación (accuracy, precisión, recall y F1 macro y ponderado), ampliamente reconocidas en tareas supervisadas (Rainio et al., 2024), así como el F1-score desagregado por clase, que permitió observar en detalle el rendimiento de cada modelo al clasificar las emociones específicas. Los resultados se visualizaron en gráficos comparativos para identificar las fortalezas particulares por emoción. A su vez, se generaron matrices de confusión por modelo para visualizar las relaciones entre clases y detectar patrones sistemáticos de error, interpretación que aportó información valiosa sobre la proximidad semántica entre clases desde la perspectiva del modelo y sobre las limitaciones en la clasificación emocional automatizada en contextos de discursos ambiguos o irónicos.

Por último, se consolidaron los mejores resultados en una tabla comparativa, destacando tanto el rendimiento agregado como el comportamiento por emoción. Esta sistematización permitió seleccionar el modelo más adecuado para el dominio en estudio y evidenció las ventajas del ajuste fino sobre corpus específicos, reafirmando la utilidad del enfoque adaptativo basado en PLN y aprendizaje profundo para el análisis emocional de narrativas digitales en contextos geopolíticos.

## **8. Trabajo de Campo**

A continuación, se presentan los principales hallazgos del estudio, organizados en dos fases. En primer lugar, se exponen los resultados del modelado de tópicos aplicado a los discursos recolectados, con el propósito de identificar patrones narrativos predominantes según la categoría del emisor. Posteriormente, se presenta un análisis comparativo del desempeño de los modelos de clasificación emocional descritos en la sección 4.2.5.3., con el objetivo de identificar la arquitectura más adecuada para futuras aplicaciones. Si bien se llevó a cabo un proceso de fine-tuning que arrojó resultados satisfactorios, este no fue aplicado sobre el corpus completo de comentarios, ya que el propósito de esta fase fue

principalmente evaluativo. En este sentido, se presenta el modelo con mejor rendimiento como una propuesta de referencia para investigaciones posteriores centradas en el análisis emocional de discursos en contextos de conflicto.

## 8.1. Extracción de videos

### 8.1.1. Diseño de términos de búsqueda y extracción de canales

La construcción de las listas de palabras clave utilizadas para la extracción automatizada de canales se realizó mediante consultas en las plataformas *TubeBuddy*, *Keywordtool.io* y *Google Trends*. A través de la extensión de *TubeBuddy*, se exploraron términos relevantes directamente en canales institucionales informativos, visualizando las palabras clave asociadas a los videos en tiempo real. De forma complementaria, se llevaron a cabo búsquedas iterativas en *Google Trends* para verificar la relevancia temporal y geográfica, así como en *Keywordtool.io* en modo YouTube, ingresando frases como “*Palestine AND Israel*” (término neutro), “*Gaza latest*” e “*Israel latest*”. Esto permitió recuperar términos derivados del autocompletado en las búsquedas de los usuarios. Con base en estas búsquedas y tras un proceso de curaduría manual orientado por la carga narrativa del contenido, se definieron 45 términos clave, agrupados en tres bloques semánticos: 8 términos neutrales, orientados a identificar cobertura internacional, 18 términos con connotación pro-palestina y 18 términos con connotación pro-israelí. La tabla 11 presenta una muestra representativa de los términos utilizados.

Tabla 11. Palabras clave de búsqueda y extracción de canales

Categoría	Palabras clave
<b>Internacional</b>	<i>Israel Palestine conflict, Middle East war coverage, Balanced report on Gaza situation, World leaders statements on Israel Palestine</i>
<b>Palestina</b>	<i>War crimes Israel Palestine, Solidarity with Palestine, Support for Palestinian rights, Gaza under attack, Israel war crimes in Palestine</i>
<b>Israel</b>	<i>Support for Israeli defense, Expose Hamas terrorism, Israel under attack, Defend Israeli sovereignty, Praise IDF operations, Hamas attack on Israel</i>

Nota: Elaboración propia

### 8.1.2. Extracción automatizada y filtrado de canales

La extracción de canales relevantes se llevó a cabo en el entorno Google Colab Pro, mediante un script que consultó la API de YouTube utilizando las combinaciones de términos y bloques semánticos definidos. Este script recorrió los resultados más relevantes desde el 7 de octubre de 2023, generando un diccionario acumulativo de menciones por canal, con exclusión de duplicados y priorización de la categoría “Internacional” en casos de ambigüedad.

Como resultado, se identificaron 513 canales únicos, clasificados según su carga narrativa. A partir de esta base, se aplicó un proceso de revisión manual para seleccionar 21 canales institucionales representativos, categorizados como Internacional, Internacional Medio Oriente, Palestina e Israel. La selección se basó en la frecuencia de aparición (ver columna “Menciones” en la Tabla 12) y en la relevancia institucional de cada canal. De este modo, se retuvieron únicamente aquellos con mayor visibilidad o importancia informativa, lo que representa el 4.1 % del total identificado automáticamente y garantiza un conjunto balanceado y sin sesgos.

*Tabla 12. Resumen de canales por categoría narrativa, número de menciones y cantidad de suscriptores*

Canal	Tipo	Menciones	Extracción	Suscriptores
France 24	Internacional	8	Automática	7.81 M
DW News	Internacional	16	Automática	5.86 M
BBC News	Internacional	36	Automática	18 M
CNN	Internacional	33	Automática	18.2 M
Al Jazeera English	Internacional Medio Oriente	188	Automática	15.8 M
TRT World	Internacional Medio Oriente	129	Automática	9.36 M
Middle East Eye	Internacional Medio Oriente	70	Automática	2.99 M
Al Mayadeen English	Internacional Medio Oriente	6	Automática	71.1 K
The Electronic Intifada	Palestina	7	Automática	268 K
Mondoweiss	Palestina	2	Automática	148 K
Palestine Deep Dive	Palestina	5	Automática	82.2 K
Voices for Gaza	Palestina	9	Automática	25.7 K
Quds News	Palestina	0	Manual	4.88 K
Palestine TV	Palestina	0	Manual	1.86 M
Eye.on.palestine	Palestina	0	Manual	7.35 K
i24 News	Israel	2	Automática	613 K
Israel Defense Forces	Israel	13	Automática	1.38 M
ILTV	Israel	7	Automática	650 K
Stand With Us	Israel	5	Automática	231 K
Jerusalem Post	Israel	0	Manual	55.1 K
Times of Israel	Israel	0	Manual	43.2 K

*Nota: Elaboración propia*

### **8.1.3. Categorización narrativa de canales**

Aunque los 21 canales seleccionados provienen de diversas regiones geográficas, su clasificación en bloques narrativos se realizó con base en su orientación editorial y carga discursiva, no en su localización formal. Dentro de la categoría Internacional se encuentran medios como France 24 (Francia), DW News (Alemania), BBC News (Reino Unido) y CNN (EE. UU.), todos con un enfoque informativo generalista y pretensión de imparcialidad.

El bloque Internacional Medio Oriente incluye medios regionales de alta influencia como Al Jazeera English (Catar), TRT World (Turquía), Middle East Eye (Reino Unido) y Al Mayadeen English (Líbano), cuya cobertura se centra en el contexto geopolítico regional.

En la categoría Palestina se agruparon tanto medios internacionales con línea editorial claramente pro-palestina —como The Electronic Intifada, Mondoweiss y Palestine Deep Dive— como canales vinculados directamente a la comunicación palestina, como Quds News, Palestine TV y Eye.on.palestine.

Finalmente, el bloque Israel incluye canales como i24 News, ILTV, y Israel Defense Forces (IDF), así como medios con presencia internacional como Stand With Us y The Jerusalem Post. La asignación a cada bloque se basó en el tipo de contenido publicado, el posicionamiento discursivo frente al conflicto y las audiencias a las que se dirigen, priorizando la representatividad narrativa.

### **8.1.4. Recolección automatizada de videos**

La recolección automática de videos se realizó mediante un pipeline diario en Google Colab Pro, con almacenamiento incremental en Google Drive. El script se diseñó para iterar por fechas desde el 7 de octubre de 2023 mediante la API de YouTube, para el conjunto de canales seleccionados. El código recorrió cada día hasta 5 videos por canal que coincidieran con la consulta "*Gaza Israel Palestine Conflict*", aplicando los filtros detallados en la sección 7.4. Además de los filtros aplicados por número mínimo de vistas y comentarios, el sistema descartó automáticamente cualquier video que no incluyera una transcripción válida. Esta condición fue implementada directamente en el script de recolección, lo que garantizó que el 100 % de los videos retenidos contara con transcripción disponible. La recolección cubre un rango temporal desde el 7 de octubre de 2023 hasta el 27 de marzo de 2025, lo que garantiza una representación longitudinal suficiente para el estudio de narrativas y cambios discursivos.

El código completo del pipeline de extracción, así como un subconjunto representativo de los datos recolectados y las instrucciones para su ejecución, se encuentran disponibles para consulta y reproducción en el repositorio de GitHub: [https://github.com/HananYousef59/DL\\_NLP\\_Palestina\\_Israel](https://github.com/HananYousef59/DL_NLP_Palestina_Israel).

### **8.1.5. Optimización del pipeline y gestión de cuotas**

El pipeline automático fue diseñado para funcionar de forma continua, alcanzando una media de 1.000 videos por día, dentro de los límites de la API estándar. Para evitar bloqueos por exceso de solicitudes, se implementó un sistema de rotación de 14 claves API, lo que permitió mantener la cobertura sin interrupciones.

También se incorporaron mecanismos de manejo de errores como reintentos ante respuestas *quotaExceeded* o *403 Forbidden*, descarte de videos sin transcripción y control incremental por `video_id`. Aunque no se calculó con exactitud el porcentaje de resultados redundantes evitados, la baja cantidad de videos recolectados por encima de la cuota sugiere que el sistema priorizó contenido altamente relevante, descartando eficazmente videos duplicados o no pertinentes.

## **8.2. Preprocesamiento y limpieza de datos de videos**

El preprocesamiento de datos se dividió en dos flujos independientes: uno aplicado a las transcripciones de los videos y otro a los comentarios. En esta sección se describen en detalle las etapas asociadas a la preparación del corpus textual de los videos, desde la limpieza inicial hasta la consolidación del conjunto final utilizado en el modelado de tópicos.

### **8.2.1. Estandarización de canales y clasificación temática**

En una primera etapa, se implementó un flujo automatizado para normalizar los nombres de los canales de YouTube, lo cual incluyó la eliminación de emojis, caracteres no alfabéticos (incluyendo texto en árabe), y la conversión a minúsculas. A través de un mapeo léxico, se unificaron variantes ortográficas comunes para identificar correctamente los emisores. Luego, cada canal fue clasificado automáticamente en una de las siguientes cuatro categorías semánticas: Palestina, Israel, Internacional e Internacional con cobertura en Medio Oriente, en función de su afiliación institucional y orientación geopolítica predominante. Estas tareas se implementaron mediante las funciones `clean_channel_name()` y `assign_category()`.

### **8.2.2. Normalización temporal y estructura del corpus**

Se procedió también a la conversión de las fechas ISO 8601 (por ejemplo, "2023-10-07T00:00:00Z") a objetos de tipo *datetime*, permitiendo una segmentación diaria de los datos. Esta resolución temporal es crucial para preservar la dinámica narrativa a lo largo del tiempo y analizar el discurso en intervalos regulares. El resultado consolidado de esta etapa se almacenó en el archivo *noticias\_youtube\_limpio.csv*.

### **8.2.3. Validación cuantitativa del corpus**

Tras la limpieza, el corpus quedó conformado por 8,553 videos, al eliminar 13 registros duplicados por contenido textual. No se identificaron transcripciones vacías ni valores nulos en campos clave (metadatos, variables cuantitativas y texto). Además, se verificó que no existieran inconsistencias como likes superiores a vistas o videos altamente vistos sin comentarios, lo que confirma la integridad numérica del conjunto de datos. En total, se extrajeron 8.566 videos provenientes de 21 canales distintos, con una cobertura completa de transcripciones. El 99.94% de los "*video\_id*" son únicos, lo que evidencia que el código evitó duplicados de manera efectiva durante la recolección, garantizando diversidad y previniendo sesgo por repetición.

### **8.2.4. Caracterización textual del corpus y filtrado por longitud mínima**

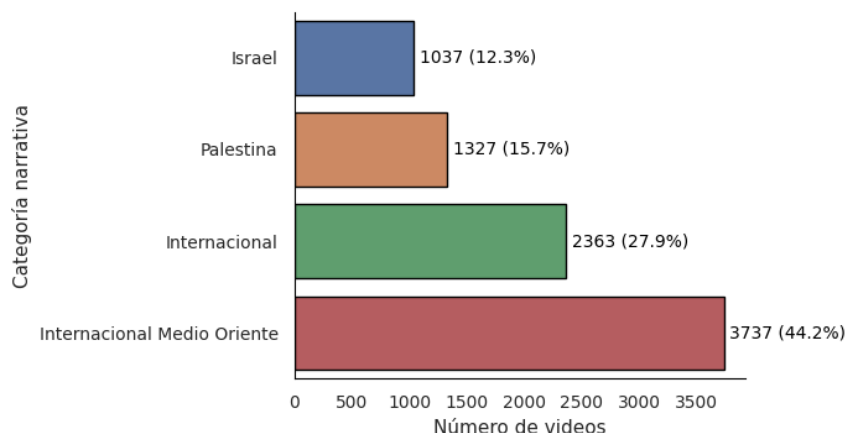
El conjunto de datos presenta una distribución asimétrica en la longitud de las transcripciones: el promedio general es de 1,592 palabras, pero la mediana es de apenas 424, lo que indica una fuerte dispersión. El video más extenso contiene más de 108,000 palabras, mientras que el más corto tiene una sola. Además, el corpus alcanza un total de 104,129 palabras únicas, con un promedio de 12.17 términos distintos por video, lo cual ofrece una línea base para evaluar la reducción del espacio semántico tras el preprocesamiento. Por categorías, los videos etiquetados como "Israel" presentan las transcripciones más extensas (4,234 palabras en promedio), posiblemente debido a la inclusión de ruedas de prensa o transmisiones completas. En contraste, la categoría Internacional Medio Oriente muestra textos más breves (796 palabras en promedio), probablemente ligados a coberturas resumidas o segmentos noticiosos concisos. Aunque todas las transcripciones contenían texto, se identificaron entradas con contenido extremadamente breve, compuesto por interjecciones, etiquetas sonoras como "[Music]", o frases sueltas sin valor semántico. Se definió un umbral mínimo en el percentil 1% ( $\leq 24$  palabras), y se eliminaron 89 registros que no alcanzaban ese límite. El corpus final quedó

conformado por 8,464 transcripciones útiles, con mejor densidad semántica para el análisis posterior.

### 8.2.5. Distribución final del corpus por categoría

Una vez completado el proceso de exploración y filtrado, las categorías narrativas quedaron distribuidas de la siguiente manera: Internacional Medio Oriente con 3,737 documentos (44.1%), seguida por Internacional (2,363; 27.9%), Palestina (1,327; 15.7%) e Israel (1,037; 12.2%). Esta estructura define el corpus final utilizado para el modelado de tópicos discursivos. (Ver Ilustración 6):

Ilustración 6. Distribución de videos por categoría narrativa



Nota: Elaboración propia

### 8.2.6. Limpieza y depuración de las transcripciones

El texto de las transcripciones fue sometido a un proceso de limpieza con el objetivo de reducir el ruido propio del lenguaje oral en YouTube y optimizar el contenido para el modelado temático. Este pipeline de preprocesamiento incluyó la conversión de todo el texto a minúsculas, la eliminación de enlaces, etiquetas HTML, signos de puntuación y caracteres no alfabéticos, así como una normalización léxica mediante lematización utilizando la herramienta *WordNetLemmatizer* de la librería NLTK. También se eliminaron palabras vacías (*stopwords*) a partir del listado estándar de *nltk.corpus.stopwords.words('english')*, complementado con una lista extendida de expresiones frecuentes en el habla cotidiana, como “um”, “yeah”, “you know”, entre otras. Adicionalmente, se aplicó un filtro de idioma mediante la librería *langdetect*, con el fin de asegurar que todas las transcripciones estuvieran redactadas en inglés. Aunque el proceso de recolección ya incluía un filtro idiomático, esta segunda verificación identificó

únicamente 10 registros (0,12 %) como potencialmente no ingleses. Sin embargo, una inspección posterior reveló que todos los casos contenían texto en inglés, y que los falsos positivos se debieron a frases muy breves, encabezados multilingües o nombres propios.

### **8.3. Caracterización del corpus**

Este bloque presenta los principales rasgos estructurales, temporales y estadísticos del corpus, con el fin de contextualizar los análisis posteriores de modelado temático y clasificación emocional.

#### **8.3.1. Estructura y variables del corpus**

El corpus final se estructuró en un único archivo con 8,464 registros, correspondientes a videos únicos que cumplen con los criterios de relevancia, disponibilidad de transcripción y diversidad temática. Cada registro incluye 11 variables, entre ellas:

- Metadatos: video\_id, title, channel, url, date
- Interacción: views, likes, comments
- Texto: transcript (transcripción completa, sin valores nulos)
- Enriquecimiento: channel\_clean (canal normalizado) y categoría (bloque narrativo asignado)

Esta estructura permitió aplicar filtros posteriores y organizar el análisis temático y emocional según la categoría del emisor. La Ilustración 7 es un ejemplo ilustrativo del contenido del conjunto de datos.

*Ilustración 7. Ejemplo ilustrativo del contenido del conjunto de datos*

video_id	Título	Canal	Fecha	Vistas	Likes	Comentarios	Transcripción	URL	Categoría
3bG2cL1ZaKI	Netanyahu declares war on Hamas after rocket attack	de-TRT World	2023-10-07	43535	372	221	the region is no stranger to violence and escalation...	<a href="https://www.youtube.com/watch?v=3bG2cL1ZaKI">https://www.youtube.com/watch?v=3bG2cL1ZaKI</a>	Internacional Medio Oriente
M1FHoCVngig	Israel Daily News – October 08, 2023	ILTV News	Israel 2023-10-08	56028	1315	282	a day after the Hamas surprise attack on Israel...	<a href="https://www.youtube.com/watch?v=M1FHoCVngig">https://www.youtube.com/watch?v=M1FHoCVngig</a>	Israel
9scGFj7zp5w	What is happening in Israel and Gaza Strip? – BBC News	BBC News	2023-10-10	1549759	11040	5289	hello I'm maram mash-eri it's time now for your questions...	<a href="https://www.youtube.com/watch?v=9scGFj7zp5w">https://www.youtube.com/watch?v=9scGFj7zp5w</a>	Internacional
IMDCsnMsqg0	Mustafa Barghouti questions US backing for Israel	Middle East Eye	East 2023-10-09	164502	8428	2138	I think this situation that has evolved is a direct result...	<a href="https://www.youtube.com/watch?v=IMDCsnMsqg0">https://www.youtube.com/watch?v=IMDCsnMsqg0</a>	Internacional Medio Oriente
bO9Qmvuh2Tg	Israel blocks aid to Gaza – DW News	DW News	2023-10-12	716409	3988	132	air strikes on Gaza have continued Israel says it's targeting...	<a href="https://www.youtube.com/watch?v=bO9Qmvuh2Tg">https://www.youtube.com/watch?v=bO9Qmvuh2Tg</a>	Internacional
Tu8hjjpP6dQ	Pro-Palestinian Movement: Changing Perspectives of Americans	Voices For Gaza	2024-06-29	8826	437	77	but now that Americans are reading about what's happening we're seeing...	<a href="https://www.youtube.com/watch?v=Tu8hjjpP6dQ">https://www.youtube.com/watch?v=Tu8hjjpP6dQ</a>	Palestina

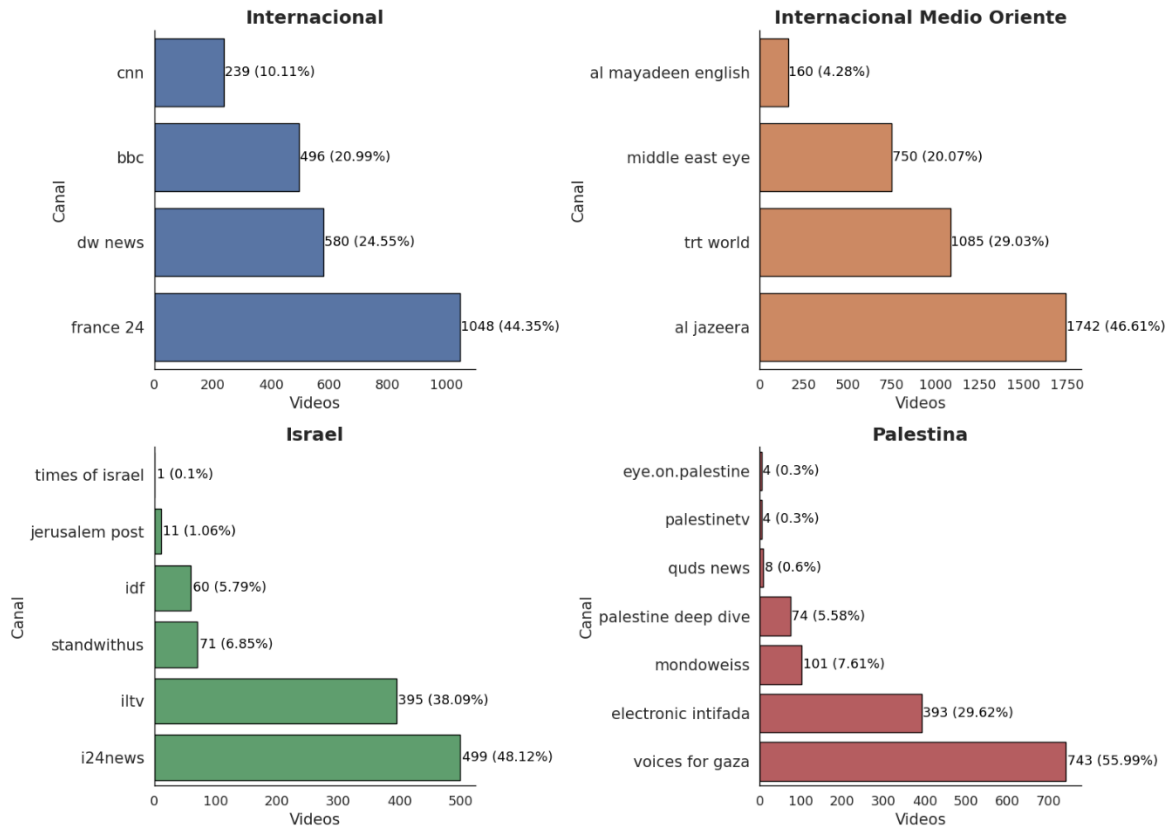
*Nota: Elaboración propia*

La longitud promedio de las transcripciones es de 1,590 tokens por video, lo que confirma que el corpus es textualmente denso y adecuado para análisis semántico. Aunque existen algunos valores atípicos con transcripciones muy extensas, la mayoría se sitúa entre 500 y 2,000 tokens, lo cual asegura una representación coherente del discurso.

### 8.3.2. Distribución por canal

El análisis de distribución por canal mostró una media de 407.9 videos por canal, con una alta desviación estándar (465.3), lo cual indica una producción muy concentrada en unos pocos emisores. Por ejemplo: Al Jazeera aporta el 45.8% del total de videos en la categoría “Internacional Medio Oriente” (1,747 de 3,814 videos), TRT World representa un 29.1% adicional en esa misma categoría. En “Internacional”, France 24 concentra el 44.3% de los videos. En “Israel”, i24News agrupa el 47.8% del total de videos de su categoría. En “Palestina”, Voices for Gaza representa el 56.3% de los videos (Ver Ilustración 8).

Ilustración 8. Distribución de videos por canal en cada categoría




Nota: Elaboración propia

Aunque la distribución es desigual, el análisis no se centra en los canales individuales como unidad principal, sino en las categorías narrativas. Esta decisión permite mantener la representatividad y riqueza discursiva de cada bloque temático, sin eliminar datos valiosos. La aplicación del filtro de máximo cinco videos por canal por día durante el proceso de extracción de videos evitaron la sobrerrepresentación de medios altamente activos.

### 8.3.3. Evolución temporal del corpus

La evolución temporal semanal del corpus mostró una alta variabilidad en la producción de contenido, con picos pronunciados en las semanas posteriores al 7 de octubre de 2023, y otros momentos críticos como enero de 2025. Esta oscilación se relaciona directamente con eventos políticos clave, lo que demuestra una sincronía entre coyuntura geopolítica y cobertura mediática.

*Ilustración 9. Evolución semanal del volumen de videos recolectados.*




*Nota: Elaboración propia*

La Ilustración 9 muestra la evolución mensual del volumen total de videos según categoría narrativa. Se observa un pico inicial en octubre de 2023, coincidiendo con el estallido del conflicto tras el ataque de Hamás. A lo largo de 2024, el volumen fluctúa, con repuntes en mayo y octubre, mientras que entre enero y marzo de 2025 se registra un aumento sostenido. Por categoría, Internacional Medio Oriente mantiene el mayor volumen de forma constante, especialmente por la cobertura de medios como Al Jazeera, TRT World o Middle East Eye. La categoría Internacional sigue una tendencia similar, aunque con menor intensidad. Las categorías Israel y Palestina, si bien menos frecuentes, muestran picos en momentos críticos, lo que sugiere una carga narrativa intensificada en situaciones de conflicto o denuncia. En particular, Palestina presenta aumentos notables en agosto y octubre de 2024, así como en enero y febrero de 2025, coincidiendo con crisis humanitarias y manifestaciones internacionales.

A nivel diario, se identificaron fechas con alta concentración informativa, como el 5 de febrero de 2025 (44 videos), y varios días en octubre de 2023 (16, 18 y 23), coincidentes con bombardeos masivos, declaraciones diplomáticas e intervenciones de organismos internacionales.

Ilustración 10. Evolución mensual por categoría narrativa



Nota: Elaboración propia

### 8.3.4. Interacción por categoría (engagement)

Para estimar el nivel de participación de la audiencia, se calculó el engagement rate de cada video como la razón entre el total de interacciones (likes + comentarios) y el número de vistas:

$$\text{Engagement Rate} = \frac{\text{Likes} + \text{Comentarios}}{\text{Vistas}} \quad (3)$$

Esta métrica permite evaluar la intensidad relativa de respuesta, independientemente del volumen de visualizaciones. Si bien su valor suele encontrarse entre 0 y 1, no está acotado superiormente, ya que en algunos casos excepcionales el número de interacciones puede superar el número de vistas (por ejemplo, en videos con alta participación, pero bajo conteo de vistas reportadas). A partir de este cálculo, se obtuvo un promedio de *engagement* por categoría (ver Tabla 13).

Tabla 13. Interacción por categoría narrativa

Categoría	Videos	Prom. vistas	Desv. vistas	Prom. likes	Prom. comentarios	Engagement Rate
Internacional	2364	115,725.02	349,397.31	1236.27	781.00	0.02
Internacional Medio Oriente	3814	132,931.74	831,384.66	6685.07	716.06	0.07
Israel	1043	77,771.52	266,923.32	2536.16	367.63	0.04
Palestina	1345	27,367.09	96,134.92	1800.30	187.33	0.14

Nota: Elaboración propia

Se identificaron diferencias sustanciales entre las categorías narrativas en términos de alcance, interacción del público y densidad textual de las transcripciones.

En primer lugar, la categoría Internacional Medio Oriente registró el mayor promedio de visualizaciones por video, así como la mayor variabilidad en ese indicador. Esto sugiere una amplia dispersión en el rendimiento de sus contenidos: algunos alcanzaron niveles de viralidad significativos, mientras que otros pasaron más desapercibidos. En contraste, la categoría Palestina presentó el promedio de vistas más bajo, pero también la menor desviación estándar y el *engagement rate* más alto del conjunto. Este patrón indica una audiencia más reducida pero altamente comprometida, con una elevada proporción de interacciones (*likes* y comentarios) por vista.

Por su parte, la categoría Internacional, aunque agrupa una gran cantidad de videos con altos niveles de visualización, muestra un *engagement* relativamente bajo. Esto podría estar asociado a un tono más informativo o neutral, dirigido a una audiencia menos emocionalmente involucrada. En cuanto a la categoría Israel, sus videos presentan un volumen de vistas moderado, superior al de Palestina, pero inferior al de Internacional, y un nivel de interacción más alto que este último, lo que sugiere una audiencia algo más activa, aunque aún por debajo de la observada en los videos palestinos.

El análisis también detectó 989 videos como *outliers* en cuanto a número de visualizaciones, lo que evidencia una alta dispersión y la presencia de contenidos virales, especialmente en categorías con mayor visibilidad como Internacional Medio Oriente. En cambio, los videos con mayores tasas de *engagement* se concentraron principalmente en la categoría Palestina, alcanzando en algunos casos ratios superiores al 50 %. Esto refuerza la hipótesis de una audiencia altamente involucrada. En el extremo opuesto, ciertos videos con cientos de miles de visualizaciones, por ejemplo, uno con más de 890.000, registraron *engagement rates* inferiores al 0,01 %, lo que podría reflejar un consumo más pasivo o un enfoque más factual y menos emocional.

### **8.3.5. Densidad léxica y extensión de transcripciones**

En términos de extensión textual, el análisis por categorías también revela diferencias importantes. Los videos de la categoría Israel presentan las transcripciones más extensas, con un promedio de 4.234 palabras, lo cual podría estar relacionado con la inclusión de ruedas de prensa, entrevistas completas o transmisiones sin cortes editoriales. Por el contrario, los videos clasificados como Internacional Medio Oriente muestran una longitud media significativamente menor, con 796 palabras, reflejando probablemente un formato más conciso, típico de segmentos noticiosos breves o reportes resumidos. Las categorías

Palestina e Internacional se ubican en un punto intermedio, con promedios de 2.405 y 1.252 palabras, respectivamente, lo que sugiere una narrativa de duración y profundidad moderadas. Finalmente, el corpus alcanza un total de 104.129 palabras únicas, con un promedio de 12,17 términos distintos por video. Esta cifra, que aún no contempla técnicas de normalización como lematización o eliminación de *stopwords*, proporciona una primera estimación de la riqueza léxica del conjunto, útil como referencia para las etapas posteriores del análisis semántico.

#### **8.4. Descripción general del discurso**

La presente sección describe el proceso de caracterización del discurso a partir del corpus textual obtenido tras la etapa de preprocesamiento. A través del campo *transcript\_filtered*, se accedió a versiones depuradas de las transcripciones originales, lo que permitió un análisis más preciso de las dinámicas narrativas en función de las distintas categorías temáticas. El objetivo central fue identificar patrones discursivos diferenciados mediante métricas lingüísticas, frecuencias léxicas y pruebas estadísticas.

El proceso de limpieza textual generó un cambio significativo en la extensión y composición del corpus. Para cuantificar este cambio, se estimó primero la cantidad de palabras por cada transcripción (equivalente a un video) y posteriormente se calcularon estadísticas descriptivas sobre esa distribución. En promedio, las transcripciones pasaron de contener 1,609 palabras por video a 582 palabras por video, lo que representa una reducción del 63.8 %. El valor máximo también disminuyó notablemente, de 108,237 a 36,845 palabras, lo cual refleja la eliminación de elementos ruidosos y la corrección de casos extremos.

Pese a esta reducción en tamaño y vocabulario total, el índice de riqueza léxica (TTR) se incrementó de 0.0076 a 0.0139, lo que indica una mayor densidad semántica y una disminución del ruido lingüístico. Este resultado valida la calidad del corpus procesado, al conservar información significativa y mejorar su interpretabilidad (ver Tabla 14).

Tabla 14. Comparativa estadística antes y después del preprocesamiento

Métrica	Original	Filtrado	Reducción (%)
Media	1608.98	581.94	63.83
Mediana	431.00	180.00	58.24
Máximo	108 237.00	36 845.00	65.96
Mínimo	25.00	5.00	80.00
Desv. Estándar	4851.29	1715.35	64.64
Vocabulario único	104 118	68 247	34.45
<b>TTR</b>	0.0076	0.0139	<b>-81.23</b>

Nota: Elaboración propia

La Tabla 15 presenta las principales características descriptivas de las transcripciones agrupadas por categoría narrativa:

Tabla 15. Estadísticas descriptivas de la longitud de transcripciones

Categoría	Cantidad	Mínimo	Mediana	Media	Máximo	Desv. Est.
Internacional	2363	14	313	470.59	13597	808.67
Internacional Medio Oriente	3737	5	147	301.43	18685	628.74
Israel	1037	10	246	1543.43	36845	3934.61
Palestina	1327	6	36	818.78	11846	1839.19

Nota: Elaboración propia

Estos datos revelan fuertes diferencias en la extensión discursiva. La categoría "Israel" presenta intervenciones extensas, posiblemente asociadas a declaraciones oficiales o coberturas en profundidad. En cambio, "Palestina" muestra una alta dispersión, combinando mensajes breves con otros de largo alcance. "Internacional Medio Oriente" destaca por una narrativa más breve y acotada. Estas diferencias reflejan no solo la diversidad en las estrategias discursivas según el tema, sino también posibles variaciones en el tipo de fuente, el estilo narrativo y la función comunicativa del discurso en cada categoría.

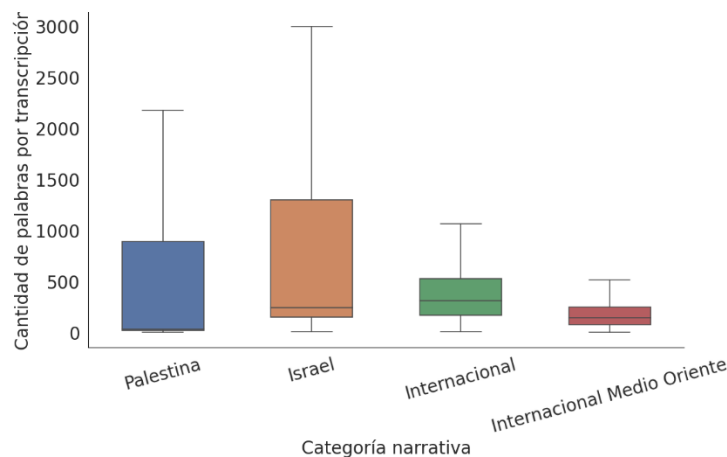
Con el fin de evaluar si las diferencias en la extensión textual de las transcripciones entre categorías narrativas son estadísticamente significativas, se aplicó una prueba ANOVA de un factor (*Analysis of Variance*). Esta prueba se emplea cuando se desea comparar las medias de más de dos grupos independientes, y en este caso resultó

adecuada al analizar si la longitud promedio de las transcripciones (en número de palabras) varía según la categoría narrativa (Palestina, Israel, Internacional e Internacional Medio Oriente). Se consideró como variable dependiente la longitud textual y como factor independiente la categoría narrativa. El resultado fue el siguiente:

$$F(3,8460) = 162.459; p < 0.0000000001; N = 8464$$

La significancia estadística se interpreta a partir del valor p asociado al estadístico F, y en este caso, al ser menor a 0.0000000001, se concluye que al menos una de las medias difiere significativamente del resto. Este resultado indica que existen diferencias significativas en la longitud promedio de las transcripciones entre categorías narrativas, lo cual sugiere la presencia de patrones discursivos diferenciados según el enfoque temático del contenido (ver Ilustración 11).

Ilustración 11. Longitud de transcripciones por categoría narrativa



Nota: Elaboración propia

Para analizar la presencia de patrones léxicos diferenciados entre las categorías narrativas, se aplicó la prueba de independencia de chi-cuadrado sobre las frecuencias absolutas de los términos más frecuentes. Esta prueba permite evaluar si existe asociación entre dos variables categóricas, y en este caso, si la distribución de ciertos términos clave depende de la categoría narrativa. El resultado fue significativo:

$$\chi^2 = 91672.44, \quad p < 0.00001$$

La interpretación del resultado se fundamenta en el valor p: al ser menor a 0.00001, se rechaza la hipótesis nula de independencia, lo cual indica que la distribución de los

términos clave no es aleatoria, sino que varía de manera sustancial entre las categorías narrativas. En otras palabras, cada narrativa emplea un repertorio léxico distintivo, en consonancia con sus respectivos marcos discursivos e intencionalidades comunicativas. Esta divergencia refuerza la hipótesis de que el lenguaje actúa como un vehículo ideológico, configurando las representaciones del conflicto desde perspectivas particulares.

Para profundizar en estas diferencias, se calcularon los residuos ajustados estándar a partir de la prueba de independencia  $\chi^2$ . Estos residuos miden la desviación entre la frecuencia observada y la frecuencia esperada de cada término en cada categoría narrativa, bajo el supuesto de independencia. Un residuo positivo alto indica que un término aparece más veces de lo esperado en esa categoría, lo que sugiere que dicho término es característico o distintivo del discurso asociado a esa narrativa. La Tabla 16 presenta los cinco términos más sobrerrepresentados en cada categoría, ordenados según el valor de su residuo ajustado.

Tabla 16. Términos distintivos por categoría narrativa

Categoría narrativa	Término 1	Término 2	Término 3	Término 4	Término 5
Palestina	resistance	fighter	genocide	operation	killed
Israel	idf	hostage	hamas	terrorist	border
Internacional	aid	humanitarian	netanyahu	president	ceasefire
Internacional Medio Oriente	child	genocide	world	international	state

Nota: *Elaboración propia*

Se utilizó el índice Type-Token Ratio (TTR) para evaluar la diversidad léxica en cada una de las categorías narrativas. Este indicador representa la proporción de términos únicos (*types*) respecto al total de palabras (*tokens*) utilizadas en los textos. Se calcula mediante la siguiente fórmula:

$$TTR = \frac{\text{Número de tipos únicos}}{\text{Número total de tokens}} \quad (4)$$

Un valor más alto de TTR indica un lenguaje más diverso o variado léxicamente, mientras que un valor más bajo sugiere un uso más repetitivo del vocabulario.

En este análisis, el valor más alto fue registrado por la categoría Internacional, lo cual sugiere una narrativa más heterogénea en términos de vocabulario, posiblemente vinculada a una mayor variedad temática o estilística. En contraste, la categoría Israel, a pesar de presentar el mayor volumen de tokens, obtuvo el TTR más bajo, lo que podría reflejar un discurso más focalizado, repetitivo o centrado en ciertos ejes léxicos predominantes (ver Tabla 17).

*Tabla 17. Índice de riqueza léxica (TTR) por categoría*


Categoría	TTR	Tokens	Tipos únicos
Palestina	0.02793	1,086,517	30,351
Israel	0.02142	1,600,534	34,276
Internacional	0.03229	1,111,997	35,902
Internacional Medio Oriente	0.03065	1,126,457	34,526

*Nota: Elaboración propia*

Además del análisis de frecuencias absolutas, se calcularon frecuencias relativas normalizadas por cada mil palabras, lo que permitió ajustar la interpretación léxica según la longitud total del corpus en cada categoría narrativa. La Ilustración 12 presenta los diez términos más frecuentes en el conjunto de datos, distribuidos por categoría. Palabras como “*hamas*” y “*hostage*” exhiben una presencia especialmente marcada en las categorías Israel e Internacional, mientras que términos como “*killed*” son más prevalentes en Palestina e Internacional Medio Oriente.

Este patrón refuerza las conclusiones derivadas del análisis estadístico (chi-cuadrado), al evidenciar una distribución no homogénea del vocabulario clave, coherente con las diferencias narrativas esperadas entre las categorías.

Ilustración 12. Frecuencia normalizada por categoría (Top 10 palabras más frecuentes)



Nota: Elaboración propia

#### 8.4.1. Mapeo léxico general por categoría narrativa

Con el fin de identificar patrones léxicos distintivos en los discursos de cada categoría narrativa, se realizó un análisis exploratorio de cada categoría. Se aplicó un análisis exploratorio mediante TF-IDF (Term Frequency–Inverse Document Frequency), con el objetivo de identificar los términos más representativos de cada categoría narrativa. Esta técnica permite destacar palabras que, si bien son frecuentes dentro de una categoría específica, no lo son en el resto del corpus, minimizando así el peso de palabras comunes o poco informativas. A partir del corpus preprocesado, se generaron listas ordenadas por peso TF-IDF para cada categoría, lo que facilitó la identificación de expresiones recurrentes y representativas. Se integraron tanto unigramas (una palabra) y bigramas (dos palabras consecutivas) con alto peso TF-IDF. Esta combinación permite capturar no solo términos clave individuales, sino también unidades léxicas compuestas que reflejan

marcos interpretativos más complejos, incluyendo relaciones actor-acción, estructuras valorativas o enfoques ideológicos implícitos en el discurso.

El análisis comparativo muestra que la narrativa de la categoría Palestina está fuertemente marcada por términos asociados al sufrimiento, el derecho internacional y la ocupación. Unigramas como *war*, *genocide*, *killed*, *military* y *child*, junto con bigramas como *war crime*, *refugee camp*, *international law* y *occupied west*, construyen un marco discursivo que enfatiza en el sufrimiento, la ilegalidad del conflicto y la apelación a actores y normas internacionales. El término *west bank*, destacado tanto como unigramas como bigrama, señala la centralidad del territorio en disputa.

En contraste, la categoría Israel presenta una narrativa centrada en amenazas percibidas, legitimación de la acción militar y respuesta institucional. Unigramas como *hamas*, *hostage*, *idf* y *terrorist* dominan el léxico, reforzados por bigramas como *hamas terrorist*, *release hostage* y *anti semitism*. Esta configuración sugiere un discurso más reactivo, centrado en seguridad y defensa, enmarcado por actores gubernamentales (*prime minister*, *idf*) y enemigos identificados.

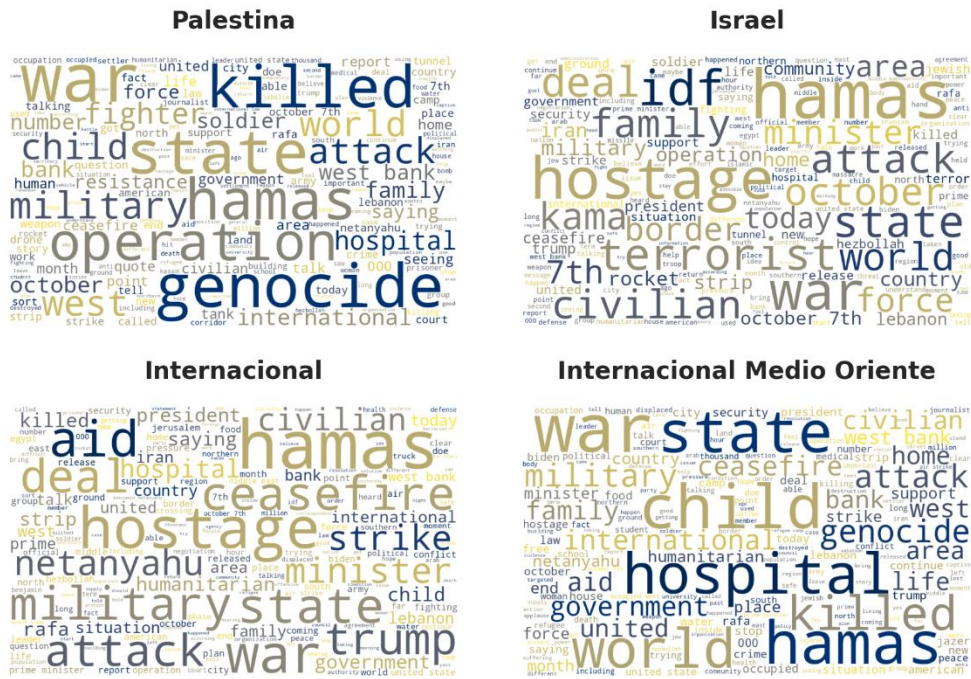
La categoría Internacional muestra una narrativa más heterogénea e informativa. Aparecen términos de conflicto (*war*, *hostage*, *military*), ayuda (*aid*, *humanitarian aid*), y diplomacia (*ceasefire*, *deal*, *united nation*), junto con nombres propios de líderes globales (*donald trump*, *benjamin netanyahu*). La coexistencia de expresiones como *prime minister*, *middle east*, *air strike* y *west bank* sugiere una cobertura geopolítica compleja, sin una narrativa única sino múltiples marcos superpuestos.

Por su parte, Internacional Medio Oriente combina una perspectiva regionalizada del conflicto con elementos humanitarios. Los términos *refugee camp*, *war crime*, *hospital*, *genocide* y *child* reflejan una atención al impacto humano, mientras que bigramas como *occupied west* refieren a contextos específicos. La categoría también incorpora referencias estatales (*united state*, *prime minister*) y militares (*air strike*, *military*), pero subordinadas a un enfoque centrado en consecuencias más que en acciones.

En conjunto, los resultados reflejan cómo cada categoría narrativa construye su discurso a partir de diferentes prioridades léxicas: desde la denuncia humanitaria en Palestina, la defensa en Israel, hasta la contextualización amplia en Internacional y la cobertura humanitaria en Internacional Medio Oriente.

Estas diferencias se reflejan gráficamente en las nubes de palabras por categoría (ver Ilustración 13 y 14), que combinan los términos más representativos según su peso TF-IDF, tanto en unigramas como en bigramas. Finalmente, la Tabla 18 resume de forma comparativa los principales términos léxicos que caracterizan cada narrativa.

Ilustración 13. Nube de n-gramas por categoría narrativa

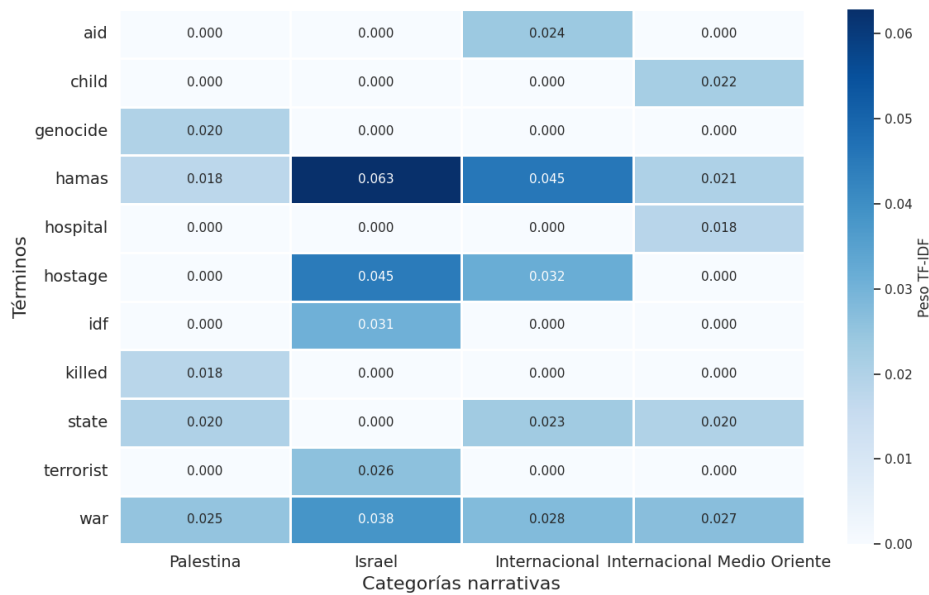


Nota: Elaboración propia



Complementariamente, se generó un mapa de calor de los cinco términos con mayor peso TF-IDF por categoría narrativa. En la Ilustración 15 se observa una clara diferenciación léxica.

Ilustración 15. Top 5 de términos con mayor peso TF-IDF por categoría narrativa



Nota: Elaboración propia

Por ejemplo, términos como *hamas*, y *hostage* son particularmente relevantes en las categorías Israel e Internacional, lo que sugiere un enfoque narrativo centrado en actores militares y rehenes. Por otro lado, *genocide*, *killed*, *war* y *state* emergen con mayor peso en la narrativa de Palestina, lo cual refleja una carga semántica orientada hacia la denuncia del genocidio, el conflicto armado y los aspectos jurídicos o identitarios del discurso. Aunque no se incluye en el cuerpo principal por razones de síntesis, el gráfico ampliado con los 10 términos principales por categoría confirma estas tendencias e incorpora matices adicionales. Por ejemplo, aparecen términos como *attack*, *ceasefire*, *military*, *trump* y *family*, lo cual revela la coexistencia de enfoques humanitarios, políticos y estratégicos dentro de algunas narrativas. La categoría Internacional Medio Oriente, si bien con pesos TF-IDF más atenuados, presenta una mezcla de vocabulario asociado a conflictos y actores, como *hospital*, *child*, o *war*, apuntando a una narrativa más contextual y menos polarizada.

Este análisis refuerza la evidencia de que cada categoría narrativa utiliza un repertorio léxico particular, configurando marcos semánticos distintos que orientan la interpretación del conflicto. La aplicación de TF-IDF demuestra ser útil para capturar estas diferencias discursivas, especialmente cuando se busca identificar términos clave más allá de su frecuencia bruta. Esta caracterización inicial del discurso demuestra la existencia de patrones discursivos diferenciados entre las categorías en estudio. Las pruebas estadísticas y visualizaciones demuestran que existe una distribución desigual de ciertos términos, tanto en frecuencia absoluta como relativa, lo cual indica que cada narrativa prioriza marcos temáticos y semánticos distintos. Estas diferencias en el lenguaje utilizado en contextos de conflicto pueden reflejar e influir la forma en que se construyen las identidades, responsabilidades y legitimidades de los actores involucrados. El predominio de determinados términos en una categoría puede estar vinculado con decisiones editoriales, lineamientos institucionales o sesgos de encuadre propios de cada fuente. Este análisis permite identificar que las narrativas no son neutras, sino que están configuradas por estructuras lingüísticas que orientan la interpretación del conflicto hacia significados específicos. En este sentido, el análisis léxico no solo aporta evidencia cuantitativa sobre las divergencias discursivas, sino que también constituye una invitación a la reflexión crítica sobre el papel del lenguaje en la construcción de realidades geopolíticas complejas.

### **8.5. Modelado de tópicos**

Este apartado presenta los resultados del modelado temático aplicado a las transcripciones, con un enfoque comparativo por narrativa. Se parte de un análisis cuantitativo del corpus preprocesado para justificar la viabilidad semántica del modelado y se continúa con una descripción rigurosa de los tópicos extraídos, sus métricas de calidad, vocabulario representativo y distribución narrativa.

El primer paso en el modelado temático consistió en determinar el número óptimo de clústers o tópicos ( $k$ ) para cada una de las categorías narrativas. Esta decisión se basó en un análisis cuantitativo que combinó dos enfoques complementarios: la suma de errores al cuadrado (SSE), utilizada como criterio del método del codo, y el índice de silueta, que evalúa la coherencia interna de los clústers formados.


Las curvas de análisis por categoría (ver Ilustración 16) muestran la evolución de ambas métricas entre  $k = 2$  y  $k = 15$ , permitiendo identificar tanto el punto de inflexión (codo) como

los valores que maximizan la cohesión semántica de los tópicos. En la mayoría de los casos, los valores óptimos propuestos por SSE y Silueta no coincidieron, lo que obligó a priorizar criterios de interpretabilidad y balance semántico.

En el caso de Palestina, aunque el valor máximo de silueta se alcanzó en  $k = 13$ , se observó un pico local destacado en  $k = 4$ , valor adoptado por ofrecer una buena diferenciación temática sin fragmentar excesivamente el discurso. Para Israel, se optó por  $k = 6$ , correspondiente al punto de codo. Si bien la silueta fue ligeramente superior en  $k = 10$ , el valor seleccionado resultó más interpretable y coherente con la estructura del contenido. En Internacional, se seleccionó  $k = 4$ , coincidiendo con el valor de silueta más alto. En Internacional Medio Oriente, aunque el codo se ubicó en  $k = 6$ , se optó por  $k = 3$ , ya que este valor también mostró un nivel alto de silueta y resultó más adecuado en términos de claridad y no redundancia temática.

Esta configuración permitió alcanzar un equilibrio entre la especificidad temática y la coherencia semántica dentro de cada grupo, asegurando que los tópicos extraídos fueran tanto distinguibles entre sí como representativos del contenido narrativo de cada categoría.

Ilustración 16. Selección del número óptimo de clústeres por categoría



Nota: Elaboración propia

Como complemento al análisis cuantitativo del número óptimo de tópicos, se generaron visualizaciones en dos dimensiones mediante la técnica de reducción UMAP, con el objetivo de observar la estructura semántica del corpus y la distribución espacial de los clústers temáticos por categoría narrativa (ver Ilustración 17).

En los gráficos se aprecia que los *embeddings* semánticos tienden a organizarse en regiones diferenciadas según el tópico asignado, lo que respalda visualmente la coherencia de los clústers obtenidos. En la categoría Palestina, los cuatro clústers muestran una separación clara y homogénea, con fronteras nítidas entre grupos. Esta configuración sugiere una segmentación temática bien definida, en la que cada grupo semántico ocupa una región específica del espacio.

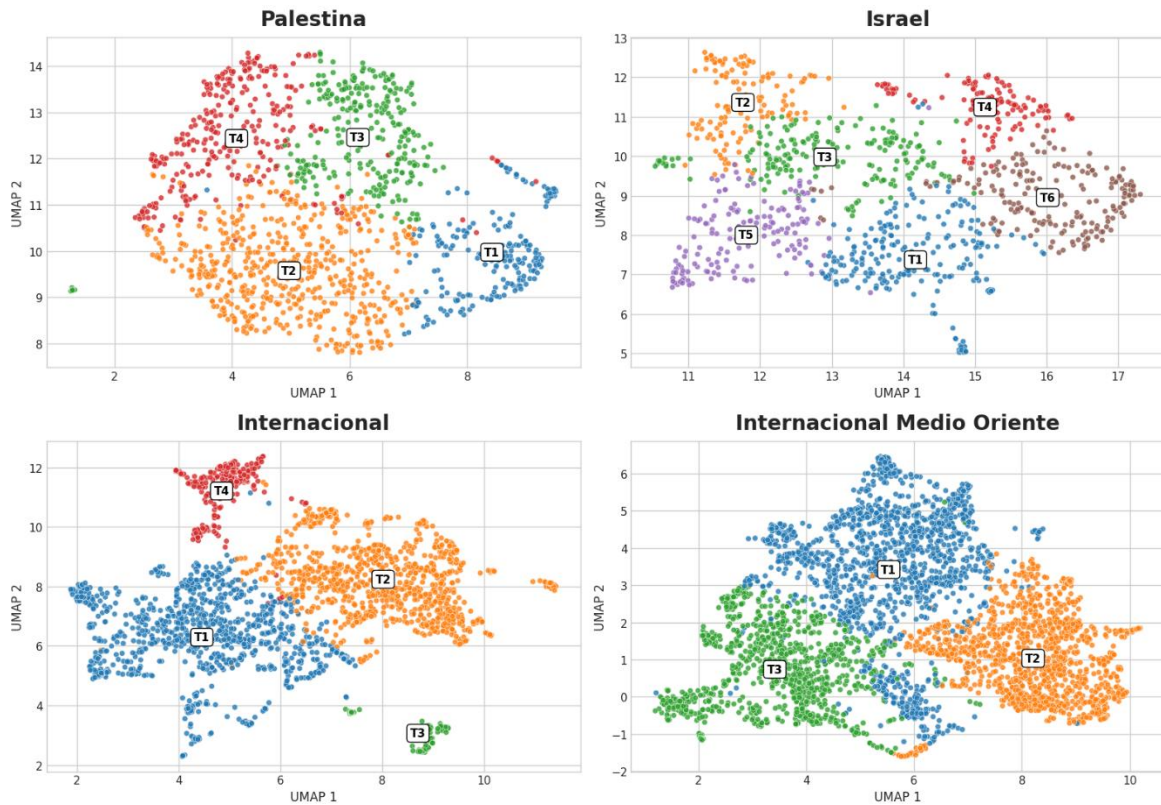
En Israel, aunque existen zonas con cierta superposición, los seis clústers son distinguibles y presentan una disposición en abanico. Esto podría reflejar una mayor diversidad discursiva o la coexistencia de subtemas interrelacionados dentro del mismo marco narrativo.

En el caso de Internacional, los Tópicos 1 (T1) y 2 (T2) dominan gran parte del espacio semántico, mientras que los Tópicos 3 (T3) y 4 (T4) aparecen más localizados y concentrados, posiblemente vinculados con temáticas específicas o nichos informativos.

Para Internacional Medio Oriente, los tres clústers evidencian una organización más integrada pero aún distinguible, con una leve intersección entre los Tópicos 1 (T1) y 3 (T3), sin que esto implique pérdida de coherencia semántica.

En conjunto, estas visualizaciones refuerzan la validez del modelado temático, al mostrar que, pese a la complejidad del discurso mediático, los tópicos extraídos corresponden a regiones semánticas discernibles. Esto sugiere una agrupación adecuada de los contenidos según su afinidad temática, aportando solidez al análisis narrativo posterior.

Ilustración 17. Visualización 2D de clústeres temáticos por categoría



Nota: Elaboración propia

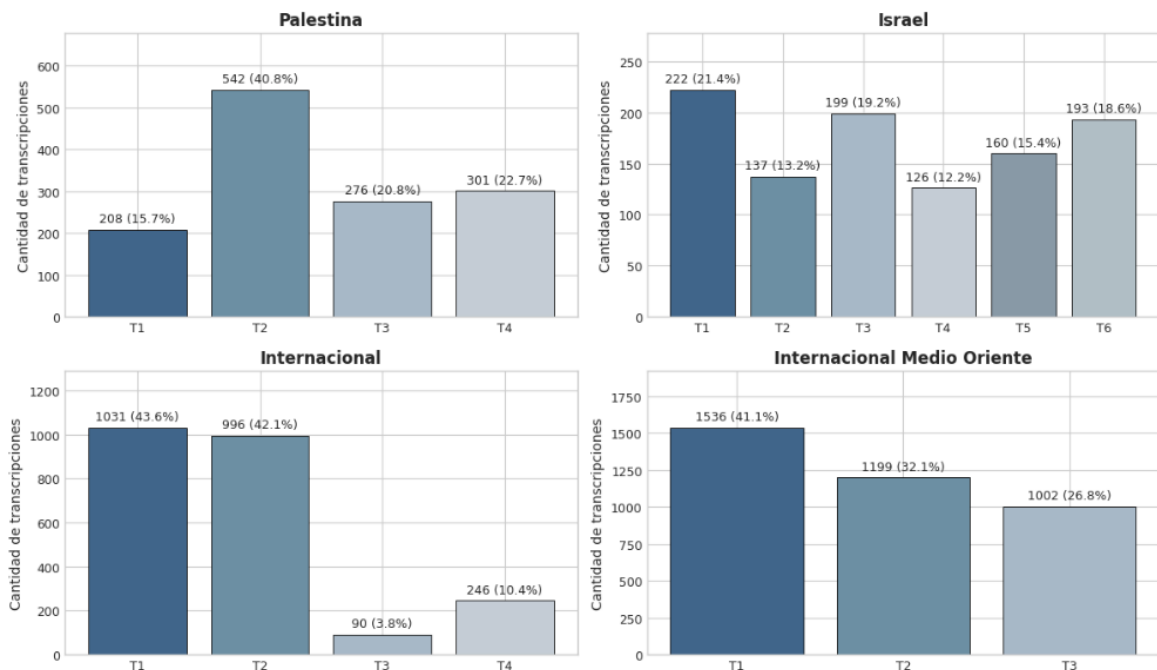
Además de visualizar la estructura semántica de los clústeres, se analizó la distribución cuantitativa de los tópicos generados para cada categoría narrativa. Este análisis permite observar si los clústeres obtenidos están balanceados o si, por el contrario, ciertos tópicos concentran una mayor cantidad de discursos.

En la categoría Palestina, los cuatro tópicos presentan una distribución relativamente equilibrada, aunque destaca el Tópico 2 (40.8%), que concentra la mayor parte de las transcripciones. Esto sugiere que, si bien hay variedad, existe un foco temático dominante dentro de la narrativa palestina. Para la categoría Israel, la distribución es más homogénea entre los seis tópicos, con el Tópico 1 concentrando el 21.4% de los discursos, y los demás distribuidos entre 12% y 19%. Este patrón indica una mayor diversidad narrativa, con distintos ejes temáticos presentes en proporciones similares. En la categoría Internacional, se observa una fuerte asimetría: los Tópicos 1 y 2 agrupan el 85% de las transcripciones, mientras que los Tópicos 3 y 4 son minoritarios. Esto podría reflejar una cobertura más

generalista de los discursos internacionales, con algunas temáticas específicas menos abordadas. Por último, en Internacional Medio Oriente, se aprecia un patrón decreciente pero balanceado: el Tópico 1 representa el 41.1% del corpus, seguido del Tópico 2 (32.1%) y el Tópico 3 (26.8%). Esta distribución muestra una segmentación temática clara, sin clústeres marginales, lo que sugiere una buena cohesión y cobertura narrativa dentro de esta categoría.

La Ilustración 18 muestra visualmente estos resultados, reforzando la comprensión de los focos temáticos predominantes y la diversidad interna de cada narrativa. Este paso resulta clave para validar la robustez del modelado temático antes de proceder al análisis cualitativo de los tópicos.

Ilustración 18. Distribución cuantitativa de tópicos por categoría



Nota: Elaboración propia

Como complemento al análisis cualitativo y visual de los clústeres, se evaluó la separabilidad semántica entre los tópicos generados para cada categoría narrativa mediante el cálculo de distancias euclidianas entre centroides en el espacio UMAP (5 dimensiones). Esta métrica permite estimar qué tan diferenciados están los núcleos temáticos dentro del espacio semántico.

La Tabla 19 resume, para cada categoría, el número de tópicos generados, la distancia media entre centroides, y los valores mínimo y máximo registrados. A su vez, la Ilustración 19 presenta mapas de calor con las distancias entre todos los tópicos de cada narrativa, facilitando una inspección visual de su grado de diferenciación.

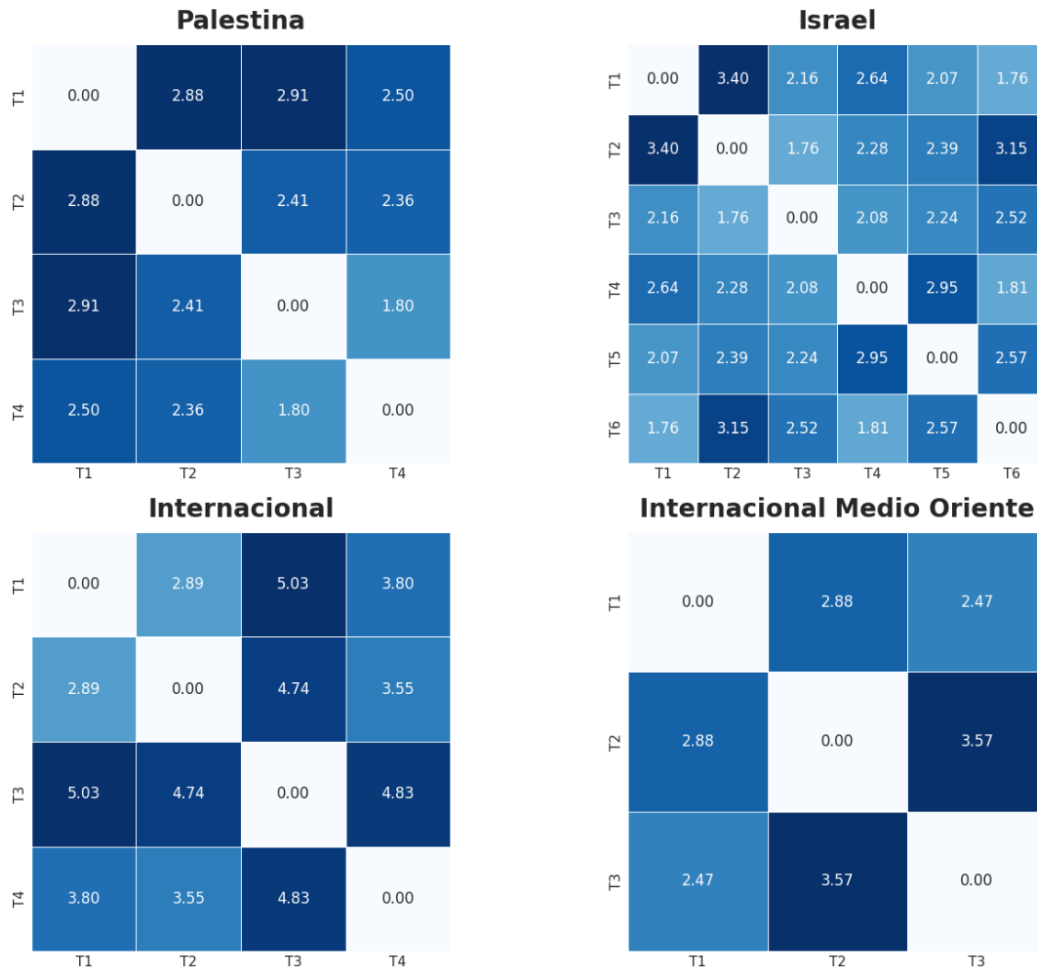
*Tabla 19. Distancia media entre centroides UMAP por categoría*

Categoría narrativa	N. Tópicos	Distancia media	Distancia mínima	Distancia máxima
Palestina	4	2.4776	1.8043	2.9145
Israel	6	2.3844	1.7555	3.3961
Internacional	4	4.1422	2.8926	5.0307
Internacional Medio Oriente	3	2.9727	2.4680	3.5734

*Nota: Elaboración propia*

Los resultados muestran que la categoría Internacional presenta la mayor distancia media (4.14) y máxima (5.03), lo que indica una alta segmentación semántica, posiblemente derivada de una cobertura diversa que incluye múltiples actores, hechos y contextos. Internacional Medio Oriente, con solo tres tópicos, también muestra distancias elevadas (media: 2.97), lo que sugiere una separación clara entre sus grupos temáticos. En contraste, Palestina (distancia media: 2.47) y Israel (2.38) exhiben valores más bajos, lo que sugiere una narrativa más cohesionada, aunque con subtemas diferenciables. En los mapas de calor (ver Ilustración 19) esto se refleja en combinaciones con distancias moderadas (como Tópico 3 y Tópico 4 en Palestina) y otras más dispersas en el caso de Israel (por ejemplo, entre Tópico 1 y Tópico 2).

Ilustración 19. Mapas de calor de distancia euclidiana entre centroides UMAP por categoría



Nota: Elaboración propia

Se evaluó la calidad del agrupamiento temático mediante métricas estándar de validación interna: el índice de Silhouette y el índice de Davies-Bouldin, calculados sobre los embeddings reducidos por UMAP. La Tabla 20 presenta los resultados por categoría narrativa. La categoría Internacional obtuvo el mayor valor de Silhouette (0.4154) y el menor índice de Davies-Bouldin (0.808), lo que sugiere una mejor separación y cohesión de clústeres en el espacio latente. Internacional Medio Oriente y Palestina también muestran valores aceptables de Silhouette (0.3901 y 0.3534), mientras que Israel presenta la puntuación más baja en ambas métricas, lo cual puede indicar una mayor proximidad o solapamiento entre sus clústeres.

*Tabla 20. Métricas de validación interna del agrupamiento temático (calculadas sobre embeddings UMAP)*

Categoría narrativa	N. Documentos	N. Tópicos	Silhouette	Davies-Bouldin
Palestina	1327	4	0.3534	1.0672
Israel	1037	6	0.3360	1.0638
Internacional	2363	4	0.4154	0.8080
Internacional Medio Oriente	3737	3	0.3901	1.0659

*Nota: Elaboración propia*

Además de examinar la estructura semántica y la distribución cuantitativa de los tópicos, se calcularon métricas globales para evaluar la calidad de los clústers generados en cada categoría narrativa. A diferencia de los análisis anteriores, basados en las representaciones reducidas mediante UMAP, estas métricas fueron calculadas directamente sobre los embeddings originales (1024 dimensiones) obtenidos con el modelo e5-large-v2, lo que permite una evaluación más precisa de la cohesión y la separabilidad semántica real entre documentos.

Se consideraron tres indicadores clave (ver Tabla 21): Homogeneidad intra-cluster, medida por la distancia coseno promedio entre cada punto y su centroide; separabilidad inter-cluster, calculada como la distancia coseno promedio entre los centroides de los clústers; y entropía de tópicos, que refleja el grado de equilibrio en la asignación de documentos a los distintos clústers.

*Tabla 21. Métricas semánticas globales por categoría narrativa (basadas en embeddings originales)*

Categoría narrativa	N. Tópicos	Homogeneidad Intra-cluster	Separabilidad Inter-cluster	Entropía de Tópicos
Palestina	4	0.0954	0.0235	1.9034
Israel	6	0.0766	0.0208	2.5558
Internacional	4	0.0767	0.0255	1.5668
Internacional Medio Oriente	3	0.0897	0.0172	1.5626

*Nota: Elaboración propia*

Los resultados muestran que los clústers son internamente coherentes y compactos (homogeneidad < 0.10 en todos los casos), destacando las categorías Israel e Internacional con la mayor cohesión interna. En cuanto a la diferenciación entre clústers, Internacional presenta la mayor separabilidad (0.0255), lo que concuerda con los análisis realizados en el espacio UMAP, mientras que Internacional Medio Oriente muestra una menor distancia entre clústers. Finalmente, la entropía más alta en Israel sugiere una distribución más balanceada de los discursos entre los seis clústers identificados, a

diferencia de otras categorías donde uno o dos tópicos concentran la mayoría de las transcripciones.

Cabe destacar que las métricas de validación interna y semántica empleadas en este estudio fueron calculadas tanto sobre los embeddings reducidos (mediante UMAP) como sobre los vectores semánticos originales. Esta dualidad metodológica permite evaluar distintas propiedades de los clústers: mientras que el índice de Silhouette y Davies-Bouldin capturan relaciones geométricas en un espacio proyectado, las métricas de homogeneidad y separabilidad basadas en coseno reflejan la coherencia semántica real entre documentos. Las ligeras discrepancias observadas entre categorías responden, por tanto, a las diferencias en la representación del espacio y no a inconsistencias en la segmentación temática.

Estas métricas refuerzan la validez del modelado temático, al mostrar que los tópicos detectados son tanto coherentes internamente como suficientemente diferenciables en el espacio semántico completo.


En la sección que sigue, se presenta una caracterización detallada de los tópicos identificados para cada una de las categorías analizadas. Este análisis se desarrolló a partir de un enfoque mixto que combina técnicas estadísticas y semánticas con el fin de garantizar tanto la coherencia léxica como la cohesión conceptual de cada clúster temático. Se evaluó la calidad de los tópicos a través de distintas métricas de coherencia (como  $C_V$  y  $U_{Mass}$ ) así como mediante un análisis semántico utilizando embeddings generados con el modelo e5-large-v2. Para cada tópico se calcularon las similitudes coseno entre los términos más representativos (según puntuaciones TF-IDF) con el fin de estimar su cohesión interna en el espacio vectorial.

Las visualizaciones incluyen nubes de palabras, gráficos de n-gramas y bigramas ponderados por TF-IDF, y representaciones gráficas de la distribución de tópicos por canal, lo que permite observar patrones discursivos dominantes y su concentración temática. Asimismo, se incluye un resumen cuantitativo con los términos clave, proporciones de videos asociados y fragmentos representativos de cada tópico.

### 8.5.1. Estructura discursiva y tópicos predominantes en Palestina

El análisis temático identificó cuatro tópicos centrales en la categoría Palestina, definidos a partir de n-gramas y bigramas ponderados mediante TF-IDF. Las visualizaciones correspondientes (Ilustraciones 20, 21 y 22) evidencian una organización semántica bien delimitada, con patrones discursivos diferenciados y alta coherencia léxica al interior de cada grupo. Cada visualización individual dentro de las ilustraciones representa un tópico específico, permitiendo visualizar el vocabulario más representativo dentro de cada clúster.

Ilustración 20. Nube de n-gramas por tópico - Palestina

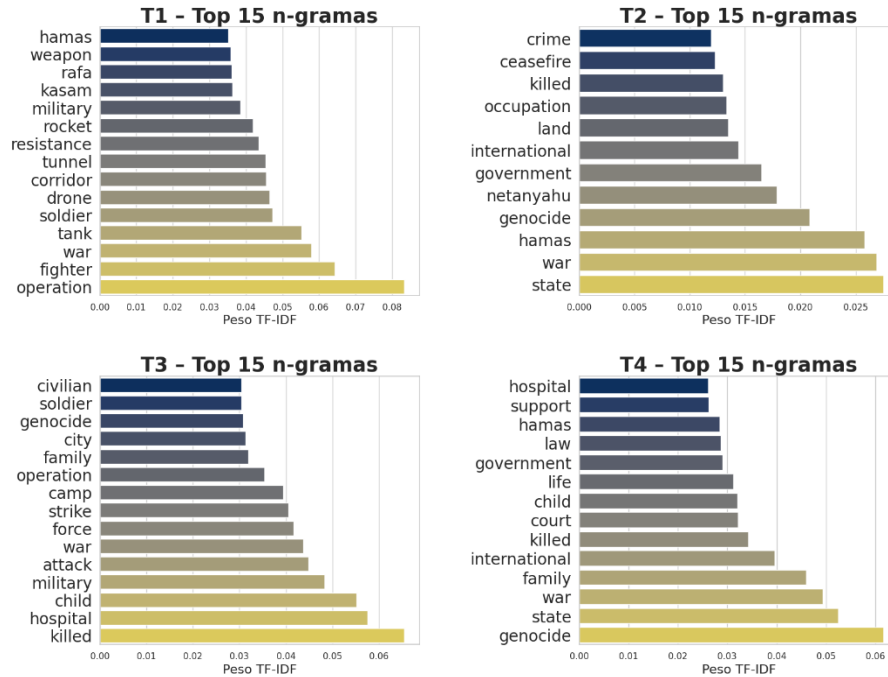


Nota: Elaboración propia

Ilustración 21. Nubes de bigramas por tópico - Palestina



Ilustración 22. Top 15 de términos con mayor peso TF-IDF por tópico - Palestina



Estas visualizaciones permiten identificar los términos dominantes en cada narrativa y su peso relativo, reflejando así la concentración semántica al interior de los clústeres. Los nombres asignados a cada tópico corresponden a una interpretación inductiva basada en las palabras más representativas dentro de cada grupo, lo que facilita la comprensión temática de las narrativas emergentes.

Además de esta interpretación cualitativa, se incorporó una evaluación cuantitativa de la coherencia léxica y semántica, con el fin de validar la consistencia interna de cada clúster. Las métricas utilizadas, presentadas más adelante en la sección “Evaluación de la coherencia léxica y semántica” (ver Tablas 23 y 24), respaldan empíricamente la organización temática descrita, aportando solidez al análisis discursivo.

### **Tópicos identificados**

#### **Tópico 1 (T1): Operaciones de resistencia**

El tópico se caracteriza por un léxico predominantemente militar y operativo, lo que sugiere una concentración temática en torno a acciones y movimientos tácticos. Los términos más relevantes, según ponderaciones TF-IDF, incluyen *operation*, *fighter*, *war*, *tank*, *soldier*, *drone*, *corridor*, *tunnel* y *rocket*, lo que evidencia un campo semántico centrado en dinámicas de enfrentamiento directo y despliegue técnico. Este patrón léxico se refuerza en los bigramas más frecuentes, entre los que destacan *anti tank*, *armored vehicle* y *prisoner exchange*, así como referencias geopolíticas como *united states* y *philadelphia corridor*. La alta coherencia de este tópico, reflejada en su puntuación C\_V de 0.6237 y su coherencia semántica E5 de 0.8036, se evidencia en un léxico homogéneo centrado en acciones militares concretas.

#### **Tópico 2 (T2): Genocidio y derecho internacional**

El segundo tópico de la categoría Palestina presenta un léxico centrado en referencias estatales, geopolíticas y jurídico-institucionales. Los términos con mayor peso TF-IDF, como *state*, *war*, *hamas*, *genocide*, *netanyahu*, *government*, *international* y *occupation*, configuran un campo semántico asociado a estructuras de poder, conflicto interestatal y violaciones a derechos humanos. La composición léxica se ve complementada por bigramas como *international law*, *state solution*, *war crime* y *occupied territory*, junto con menciones a actores relevantes como *united states*, *united nation* y *benjamin netanyahu*. Esta narrativa refleja un discurso centrado en marcos institucionales y disputas por

legitimidad estatal y territorial. Su coherencia léxica, aunque más baja ( $C_V = 0.4016$ ;  $E5 = 0.7851$ ), refleja la diversidad temática del clúster.

### **Tópico 3 (T3): Crisis humanitaria y víctimas civiles**

El tercer tópico presenta una fuerte orientación léxica hacia el impacto humanitario del conflicto, con énfasis en víctimas civiles, infraestructura médica y desplazamiento forzado. Los términos con mayor peso TF-IDF, como *killed, hospital, child, military, attack, strike, force* y *camp*, reflejan un campo semántico vinculado a consecuencias directas de la violencia armada sobre la población no combatiente. Este patrón se refuerza mediante bigramas como *air strike, refugee camp, humanitarian aid* y *health ministry*, junto con menciones a organismos multilaterales como *united nation* y *united states*. La estructura discursiva está centrada en la representación de víctimas, atención médica y afectaciones a infraestructura civil, sin incluir elementos técnicos o estratégicos del combate. La puntuación  $C_V$  de 0.4625 y el alto valor de coherencia  $E5$  (0.8160) refuerzan la compacidad semántica del tópico, centrado en un discurso humanitario cohesivo.

### **Tópico 4 (T4): Responsabilidad jurídica internacional y derechos humanos (DDHH)**

El análisis léxico del Tópico 4 en la categoría Palestina revela un discurso fuertemente orientado hacia la denuncia jurídica y política del conflicto. Los términos con mayor peso TF-IDF, como *genocide, state, war, family, y court*, representan un eje narrativo centrado en la acusación de crímenes de guerra y la implicación de actores estatales e internacionales. Esta narrativa se ve reforzada en la nube de bigramas por expresiones como *south africa, international law, war crime, arrest warrant* y *occupied west*, que sugieren un énfasis explícito en los mecanismos de justicia global, particularmente en relación con el rol de instituciones como la Corte Penal Internacional y actores diplomáticos relevantes. Aunque presenta la menor coherencia léxica ( $C_V = 0.3541$ ), su coherencia semántica  $E5$  es alta (0.8132), lo que indica una narrativa menos homogénea léxicamente, pero estructurada conceptualmente en torno a la justicia internacional.

La Tabla 22 sintetiza los tópicos con sus términos más relevantes, proporción de videos asociados y fragmentos representativos. Estos últimos fueron seleccionados por cercanía semántica al centroide del clúster en el espacio de *embeddings*, lo que asegura su representatividad discursiva.

Tabla 22. Resumen temático en la categoría Palestina


Tópico	% de videos	Top 15 n-gramas	Fragmento representativo
<b>Operaciones de resistencia (T1)</b>	15.67%	operation, fighter, war, tank, soldier, drone, corridor, tunnel, resistance, rocket, military, kasam, rafa, weapon, hamas	“More than 40 air strikes a day in Gaza – a consistent number for many months [...] attacks in all major cities and camps. [...] The siege in the north has turned all of Gaza into a frontline killing zone.”
<b>Genocidio y derecho internacional (T2)</b>	40.84%	state, war, hamas, genocide, netanyahu, government, international, land, occupation, killed, ceasefire, crime, human, military	“this situation requires international law and human right not medication [...] oppression injustice political violence”
<b>Crisis humanitaria y víctimas civiles (T3)</b>	20.80%	killed, hospital, child, military, attack, war, force, strike, camp, operation, family, city, genocide, soldier, civilian	“gaza has become a graveyard for child and family [...] virtually all child are at risk or have been shattered by unimaginable trauma”
<b>Responsabilidad jurídica internacional y DDHH (T4)</b>	22.68%	genocide, state, war, family, international, killed, court, child, life, government, law, hamas, support, hospital	“They are clearly committing genocide under the convention. [...] This is a violation of international humanitarian law.”

Nota: Elaboración propia

### Distribución temática por medio y evolución temporal

La distribución de tópicos por canal (ver Ilustración 23) evidencia patrones editoriales diferenciados entre las fuentes analizadas. Electronic Intifada muestra una fuerte concentración en el Tópico 1 (Operaciones de resistencia), mientras que Quds News domina ampliamente el Tópico 2 (Genocidio y derecho internacional), con más del 90 % de sus videos asignados a este clúster. Por su parte, Voices for Gaza presenta una mayor proporción en el Tópico 3 (Crisis humanitaria y víctimas civiles), mientras que Palestine Deep Dive y Mondoweiss tienen una participación más dispersa, aunque ligeramente inclinada hacia los Tópicos 3 y 4. Eye.on.Palestine y PalestineTV presentan una participación marginal en el conjunto de datos, lo que limita la posibilidad de establecer patrones interpretables sobre su distribución temática.


Ilustración 23. Distribución de canales por tópico - Palestina



Nota: Elaboración propia

En cuanto a la evolución temporal (ver Ilustración 24), se observa un repunte significativo del Tópico 2 a partir de mediados de 2024, asociado a contextos de alta conflictividad. En contraste, los tópicos 1 y 4 presentan variaciones moderadas, mientras que el Tópico 3 muestra una tendencia ascendente sostenida, reflejando un desplazamiento del foco discursivo desde temas tácticos hacia las dimensiones humanitaria y jurídica del conflicto.

Ilustración 24. Evolución temporal de los tópicos - Palestina



Nota: Elaboración propia

### Evaluación de la coherencia léxica y semántica

El modelado temático se realizó mediante reducción de dimensionalidad con UMAP y agrupamiento con k-means sobre embeddings generados por BERT. Para evaluar la consistencia interna, se utilizaron métricas clásicas de coherencia léxica (C\_V y U\_Mass). Los resultados muestran que el Tópico 1 (Operaciones de resistencia) presenta la mayor coherencia en ambas métricas (C\_V = 0.6237; U\_Mass = -0.5504), lo que indica una alta compactación semántica. En contraste, el Tópico 4 (Responsabilidad jurídica y DDHH) refleja la menor cohesión (C\_V = 0.3541; U\_Mass = -0.5892), sugiriendo una mayor heterogeneidad léxica dentro del grupo (Ver tabla 23).

Tabla 23. Métricas de coherencia léxica por tópico - Palestina

Tópico	Coherencia C_V	Coherencia U_Mass
Operaciones de resistencia (T1)	0.6237	-0.5504
Genocidio y derecho internacional (T2)	0.4016	-0.6656
Crisis humanitaria y víctimas civiles (T3)	0.4625	-0.4918
Responsabilidad jurídica internacional y DDHH (T4)	0.3541	-0.5892

Nota: Elaboración propia

Además, se implementó una evaluación vectorial adicional usando el modelo E5-large-v2, preentrenado para recuperación semántica. Se seleccionaron los 10 términos con mayor TF-IDF por tópico y se calcularon todas las combinaciones de similitud coseno entre sus vectores. El valor promedio resultante (ver Tabla 24) representa el grado de cohesión semántica entre los términos del clúster. Los resultados para la categoría Palestina muestran una alta coherencia global, destacándose el Tópico 3 (Crisis humanitaria y víctimas civiles) con un valor de 0.816, seguido por el Tópico 4 (0.8132) y el Tópico 1 (0.8036). Este enfoque confirma la validez estructural de los clústeres temáticos identificados mediante UMAP y K-means, reforzando la solidez del análisis discursivo.

Tabla 24. Coherencia semántica por tópico - Palestina

Tópico	Coherencia E5
Operaciones de resistencia (T1)	0.8036
Genocidio y derecho internacional (T2)	0.7851
Crisis humanitaria y víctimas civiles (T3)	0.8160
Responsabilidad jurídica internacional y DDHH (T4)	0.8132

Nota: Elaboración propia

Los resultados del modelado temático revelan una segmentación discursiva clara y estructurada en la narrativa palestina. Esta organización abarca desde discursos centrados en la resistencia (T1), hasta representaciones humanitarias (T3) y marcos jurídicos internacionales (T2 y T4). Conceptos como la violencia estructural, las víctimas civiles y la justicia internacional emergen como ejes semánticos que articulan el discurso. Cada clúster refleja una configuración particular de sentido, desde la denuncia de estructuras opresivas, pasando por el sufrimiento humanitario, hasta la apelación a marcos jurídicos para la legitimación del reclamo palestino. Parte del discurso se construye en torno a categorías como *apartheid*, *colonialismo* y/o *limpieza étnica*, insertas en narrativas históricas y jurídicas que buscan generar simbolismo político y reconocimiento internacional. Por último, se observa una crítica sostenida hacia la comunidad internacional, que es interpelada por su percepción de inacción o sesgo. Estos patrones discursivos reflejan una articulación léxica coherente frente a una experiencia histórica narrada como marcada por el despojo, la violencia prolongada y la falta de protección internacional. La presencia sistemática de términos jurídicos y humanitarios —como genocidio, crímenes de guerra o derecho internacional— responde al intento de visibilizar, desde el discurso, acontecimientos que los emisores presentan como violaciones graves a los derechos humanos. La narrativa palestina se configura como una forma de resistencia simbólica, que combina memoria, denuncia y apelación al derecho, con el fin de sostener un reclamo de justicia en distintos planos: político, humanitario y legal.

### 8.5.2. Estructura discursiva y tópicos predominantes en Israel

El análisis temático identificó seis tópicos centrales en la categoría Israel, definidos a partir de n-gramas y bigramas ponderados mediante TF-IDF. Las visualizaciones correspondientes (Ilustraciones 25, 26 y 27) evidencian una organización semántica bien delimitada, con patrones discursivos diferenciados y alta coherencia léxica al interior de cada grupo. Cada visualización individual dentro de las ilustraciones representa un tópico específico, permitiendo visualizar el vocabulario más representativo dentro de cada clúster.

Ilustración 25. Nubes de n-gramas por tópico – Israel


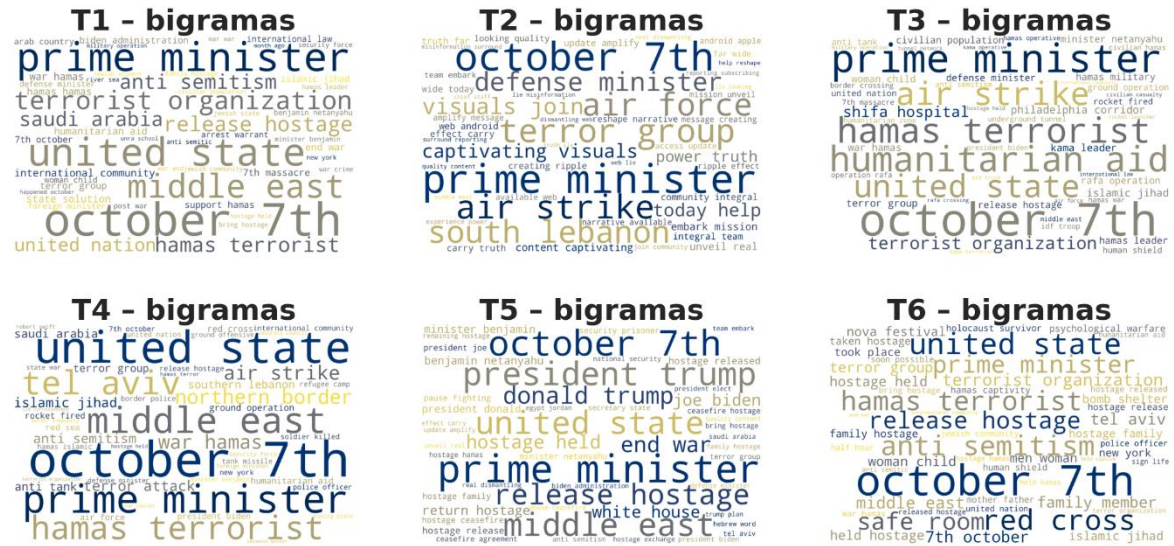
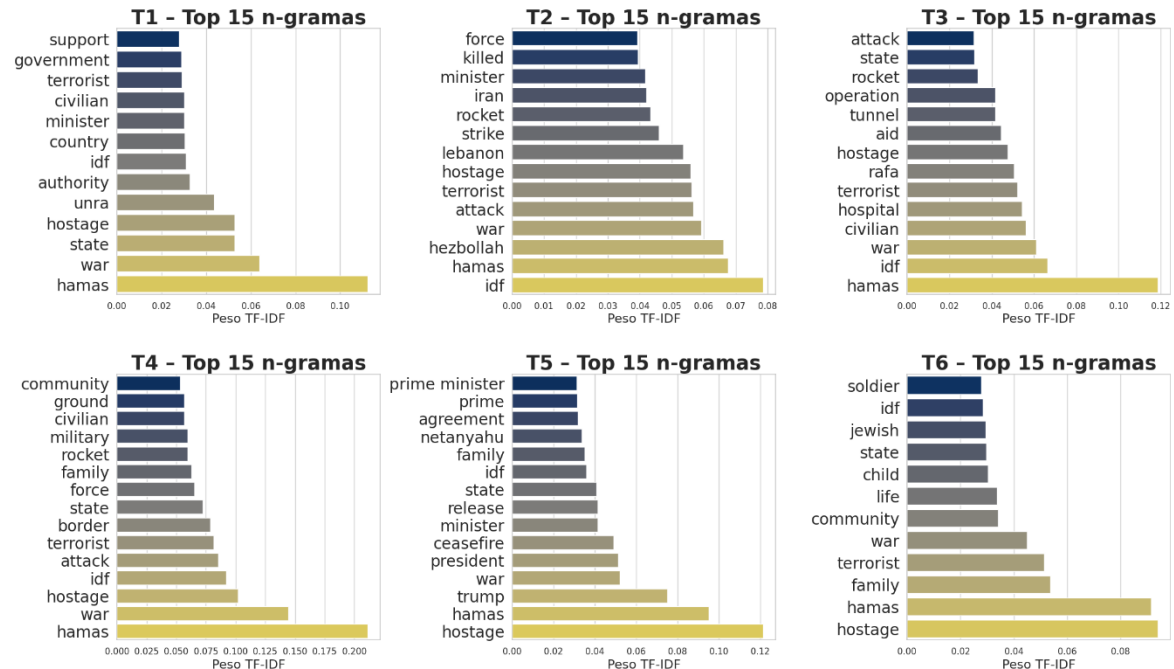


Ilustración 26. Nube de bigramas por tópico - Israel



Nota: Elaboración propia

Ilustración 27. Top 15 de términos con mayor peso TF-IDF por tópico - Israel



Nota: Elaboración propia

Estas visualizaciones permiten identificar los términos dominantes en cada narrativa y su peso relativo, reflejando así la concentración semántica al interior de los clústeres. Los nombres asignados a cada tópico corresponden a una interpretación inductiva basada en las palabras más representativas dentro de cada grupo, lo que facilita la comprensión temática de las narrativas emergentes.

Además de la interpretación cualitativa basada en términos representativos, se incorporaron métricas de coherencia léxica y semántica para validar la consistencia interna de los tópicos. Los valores cuantitativos asociados a cada clúster se presentan más adelante en la sección de “Evaluación de la coherencia léxica y semántica” (ver Tablas 26 y 27), y respaldan la organización temática observada en la caracterización léxica de cada grupo.

### **Tópicos identificados**

#### **Tópico 1 (T1): Narrativa político-institucional**

El primer tópico presenta una estructura léxica centrada en actores estatales, categorización de enemigos y eventos clave relacionados con el conflicto del 7 de octubre. Los términos con mayor peso TF-IDF, como *hamas*, *war*, *state*, *hostage*, *authority*, *idf* y *government*, configuran un campo semántico orientado a la narrativa institucional de respuesta ante el ataque. Este patrón se ve reforzado por la presencia de bigramas como *prime minister*, *terrorist organization*, *release hostage*, *united state* y *october 7th*, que articulan una representación discursiva basada en el accionar de gobiernos, la denominación de actores como terroristas y la referencia explícita a la fecha del 7 de octubre. La estructura temática del clúster enfatiza la reacción estatal, el tratamiento oficial del secuestro de civiles y la legitimación de acciones militares, sin incorporar perspectivas humanitarias ni contextos históricos amplios. Este clúster obtuvo una puntuación C\_V de 0.3244, lo que indica una cohesión léxica moderadamente baja. No obstante, la coherencia semántica E5 alcanza 0.7875, reflejando una buena concentración temática a nivel conceptual.

#### **Tópico 2 (T2): Escalada en la frontera norte**

El segundo tópico presenta una estructura semántica centrada en dinámicas de conflicto en la frontera norte de Israel, con énfasis en el enfrentamiento militar con actores

no estatales regionales. Los n-gramas más relevantes incluyen *idf*, *hamas*, *hezbollah*, *attack*, *rocket*, *strike* y *lebanon*, con pesos TF-IDF que revelan una narrativa marcada por acciones ofensivas y amenazas transfronterizas. Esta composición sugiere un discurso orientado a la escalada del conflicto y la proyección militar hacia el Líbano. La nube de bigramas refuerza esta lectura al destacar combinaciones como *south lebanon*, *air strike*, *defense minister* y *terror group*, que articulan una narrativa de confrontación aérea y militar contra Hezbollah y Hamás. La convergencia entre términos militares, geográficos y políticos sugiere un encuadre de seguridad nacional que prioriza la contención de amenazas externas, particularmente en la frontera con el Líbano. Las métricas reflejan una coherencia léxica sólida ( $C_V = 0.4548$ ) y una alta coherencia semántica ( $E5 = 0.7979$ ), lo que valida la unidad discursiva de este clúster.

### **Tópico 3 (T3): Impacto humanitario**

Este tópico revela una narrativa centrada en el enfrentamiento militar con Hamás, particularmente en contextos urbanos y civiles. Términos como *hamas*, *idf*, *war*, *civilian*, *hospital*, *hostage* y *aid* figuran entre los más relevantes según el peso TF-IDF, lo que sugiere una narrativa que articula operaciones militares con consecuencias humanitarias. Este tópico combina referencias militares con un léxico centrado en consecuencias humanitarias con el uso de palabras como *civilian*, *hospital*, *aid* y *shifa hospital* aparecen asociadas en el discurso. Bigramas como *humanitarian aid*, *air strike* y *hamas terrorist* reflejan una combinación entre términos de seguridad y referencias explícitas a víctimas y estructuras médicas, lo que denota tensión entre objetivos militares y costos humanitarios. En cuanto a coherencia, presenta un  $C_V$  de 0.4122, junto con una coherencia semántica  $E5$  de 0.7937, confirmando una narrativa bien estructurada, aunque con cierta dispersión léxica.

### **Tópico 4 (T4): Guerra y geopolítica**

El tópico presenta un léxico centrado en la narrativa bélica, con alta concentración semántica en torno a dinámicas militares, rehenes y actores internacionales. Predominan términos como *hamas*, *war*, *hostage*, *idf*, *terrorist* y *attack*, lo que sugiere un discurso orientado a la confrontación armada y la figura del enemigo, complementado por términos como *force*, *military*, *rocket* y *ground*. Además, aparecen elementos que reflejan el impacto del conflicto como *civilian*, *community* y *family*. Los bigramas destacados como *united states*, *prime minister*, *middle east* y *tel aviv* amplían el marco del tópico hacia dimensiones

geopolíticas y político-diplomáticas, conectando el discurso con actores estatales. El histograma de términos refuerza esta interpretación, posicionando como términos de mayor peso a *hamas*, *war*, *hostage*, *idf* y *attack*, lo que confirma una narrativa centrada en la guerra y el alcance geopolítico. Las métricas de coherencia son  $C\_V = 0.3705$  y  $E5 = 0.8047$ , siendo este el clúster con mayor cohesión semántica, a pesar de una dispersión moderada en términos léxicos.

#### **T5: Negociaciones y diplomacia internacional**

Este tópico se caracteriza por un léxico centrado en la negociación diplomática, la presión internacional y el rol de figuras políticas. Las visualizaciones correspondientes evidencian una narrativa estructurada en torno a términos como *hostage*, *hamas*, *ceasefire*, *trump*, *prime minister* y *release*, con asociaciones frecuentes hacia actores estatales como *president trump*, *prime minister netanyahu*, *joe biden* y *united state*. La nube de bigramas refuerza esta dimensión diplomática, mostrando la centralidad de expresiones como *release hostage*, *ceasefire agreement* y *three-phase proposal*. En el gráfico de barras de n-gramas, *hostage* y *hamas* son los términos con mayor peso TF-IDF, lo que indica su prominencia en los documentos analizados. Presenta la mayor coherencia léxica de todos los tópicos ( $C\_V = 0.5270$ ) y una alta cohesión semántica ( $E5 = 0.7919$ ), lo que confirma la nitidez temática del discurso diplomático.

#### **T6: Memoria del 7 de octubre**

El tópico presenta una estructura léxica centrada en términos como *hamas*, *hostage*, *family*, *terrorist* y *idf*, lo que sugiere un foco narrativo en torno a los rehenes y su impacto en la población. Los términos con mayor peso TF-IDF son *hostage*, *hamas*, *family*, y *terrorist*, evidenciando una carga temática significativa hacia los rehenes y los vínculos familiares. Las nubes de palabras refuerzan esta estructura semántica con bigramas como *release hostage* y *red cross*, que aportan contexto humanitario y discursivo al tópico. La mención de *october 7th* y *anti semitism* ancla el discurso en la memoria colectiva y la narrativa identitaria. Este clúster exhibe una coherencia temática centrada en las experiencias la construcción mediática y testimonial colectivo del acontecimiento del 7 de octubre. Las métricas arrojan una coherencia léxica intermedia ( $C\_V = 0.3650$ ) y una alta coherencia semántica ( $E5 = 0.8025$ ), reflejando una narrativa sólida centrada en la emocionalidad y la memoria.

La Tabla 25 sintetiza los tópicos con sus términos más relevantes, proporción de videos asociados y fragmentos representativos. Estos últimos fueron seleccionados por cercanía semántica al centroide del clúster en el espacio de embeddings, lo que asegura su representatividad discursiva.

Tabla 25. Resumen temático en la categoría Israel


Tópico	% de videos	Top 15 n-gramas	Fragmento representativo
<b>Narrativa político-institucional (T1)</b>	21.41%	hamas, war, state, hostage, unra, authority, idf, country, civilian, minister, terrorist, government, support	“The aim this time is to destroy Hamas – We demand the immediate and unconditional return of our hostages”
<b>Escalada en la frontera norte (T2)</b>	13.21%	idf, hamas, hezbollah, war, attack, terrorist, hostage, lebanon, strike, rocket, iran, minister, killed, force	“In the north, the IDF targeted a senior Hamas official in Lebanon [...] There was an attempted terrorist infiltration into Israel from Lebanon”
<b>Impacto humanitario (T3)</b>	19.19%	hamas, idf, war, civilian, hospital, terrorist, rafa, hostage, aid, tunnel, operation, rocket, state, attack	“The IDF expanded its ground operation in Gaza [...] Hundreds of thousands of Palestinians are fleeing south”
<b>Guerra y geopolítica (T4)</b>	12.15%	hamas, war, hostage, idf, attack, terrorist, border, state, force, family, rocket, military, civilian, ground, community	“The IDF continues its battle on the ground in the southern part of the Gaza Strip”
<b>Negociaciones y diplomacia internacional (T5)</b>	15.43%	hostage, hamas, trump, war, president, ceasefire, release, minister, state, idf, family, netanyahu, agreement, prime, prime minister	“A major breakthrough in hostage for ceasefire negotiation has reportedly been reached today [...] The focus does remain on securing a deal before U.S. President-elect Donald Trump’s inauguration on January 20th”
<b>Memoria del 7 de octubre (T6)</b>	18.61%	hostage, hamas, family, terrorist, war, community, life, child, state, jewish, idf, soldier	“We are Jews. We must value life. The Israeli government should be brave and take this brave decision: bring them all back”

Nota: Elaboración propia

### Distribución temática por medio y evolución temporal

La distribución de tópicos por canal (ver Ilustración 28) evidencia patrones editoriales diferenciados entre las fuentes analizadas. Estos fueron seleccionados por cercanía semántica al centroide de cada clúster en el espacio de embeddings, asegurando su representatividad discursiva. i24news presenta una fuerte centralización narrativa, liderando en cuatro de los seis tópicos (T1, T3, T4 y T5), lo que sugiere su papel como constructor principal del discurso mediático nacional en torno a la guerra. En contraste, el canal ILTV muestra una especialización temática, siendo altamente relevante en el Tópico 2 (Escalada en la frontera norte) y compartiendo protagonismo en el Tópico 5 (Negociaciones por rehenes). Finalmente, el Tópico 6 (Memoria del 7 de octubre y legitimidad internacional) destaca por una mayor diversidad de fuentes, con participación significativa de Jerusalem Post y StandWithUs, lo que sugiere una apertura discursiva hacia voces comunitarias y de diplomacia pública en el tratamiento del trauma y la narrativa de victimización.


Ilustración 28. Distribución de canales por tópico - Israel



Nota: Elaboración propia

Desde una perspectiva temporal, la Ilustración 29 muestra fluctuaciones dinámicas en la cobertura. El Tópico 1 mantiene una presencia sostenida en el tiempo, mientras que el Tópico 2 presenta picos significativos hacia enero de 2025, reflejando momentos de escalada militar. Por su parte, el Tópico 5 también muestra repuntes marcados, coincidiendo con avances en negociaciones por rehenes. El Tópico 6, ligado al trauma del 7 de octubre, aparece como constante desde los primeros días del conflicto.

Ilustración 29. Evolución temporal de los tópicos - Israel



Nota: Elaboración propia

### Evaluación de la coherencia léxica y semántica

El modelado temático se realizó mediante reducción de dimensionalidad con UMAP y agrupamiento con K-Means sobre embeddings generados por BERT. Para evaluar la consistencia interna de los clústeres, se emplearon las métricas clásicas de coherencia léxica  $C_V$  y  $U_{Mass}$  (Ver tabla 26). Los resultados muestran que el Tópico 5 (Negociaciones y diplomacia internacional) presenta la mayor coherencia en ambas métricas ( $C_V = 0.5270$ ;  $U_{Mass} = -0.4783$ ), lo que sugiere una estructura semántica bien delimitada y una alta consistencia entre los términos del clúster. En contraste, el Tópico 1 (Narrativa político-institucional) refleja la menor cohesión interna ( $C_V = 0.3244$ ;  $U_{Mass} = -0.5628$ ), lo que indica una mayor dispersión léxica al interior del grupo temático.

*Tabla 26. Métricas de coherencia léxica por tópico - Israel*

Tópico	Coherencia C.V	Coherencia U.Mass
Narrativa político-institucional (T1)	0.3244	-0.5628
Escalada en la frontera norte (T2)	0.4548	-0.4780
Impacto humanitario (T3)	0.4122	-0.5903
Guerra y geopolítica (T4)	0.3705	-0.4896
Negociaciones y diplomacia internacional (T5)	0.5270	-0.4783
Memoria del 7 de octubre (T6)	0.3650	-0.5197

*Nota: Elaboración propia*

Además, se implementó una evaluación vectorial adicional usando el modelo E5-large-v2, preentrenado para tareas de recuperación semántica. Para cada clúster, se seleccionaron los 10 términos con mayor puntuación TF-IDF y se calcularon todas las combinaciones posibles de similitud coseno entre sus vectores. El valor promedio resultante (ver Tabla 27) representa el grado de cohesión semántica entre los términos del clúster. Los puntajes obtenidos en la categoría Israel oscilan entre 0.7875 (T1) y 0.8047 (T4), lo que indica una coherencia semántica relativamente alta y homogénea entre los tópicos identificados.

*Tabla 27. Coherencia semántica por tópico - Israel*

Tópico	Coherencia E5
Narrativa político-institucional (T1)	0.7875
Escalada en la frontera norte (T2)	0.7979
Impacto humanitario (T3)	0.7937
Guerra y geopolítica (T4)	0.8047
Negociaciones y diplomacia internacional (T5)	0.7919
Memoria del 7 de octubre (T6)	0.8025

*Nota: Elaboración propia*

Los resultados del modelado temático evidencian una narrativa israelí organizada en torno a seis clústeres discursivos que combinan referencias militares, institucionales, diplomáticas y humanitarias. Esta narrativa articula ejes semánticos como la seguridad


nacional y la amenaza terrorista (T1, T2 y T4), la dimensión diplomática y geopolítica (T5), y la memoria del trauma junto con la legitimidad moral (T3 y T6). El acontecimiento del 7 de octubre se consolida como el punto de convergencia en todos los tópicos, funcionando como marcador temporal, emocional y estratégico que estructura la narrativa global. Su aparición predominante en el discurso refuerza el encuadre de emergencia nacional, legitimando respuestas militares e intervenciones diplomáticas. El discurso israelí construye una imagen cohesionada del conflicto que tiene como objetivo la denuncia del terrorismo, la defensa de la población civil y la exigencia de respaldo internacional. La narrativa israelí se presenta como una construcción altamente institucionalizada y estratégicamente articulada. A través del uso de registros bélicos, diplomáticos y testimoniales, busca proyectar legitimidad frente a audiencias tanto locales como internacionales, reforzando su posición en el plano militar, geopolítico y moral. No obstante, en los discursos analizados se observa una escasa referencia a dimensiones estructurales del conflicto —como la ocupación, el bloqueo o las condiciones en Gaza previas al 7 de octubre— lo que delimita el marco interpretativo hacia una visión más reactiva y centrada en la autodefensa. Esta ausencia sugiere un enfoque discursivo que privilegia ciertos marcos explicativos mientras relega otros al margen del relato dominante.

### **8.5.3. Estructura discursiva y tópicos predominantes en Internacional**

El análisis temático identificó cuatro tópicos centrales en la categoría Internacional, definidos a partir de n-gramas y bigramas ponderados mediante TF-IDF. Las visualizaciones correspondientes (Ilustraciones 30, 31 y 32) evidencian una organización semántica bien delimitada, con patrones discursivos diferenciados y alta coherencia léxica al interior de cada grupo. Cada visualización individual dentro de las ilustraciones representa un tópico específico, permitiendo visualizar el vocabulario más representativo dentro de cada clúster.

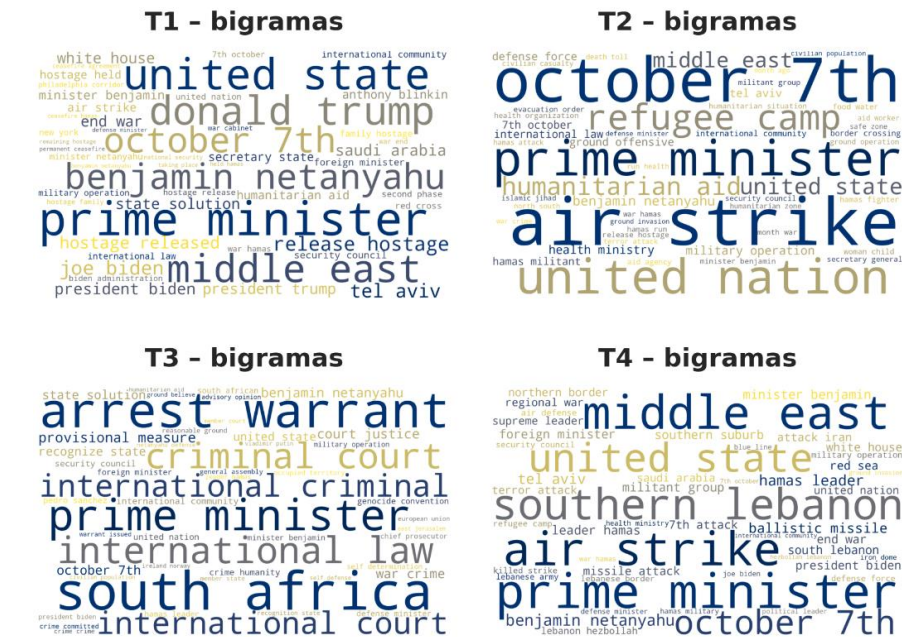
Además de la interpretación cualitativa basada en términos representativos, se incorporaron métricas de coherencia léxica y semántica para validar la consistencia interna de los tópicos. Los valores cuantitativos asociados a cada clúster se presentan más adelante en la sección de “Evaluación de la coherencia léxica y semántica” (ver Tablas 29 y 30), y respaldan la organización temática observada en la caracterización léxica de cada grupo.

Ilustración 30. Nube de n-gramas por tópico - Internacional



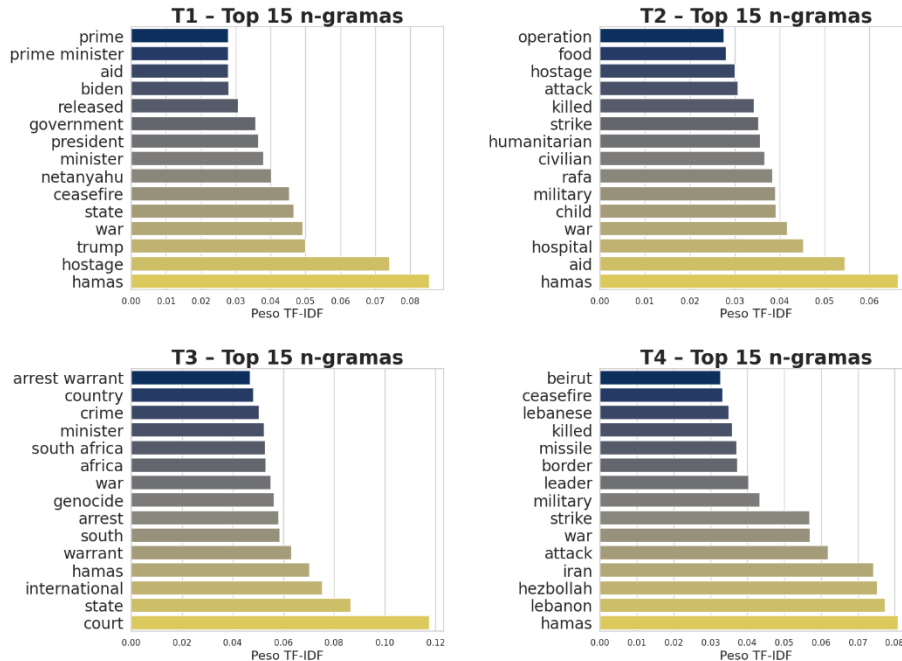
Nota: Elaboración propia

Ilustración 31. Nubes de bigramas por tópico - Internacional



Nota: Elaboración propia

Ilustración 32. Top 15 de términos con mayor peso TF-IDF por tópico - Internacional



Nota: Elaboración propia

Estas visualizaciones permiten identificar los términos dominantes en cada narrativa y su peso relativo, reflejando así la concentración semántica al interior de los clústeres. Los nombres asignados a cada tópico corresponden a una interpretación inductiva basada en las palabras más representativas dentro de cada grupo, lo que facilita la comprensión temática de las narrativas emergentes.

**Tópicos identificados**

**Tópico 1 (T1): Rehenes y legitimación estatal**

Este clúster se enfoca en eventos relacionados con la crisis de rehenes, respuestas estatales y posicionamientos diplomáticos. Los términos más relevantes por TF-IDF como *hamas*, *hostage*, *trump*, *war*, *state*, *ceasefire* conforman un grupo semántico en el que se relacionan actores gubernamentales, referencias al conflicto armado y discursos de legitimación. Los bigramas como *prime minister*, *united state*, *october 7th* y *release hostage* refuerzan esta estructura discursiva al vincular el accionar estatal con medidas de contención y negociación. El énfasis léxico en figuras como *trump*, *biden* y *netanyahu* sugiere una narrativa fuertemente institucionalizada, en la que las acciones

gubernamentales y diplomáticas adquieren protagonismo en la cobertura internacional. Este clúster exhibe una organización discursiva coherente y temática, dominada por términos asociados al conflicto diplomático, los rehenes y la respuesta estatal en medios internacionales. En términos de coherencia, este clúster obtuvo una puntuación C\_V de 0.5181 y una coherencia semántica E5 de 0.7944, lo que indica una buena concentración léxica y una sólida cohesión temática a nivel conceptual.

### **Tópico 2 (T2): Crisis humanitaria**

El segundo clúster presenta una fuerte orientación léxica hacia los efectos humanitarios del conflicto. Los términos con mayor peso TF-IDF *hamas, aid, hospital, war, civilian, child, humanitarian, strike*, evidencian una narrativa centrada en la asistencia internacional, las víctimas civiles y el colapso de la infraestructura médica. Los bigramas más frecuentes como *air strike, refugee camp, humanitarian aid y october 7th*, refuerzan un discurso orientado a la denuncia ante la crisis humanitaria, en el que se articulan llamados al alto al fuego y la intervención de organismos internacionales. El clúster proyecta una coherencia temática clara, donde el énfasis recae en las consecuencias humanas, el colapso hospitalario, la escasez de recursos y los llamados a un alto al fuego por parte de actores humanitarios y diplomáticos. La puntuación C\_V de 0.4791 y E5 de 0.7985 reflejan una coherencia moderadamente alta, que respalda la solidez del discurso humanitario identificado en este grupo.

### **Tópico 3 (T3): Legalidad internacional y procesos judiciales**

Este clúster se caracteriza por un léxico fuertemente institucional y jurídico. Se evidencia una alta concentración semántica en términos como *court, state, international, warrant, arrest, genocide, hamas y south africa*, lo cual sugiere una narrativa fundamentada en marcos legales internacionales, procesos judiciales supranacionales y la acusación formal de crímenes de guerra. Las nubes de palabras y bigramas refuerzan esta orientación discursiva, destacando combinaciones como *arrest warrant, criminal court, international law, south africa e international criminal*. Estas expresiones aluden explícitamente a resoluciones de la Corte Penal Internacional (CPI), a la Corte Internacional de Justicia (CIJ), y a procedimientos legales vinculados al genocidio y crímenes de guerra. El tópico exhibe una cohesión temática sólida en torno a la judicialización del conflicto, el papel del derecho internacional y las tensiones diplomáticas que emergen a partir de decisiones

judiciales que desafían la legitimidad de las acciones bélicas. Este clúster evidencia la una coherencia léxica alta, con una puntuación C\_V de 0.5621. La coherencia semántica E5 de 0.7891 sugiere una organización conceptual sólida en torno a la judicialización del conflicto.

#### **Tópico 4 (T4): Confrontación regional**

Este clúster despliega una narrativa geopolítica que extiende el conflicto más allá de Gaza, hacia el norte de Israel, el Líbano e Irán. El léxico con mayor peso como *lebanon*, *hezbollah*, *hamas*, *iran*, *missile*, *war*, *border*, *strike* indica una escalada bélica regional en múltiples frentes. El análisis de n-gramas revela un eje discursivo centrado en la expansión regional del conflicto. Los bigramas más frecuentes como *southern lebanon*, *ballistic missile*, *air strike*, *united state* y *benjamin Netanyahu*, configuran una narrativa de guerra transfronteriza, respaldada por referencias a bombardeos, evacuaciones, asesinatos selectivos y amenazas regionales. La estructura temática sugiere una proyección discursiva que legitima la expansión militar israelí bajo argumentos de defensa preventiva frente a Hezbollah e Irán, consolidando una lectura del conflicto como parte de una disputa regional de gran escala. Este clúster alcanza la puntuación C\_V más alta (0.5729), lo que refleja una fuerte cohesión léxica, complementada con un valor E5 de 0.7935, que confirma la densidad semántica del tópico.

Cada clúster ha sido validado mediante selección de fragmentos representativos por cercanía semántica al centroide del clúster en el espacio de embeddings, asegurando su representatividad discursiva. La Tabla 28 resume los tópicos con sus términos más relevantes, proporción de videos y ejemplos representativos.

*Tabla 28. Resumen temático en la categoría Internacional*


<b>Tópico</b>	<b>% de videos</b>	<b>Top 15 n-gramas</b>	<b>Fragmento representativo</b>
<b>Rehenes y legitimación estatal (T1)</b>	43.63%	hamas, hostage, trump, war, state, ceasefire, netanyahu, minister, president, government, released, biden, prime, prime minister, aid	“We are working to achieve an additional framework for the release of our captives, but I stress: not at any cost. We will not finish the war, we will not remove the IDF from the Strip”
<b>Crisis humanitaria (T2)</b>	42.15%	hamas, aid, hospital, war, child, military, rafa, civilian, humanitarian, strike, killed, attack, hostage, food, operation	“From every angle – airstrikes, fuel shortage, food shortage – the children of Gaza especially are suffering right now”
<b>Legalidad internacional y procesos judiciales (T3)</b>	3.81%	court, state, international, hamas, warrant, south, arrest, genocide, war, africa, south africa, minister, crime, country, arrest warrant	“The International Court of Justice has ordered Israel to stop its military offensive... and to allow unhindered access of aid”
<b>Confrontación regional (T4)</b>	10.41%	hamas, lebanon, hezbollah, iran, attack, war, strike, military, leader, border, missile, killed, lebanese, ceasefire, beirut	“Israeli fighter jets dropped a series of bombs on Beirut’s southern suburbs targeting Hezbollah’s top commander... Hezbollah confirmed that the explosion killed its leader Hassan Nasrallah... Netanyahu: ‘an historic turning point’”

*Nota: Elaboración propia*

### Distribución temática por medio y evolución temporal

La distribución de tópicos por canal (ver Ilustración 33) muestra patrones editoriales diferenciados entre los medios internacionales. France 24 lidera ampliamente en los cuatro tópicos, con especial énfasis en el Tópico 2 (Crisis humanitaria) y el Tópico 3 (Legalidad internacional), lo que sugiere una cobertura transversal del conflicto con enfoque diplomático y humanitario. DW News presenta una distribución más equilibrada, aunque con menor presencia en el tópico 4 y mayor concentración en los otros tópicos, lo que indica un interés por las negociaciones políticas y la judicialización del conflicto. Por su parte, BBC y CNN concentran su cobertura en el Tópico 4 (Confrontación regional).

Ilustración 33. Distribución de canales por tópico - Internacional




Nota: Elaboración propia

Desde una perspectiva temporal (ver Ilustración 34), se observa una dinámica evolutiva marcada por picos específicos. El Tópico 1 (Rehenes y legitimación estatal) mantiene una presencia constante a lo largo del periodo analizado, con un fuerte repunte a inicios de 2025, coincidiendo con procesos de negociación y liberación de rehenes. El Tópico 2 (Crisis humanitaria) muestra mayor intensidad a finales de 2023 y mediados de 2024, reflejando picos y bombardeos masivos. El Tópico 3 (Legalidad internacional) exhibe una cobertura intermitente, con picos asociados a hitos jurídicos, como pronunciamientos de la Corte Penal Internacional. Finalmente, el Tópico 4 (Confrontación regional) presenta un

aumento sostenido hacia octubre de 2024, probablemente vinculado a episodios de escalada militar en Líbano y el norte de Israel.

Ilustración 34. Evolución temporal de los tópicos - Internacional



Nota: Elaboración propia

### Evaluación de la coherencia léxica y semántica

La evaluación de la coherencia léxica se realizó utilizando las métricas  $C_V$  y  $U_{Mass}$ , cuyos resultados se presentan en la Tabla 29. El Tópico 4 (Confrontación regional) obtuvo la mayor coherencia léxica ( $C_V = 0.5729$ ), seguido por el Tópico 3 (Legalidad internacional), lo que indica una alta consistencia léxica en sus patrones discursivos. En contraste, el Tópico 2 mostró los valores más bajos ( $C_V = 0.4791$ ), lo que sugiere mayor dispersión léxica dentro del clúster.

*Tabla 29. Métricas de coherencia léxica por tópico - Internacional*

Tópico	Coherencia C.V	Coherencia U.Mass
Rehenes y legitimación estatal (T1)	0.5181	-0.6559
Crisis humanitaria (T2)	0.4791	-0.7031
Legalidad internacional y procesos judiciales (T3)	0.5621	-1.3434
Confrontación regional (T4)	0.5729	-0.9873

*Nota: Elaboración propia*

Además, se implementó una evaluación vectorial adicional usando el modelo E5-large-v2, preentrenado para tareas de recuperación semántica. Para cada clúster, se seleccionaron los 10 términos con mayor puntuación TF-IDF y se calcularon todas las combinaciones posibles de similitud coseno entre sus vectores. El valor promedio resultante (ver Tabla 30) representa el grado de cohesión semántica entre los términos del clúster. Los puntajes obtenidos en la categoría Israel oscilan entre 0.7875 (T1) y 0.8047 (T4), lo que indica una coherencia semántica relativamente alta y homogénea entre los tópicos identificados.

*Tabla 30. Coherencia semántica por tópico - Internacional*

Tópico	Coherencia E5
Rehenes y legitimación estatal (T1)	0.7944
Crisis humanitaria (T2)	0.7985
Legalidad internacional y procesos judiciales (T3)	0.7891
Confrontación regional (T4)	0.7935

*Nota: Elaboración propia*

La narrativa internacional se estructura en torno a cuatro tópicos diferenciados: crisis de rehenes, dimensión humanitaria, legalidad internacional y confrontación regional. Aunque en términos metodológicos se presenta como un discurso multivocal y regulador, los fragmentos analizados evidencian una alineación predominante con el encuadre israelí, particularmente en los tópicos sobre legitimación estatal (T1) y seguridad regional (T4).


Los medios priorizan la visibilización de figuras como Netanyahu, Biden o Blinken, el derecho a la defensa, y la narrativa de amenaza regional. La dimensión humanitaria (T2) y legal (T3) también está presente, pero enmarcada mayoritariamente desde la lógica occidental de responsabilidad moral o cumplimiento legal, sin descentrar del todo la narrativa hegemónica. El discurso internacional se configura como una narrativa institucional, jurídica y diplomática, pero condicionada por marcos de interpretación que favorecen el posicionamiento geoestratégico de Israel, limitando así el potencial de neutralidad o mediación que se le atribuye en el análisis superficial.

#### **8.5.4. Estructura discursiva y tópicos predominantes en Internacional Medio Oriente**

El análisis temático aplicado a la categoría Internacional Medio Oriente identificó tres tópicos centrales, definidos a partir de n-gramas y bigramas ponderados mediante TF-IDF. Las visualizaciones correspondientes (Ilustraciones 35, 36 y 37) evidencian una organización semántica diferenciada y una alta coherencia temática entre clústeres, lo que permite identificar patrones discursivos dominantes en medios no alineados directamente con las partes en conflicto.

Además de la interpretación cualitativa basada en términos representativos, se incorporaron métricas de coherencia léxica y semántica para validar la consistencia interna de los tópicos. Los valores cuantitativos asociados a cada clúster se presentan más adelante en la sección de “Evaluación de la coherencia léxica y semántica” (ver Tablas 32 y 33), y respaldan la organización temática observada en la caracterización léxica de cada grupo.

Ilustración 35. Nube de n-gramas por tópico - Internacional Medio Oriente



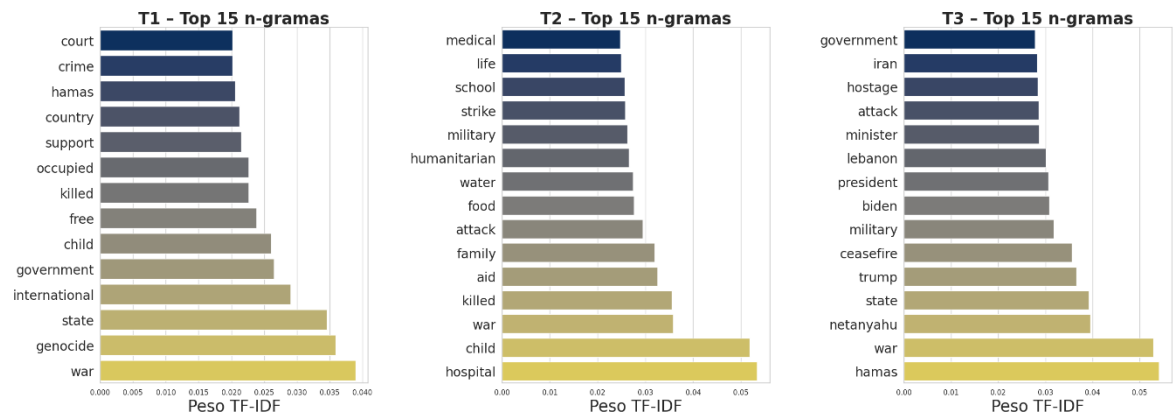
Nota: Elaboración propia

Ilustración 36. Nubes de bigramas por tópico – Internacional Medio Oriente



Nota: Elaboración propia

Ilustración 37. Top 15 de términos con mayor peso TF-IDF por tópico – Internacional Medio Oriente



Nota: Elaboración propia

Estas visualizaciones permiten identificar los términos dominantes en cada narrativa y su peso relativo, reflejando así la concentración semántica al interior de los clústeres. Los nombres asignados a cada tópico corresponden a una interpretación inductiva basada en

las palabras más representativas dentro de cada grupo, lo que facilita la comprensión temática de las narrativas emergentes.

### **Tópicos identificados**

#### **Tópico 1 (T1): Acusaciones de genocidio y violaciones del derecho internacional**

Este clúster se estructura en torno a términos con alta carga jurídico-política como *genocide, war, court, state, international y crime*. La composición léxica sugiere un discurso centrado en la judicialización del conflicto, con énfasis en crímenes de guerra, violaciones al derecho internacional y la implicación de actores estatales. Los bigramas más frecuentes como *international law, war crime, refugee camp y south africa* refuerzan esta orientación temática, aludiendo a procesos legales internacionales y resoluciones de organismos como la Corte Penal Internacional. El tópico refleja una narrativa acusatoria de alta cohesión semántica, sostenida en marcos legales y resoluciones multilaterales. En términos de coherencia, este clúster obtuvo una puntuación C\_V de 0.3659, lo que indica una cohesión léxica relativamente baja. Sin embargo, la coherencia semántica E5 alcanza un valor de 0.8060, evidenciando una sólida concentración temática a nivel conceptual, fundamentada en marcos legales y resoluciones multilaterales.

#### **Tópico 2 (T2): Ataques a infraestructura médica y crisis humanitaria**

Este tópico presenta una orientación léxica enfocada en las consecuencias humanitarias del conflicto. Palabras como *hospital, child, killed, aid, family y attack* dominan el campo semántico, proyectando una narrativa centrada en víctimas civiles, desplazamiento forzado y colapso sanitario. Los bigramas como *air strike, humanitarian aid, refugee camp y united nation* refuerzan esta estructura discursiva, aludiendo a bombardeos sistemáticos, escasez de insumos y respuestas de organismos internacionales. Este clúster exhibe una alta coherencia temática, con un enfoque explícito en la crisis de salud, inseguridad alimentaria y emergencia humanitaria. Este clúster exhibe una alta coherencia temática, respaldada por un puntaje C\_V de 0.5600, lo cual indica una buena cohesión léxica. La coherencia semántica también es elevada, con un valor E5 de 0.8146, lo que confirma la consistencia del discurso en torno a la crisis de salud y la emergencia humanitaria.

#### **Tópico 3 (T3): Negociaciones y liderazgo internacional**

El tercer clúster articula un discurso diplomático e institucional, centrado en figuras políticas, procesos de negociación y posicionamientos estratégicos. Los términos más

relevantes incluyen *war, ceasefire, netanyahu, trump, biden y hamas*, lo que refleja una narrativa orientada a la intervención internacional y la legitimación estatal. Bigramas como *prime minister, united state, joe biden y benjamin netanyahu* configuran una red discursiva centrada en mediaciones diplomáticas y liderazgo político, particularmente de Estados Unidos e Israel. Este tópico presenta una estructura léxica coherente que vincula el seguimiento político del conflicto con presiones internacionales, rondas de negociación y discursos de legitimación. Las métricas de coherencia refuerzan esta lectura. El clúster presenta un valor  $C_V$  de 0.4886 y una coherencia semántica E5 de 0.7899, lo que indica una organización temática estable y conceptualizada en torno a las dinámicas del liderazgo político internacional.

Cada clúster ha sido validado mediante selección de fragmentos representativos por cercanía semántica al centroide del clúster en el espacio de embeddings, asegurando su representatividad discursiva. La Tabla 31 resume los tópicos con sus términos más relevantes, proporción de videos y ejemplos representativos.

Tabla 31. Resumen temático en la categoría Internacional Medio Oriente

Tópico	% de videos	Top 15 n-gramas	Fragmento representativo
<b>Acusaciones de genocidio y violaciones del derecho internacional (T1)</b>	41.10%	war, genocide, state, international, government, child, free, occupied, killed, support, country, hamas, court, crime	“Despite several binding order by the International Court of Justice in the case of genocide brought forward by South Africa, Israel has made sure that famine set in, obstructing aid [...] Israel is in breach of every aspect of international law: the ICC, the ICJ, the Geneva Convention... in defiance of the UN Security Council and General Assembly.”
<b>Ataques a infraestructura médica y crisis humanitaria (T2)</b>	32.08%	hospital, child, war, killed, aid, family, attack, food, water, humanitarian, military, strike, school, life, medical	“Children are starving to death... there’s no food, no water, no medical intervention, nothing [...] The health care system is on the brink of collapse. Hospitals are out of service, and medical staff are overwhelmed”
<b>Negociaciones y liderazgo internacional (T3)</b>	26.81%	hamas, war, netanyahu, state, trump, ceasefire, military, biden, president, lebanon, minister, attack, hostage, iran, government	“The U.S. administration is facing pressure from within... many Democratic senators are opposing further aid to Israel unless a serious diplomatic process is initiated.”


Nota: Elaboración propia

### Distribución temática por medio y evolución temporal

La distribución de tópicos por canal (ver Ilustración 38) evidencia un claro liderazgo de Al Jazeera, con más del 55 % de participación en los tópicos T2 y T3. TRT World ocupa una posición relevante con cobertura balanceada, mientras que Middle East Eye y Al

Mayadeen English muestran una representación marginal. Esta concentración sugiere una construcción narrativa dominada por enfoques humanitarios y diplomáticos promovidos por los medios más activos.


Ilustración 38. Distribución de canales por tópico - Internacional Medio Oriente



Nota: Elaboración propia

En términos temporales (Ilustración 39), se observa una evolución temática dinámica: el Tópico 1 (genocidio y derecho internacional) domina en los primeros meses del conflicto, mientras que T2 (crisis humanitaria) y T3 (negociaciones) adquieren mayor protagonismo en etapas posteriores. Este desplazamiento discursivo indica una transición desde marcos acusatorios hacia registros humanitarios y diplomáticos, en concordancia con la evolución del conflicto y los ciclos mediáticos.

Ilustración 39. Evolución temporal de los tópicos - Internacional Medio Oriente



Nota: Elaboración propia

### Evaluación de la coherencia léxica y semántica

La evaluación de la coherencia léxica se realizó utilizando las métricas C\_V y U\_Mass, cuyos resultados se presentan en la Tabla 32. Los resultados muestran que el Tópico 2 presenta la mayor consistencia interna (C\_V = 0.5600), seguido por el Tópico 3 (0.4886). El Tópico 1 obtiene el valor más bajo (0.3659), lo que sugiere mayor diversidad léxica en sus expresiones.

Tabla 32. Métricas de coherencia léxica por tópico - Internacional Medio Oriente

Tópico	Coherencia C_V	Coherencia U_Mass
Acusaciones de genocidio y violaciones del derecho internacional (T1)	0.3659	-1.1056
Ataques a infraestructura médica y crisis humanitaria (T2)	0.5600	-1.0686
Negociaciones y liderazgo internacional (T3)	0.4886	-1.0763

Nota: Elaboración propia

Además, se implementó una evaluación vectorial adicional usando el modelo E5-large-v2, preentrenado para tareas de recuperación semántica. Para cada clúster, se seleccionaron los 10 términos con mayor puntuación TF-IDF y se calcularon todas las combinaciones posibles de similitud coseno entre sus vectores. La evaluación semántica basada (Tabla 33) evidencia altos niveles de cohesión en todos los clústeres, con puntuaciones superiores a 0.78. El Tópico 2 (0.8146) alcanza la mayor coherencia semántica, lo que refuerza su solidez discursiva.

Tabla 33. *Coherencia semántica por tópico - Internacional Medio Oriente*

Tópico	Coherencia E5
Acusaciones de genocidio y violaciones del derecho internacional (T1)	0.8060
Ataques a infraestructura médica y crisis humanitaria (T2)	0.8146
Negociaciones y liderazgo internacional (T3)	0.7899

*Nota: Elaboración propia*

Los resultados del modelado temático evidencian que la narrativa de los medios Internacional Medio Oriente se articula en torno a tres ejes discursivos principales: las acusaciones por crímenes internacionales (T1), la denuncia humanitaria (T2) y los procesos de negociación geopolítica (T3). Esta configuración refleja un posicionamiento editorial con alta cohesión semántica, orientado a documentar las consecuencias del conflicto, cuestionar la legalidad de las acciones militares israelíes y visibilizar los esfuerzos diplomáticos en curso. Esta narrativa adopta un enfoque híbrido que combina la denuncia jurídica internacional con la atención a las víctimas civiles y la cobertura de actores clave en las negociaciones. En conjunto, la narrativa de los medios internacionales del Medio Oriente se presenta como una construcción discursiva cohesionada, con alta consistencia léxica y semántica, que equilibra la crítica legal, la denuncia humanitaria y el seguimiento político. Su cobertura otorga centralidad a las víctimas, cuestiona la legitimidad de las acciones armadas y posiciona el liderazgo internacional como un factor clave en la resolución del conflicto. A diferencia de los medios occidentales, aquí se observa una mayor intencionalidad crítica y un esfuerzo por incorporar marcos normativos internacionales y registros de justicia global, sin diluir el peso ético del sufrimiento civil ni invisibilizar los actores no estatales implicados.

### **Conclusión comparativa**


El modelado temático evidencia construcciones discursivas claramente diferenciadas entre las categorías analizadas. La narrativa palestina se articula desde una lógica política, jurídica y crítica, combinando registros de resistencia, denuncia humanitaria y apelaciones a marcos de justicia internacional. Se configura como un discurso acumulativo, en el que

el conflicto actual se inserta dentro de una continuidad histórica de ocupación, violencia estructural y lucha prolongada. Conceptos como apartheid, colonialismo o limpieza étnica estructuran una narrativa orientada a la legitimación simbólica y jurídica del reclamo palestino, con una interpelación constante hacia la comunidad internacional por su percepción de inacción o parcialidad. En contraste, la narrativa israelí se organiza principalmente en torno al acontecimiento del 7 de octubre, que actúa como eje estructurante del discurso. Este evento es presentado como una ruptura sin precedentes que justifica la ofensiva bélica posterior, activa marcos de autodefensa y orienta la demanda de respaldo internacional. La figura de Hamas es construida como enemigo central mediante su constante rotulación como organización terrorista, reforzando un encuadre binario centrado en la amenaza existencial. Esta narrativa, cohesionada y altamente institucionalizada, apela a registros bélicos, diplomáticos y testimoniales que privilegian la defensa nacional, al tiempo que minimizan, en los discursos analizados, referencias al contexto estructural del conflicto, como la ocupación o el bloqueo de Gaza. A nivel internacional, los medios occidentales tienden a reproducir de forma acrítica esta narrativa, adoptando marcos interpretativos centrados en la seguridad nacional israelí y el combate al terrorismo. Aunque las dimensiones humanitaria y jurídica están presentes, estas son encuadradas desde lógicas normativas occidentales que rara vez cuestionan el desequilibrio estructural del conflicto. La cobertura mediática prioriza el trauma israelí y la figura del rehén, mientras omite o minimiza sistemáticamente las consecuencias de los ataques sobre la población civil palestina. Este desequilibrio discursivo contribuye a la legitimación de las acciones militares israelíes y al silenciamiento de las narrativas alternativas. Por el contrario, los medios del Medio Oriente adoptan un enfoque más crítico y cohesivo, centrado en las consecuencias humanitarias, la denuncia jurídica y los procesos de negociación, incorporando marcos normativos internacionales con mayor consistencia. Su representación del conflicto es más plural y descentralizada, visibilizando tanto a actores estatales como no estatales y problematizando las estructuras de poder que configuran el conflicto. Así, la teoría del encuadre permite evidenciar cómo los medios no solo informan, sino que construyen activamente el sentido del conflicto, privilegiando ciertas perspectivas y silenciando otras según alineamientos geopolíticos y culturales.

Los patrones léxicos observados en la Ilustración 40 complementan y refuerzan las dinámicas discursivas identificadas en el modelado temático. La distribución de términos

clave por categoría, ponderados mediante TF-IDF, permite visualizar con claridad la jerarquía semántica interna de cada narrativa. La categoría Israel destaca por una centralidad léxica absoluta del término *hamas*, acompañado de *hostage*, *idf* y *trump*, lo que consolida un encuadre discursivo centrado en la amenaza externa, la defensa militar y la búsqueda de respaldo internacional. Por su parte, el término *genocide*, ausente en la narrativa israelí, cobra peso en Palestina e Internacional, donde adquiere un valor argumentativo jurídico y ético. La narrativa palestina incorpora un léxico centrado en el sufrimiento colectivo y la confrontación territorial, con términos como *fighter*, *tank*, *hospital* o *killed*, que reflejan tanto las dinámicas de resistencia como los efectos humanitarios del conflicto, mientras que Internacional Medio Oriente incorpora un léxico testimonial y normativo, con peso en *child*, *family* y *hospital*. Por último, la categoría Internacional proyecta un discurso jurídico-global, evidenciado por la prominencia de *court*, *hezbollah* e *iran*. La ilustración permite apreciar además cómo términos como *family*, *child* o *war* reflejan diferencias en la personalización del dolor, la representación del enemigo y la construcción de legitimidad. Estos hallazgos léxicos consolidan la coherencia temática identificada en cada clúster, y validan los encuadres discursivos previamente analizados.

Ilustración 40. Mapa de calor de términos más relevantes por categoría



Nota: Elaboración propia

La identificación de tópicos mediante embeddings, reducción dimensional y agrupamiento permitió caracterizar con precisión las principales narrativas discursivas asociadas al conflicto, organizadas por categoría geopolítica. Esta estructuración temática no solo facilitó una interpretación cualitativa del discurso, sino que también sirvió como base para la siguiente fase del análisis. A partir de los clústeres obtenidos, se seleccionaron de forma estratégica comentarios representativos por categoría y tópico, asegurando una cobertura balanceada y diversa del espectro narrativo identificado. Esta selección estructurada de comentarios constituyó el insumo para el proceso de etiquetado emocional, estableciendo así una continuidad metodológica entre el modelado temático y la clasificación afectiva.

## **8.6. Fine-tuning de comentarios**

### **8.6.1. Recolección automatizada de comentarios**

El script recolectó alrededor de 164.000 comentarios únicos mediante un sistema rotativo de 14 claves API, lo que evitó bloqueos por cuota y permitió ejecutar cada iteración en menos de una hora, con una media de 20.000 comentarios por ejecución. Durante la recolección, se aplicaron filtros automáticos para excluir comentarios repetidos, no ingleses o con escaso contenido informativo, y se utilizó un registro incremental para evitar duplicaciones entre ejecuciones.

A partir de este corpus general, se extrajo una muestra balanceada de más de 8.000 comentarios, proporcionalmente distribuida entre tópicos y categorías, garantizando representatividad narrativa. Esta muestra fue preparada para su etiquetado emocional supervisado. Todos los archivos fueron almacenados de forma estructurada en Google Drive, asegurando trazabilidad, respaldo y control de versiones para el análisis posterior.

### **8.6.2. Definición operativa de emociones clasificadas**

La selección de emociones se diseñó para capturar la dimensión afectiva dominante en los discursos digitales sobre el conflicto palestino-israelí. El esquema adoptado incluye cinco emociones: Resistencia, Tristeza, Ira, Sarcasmo y Esperanza. Esta elección permite un equilibrio analítico entre emociones negativas (tristeza e ira), positivas (esperanza) y de naturaleza moral, política o retórica (resistencia y sarcasmo), lo cual posibilita una lectura más profunda que la simple polaridad sentimental tradicional. Si bien modelos clásicos como el de Plutchik (1980) proponen emociones universales como alegría, miedo o sorpresa, este esquema se diseñó a partir del tono discursivo dominante en escenarios de guerra simbólica. Se toma como referencia teórica el enfoque de Hutchison y Bleiker (2014), quienes subrayan la importancia de teorizar el tránsito de las emociones individuales a su dimensión colectiva, destacando su potencial performativo en contextos políticos específicos. Estas emociones situadas, no universales, sino emergentes en condiciones particulares de conflicto, permiten revelar cómo el poder, la memoria y la representación se articulan en los discursos afectivos contemporáneos. La clasificación adoptada se fundamentó también en una exploración inductiva del corpus, donde se observó la aparición sistemática, frecuente y diferenciable de estas cinco emociones. Esto

confirmó su pertinencia empírica, además de su coherencia semántica, lo que justifica su uso como etiquetas de clasificación en el modelo propuesto.

La tabla 34 caracteriza las emociones seleccionadas y su definición operativa, la cual sirvió como guía para el proceso de anotación. Esta definición fue utilizada tanto para el etiquetado manual como para la revisión posterior de las predicciones automáticas.

Tabla 34. Definición operativa de las emociones etiquetadas

Emoción	Tono dominante	Indicadores lingüísticos	Ejemplos de expresiones	Palabras clave / frases
<b>Tristeza</b>	Dolor, pérdida, impotencia	Enunciados que expresan sufrimiento, luto, tragedia o resignación	<i>This is horrific 😞 Please stop this madness. Poor children 😞</i>  <i>If only we could help you 😞😞</i>	<i>tragic, heartbreaking, helpless, I feel sorry, makes me cry</i>
<b>Sarcasmo</b>	Burla, ironía, ridiculización, desprecio indirecto	Comentarios irónicos, tono exagerado, bromas sobre el conflicto o actores clave	<i>Deport Gaza 😏😏</i>  <i>Victim card activated 😏</i>	<i>lol, clown, puppy, so much for peace, what a joke</i>
<b>Resistencia</b>	Lucha activa, dignidad, coraje, orgullo nacional y apoyo explícito	Verbos de acción, llamados a protestar, apoyo a movimientos de resistencia, declaraciones de afiliación a un bando del conflicto.	<i>They don't want peace 🙌🙌 be strong Israel</i>  <i>Free free Palestine! Big shoutout to the resistance!! 🍌</i>	<i>Free Palestine, resist, boycott, freedom fighters, from the river to the sea, I stand with Israel</i>
<b>Ira</b>	Indignación, furia, acusación	Insultos, denuncias, lenguaje hostil contra gobiernos, líderes, instituciones	<i>What a load of bs by the Zionist terrorists</i> <i>😡😡😡</i>  <i>It MUST be STOPPED!</i> <i>👊👊👊</i>	<i>barbaric, murderer, genocide, double standard, shame</i>
<b>Esperanza</b>	Fe, deseo de paz o solución	Frases optimistas, bendiciones, rezos, visión de un futuro mejor	<i>In sha'Allah Allah SWT will grant the FILESTEENS justice</i>  <i>Justice is coming up sooner or later 🙌🙌</i>	<i>hope, God will protect, justice will prevail, healing, peace for all</i>


Nota: Elaboración propia

### 8.6.3. Etiquetado manual y limpieza de datos

Una vez definidas las emociones a etiquetar, se procedió al etiquetado manual de la muestra recolectada de comentarios. Durante este proceso, se observó que muchos comentarios manifestaban una combinación de emociones, lo que podía dificultar su clasificación. Por esta razón, se seleccionaron únicamente aquellos comentarios que evocaran de forma explícita y dominante una sola emoción, con el objetivo de reducir ambigüedades y facilitar el aprendizaje supervisado del modelo.

El resultado fue un conjunto de 2.283 comentarios únicos, distribuidos de la siguiente manera: Ira (512), Tristeza (494), Esperanza (454), Sarcasmo (453) y Resistencia (370) (Ver Ilustración 41). La categoría de Resistencia fue la que presentó menor representatividad dentro del corpus, debido a que sus manifestaciones suelen mezclarse con otras emociones, como la ira o la esperanza. Por ello, se realizó una curaduría cuidadosa, conservando únicamente aquellos comentarios que expresaran de forma inequívoca la emoción de resistencia.

Ilustración 41. Distribución de emociones de la muestra etiquetada




Nota: Elaboración propia

Durante el proceso de etiquetado, se garantizó la limpieza del corpus mediante una revisión manual exhaustiva. Se eliminaron comentarios duplicados, mensajes con frases repetitivas, comentarios ambiguos que contenían múltiples emociones, así como aquellos que presentaban un uso excesivo de emojis o carecían de contenido semántico relevante. También se descartaron los casos en los que un mismo comentario aparecía etiquetado con emociones distintas en diferentes registros.

Además, se realizó un control de calidad sobre la longitud textual de los comentarios. Se tokenizó el corpus utilizando los autotokenizadores de los modelos Transformer a emplear (por ejemplo, RoBERTa, cuyo límite máximo es de 512 tokens). Como medida de consistencia, se estableció un umbral de corte en 256 tokens, eliminando aquellos comentarios demasiado extensos para garantizar una representación uniforme del input. La mayoría de los comentarios se encontraba muy por debajo de este umbral, con una mediana de 19 tokens y una longitud máxima observada de 338 tokens, como se muestra en la Ilustración 42.

Ilustración 42. Distribución de tokens por comentario



Nota: Elaboración propia

No se detectaron registros nulos en el texto ni en la columna de emoción, ni comentarios vacíos, duplicados o etiquetados de manera contradictoria. El conjunto final constó de 2.283 comentarios únicos, con una media de 24 tokens por comentario, sin repeticiones entre tópicos ni valores faltantes. A su vez, el análisis de las palabras más frecuentes por cada emoción con TF-IDF permitió identificar patrones léxicos diferenciables entre clases. Por ejemplo, la prominencia de términos como *terrorist*, *genocide* o *shame* en la categoría de Ira, frente a expresiones como *peace*, *hope* o *bless* en Esperanza, y *strong*, *boycot* o *free* en Resistencia.

#### **8.6.4. Modelos de clasificación emocional**

En este apartado se presentan los resultados obtenidos a partir de un primer proceso de fine-tuning aplicado a modelos de lenguaje preentrenados —RoBERTa, ELECTRA, DeBERTa y XLNet— para la tarea de clasificación emocional. El objetivo fue identificar la emoción dominante en comentarios relacionados con el conflicto palestino-israelí, utilizando el conjunto de datos curado y etiquetado manualmente, descrito en las secciones anteriores. Para ello, se entrenaron modelos basados en la arquitectura Transformer sobre un corpus balanceado de 2.283 comentarios, distribuidos en cinco emociones: Ira, Tristeza, Esperanza, Sarcasmo y Resistencia. Es importante señalar que este ejercicio tiene carácter exploratorio, y que los modelos no fueron aplicados sobre comentarios reales no etiquetados, ya que no sería éticamente adecuado generalizar a partir de un corpus reducido. El foco de este apartado está en evaluar la capacidad de los modelos para aprender a diferenciar las emociones definidas en el contexto del conflicto palestino-israelí, bajo condiciones controladas y con datos de entrenamiento cuidadosamente curados. A continuación, se reportan los resultados obtenidos en métricas estándar como precisión, recall, F1-score macro y matriz de confusión, así como un análisis comparativo del rendimiento entre los distintos modelos evaluados.

##### **8.6.4.1. Manejo del desbalance de clases**

Para garantizar una evaluación justa del desempeño del modelo en presencia de clases con diferente frecuencia, se aplicó un esquema de pesos de clase balanceados durante el entrenamiento. Estos pesos fueron calculados automáticamente a partir de la distribución del conjunto de datos utilizando la función `compute_class_weight` de la biblioteca `sklearn`. Esta técnica asigna mayor peso a aquellas clases menos representadas, lo que permite penalizar más fuertemente los errores cometidos en dichas categorías durante el entrenamiento. La asignación final de pesos por clase fue la siguiente: Esperanza: 1.01, Ira: 0.89, Resistencia: 1.23, Sarcasmo: 1.01, Tristeza: 0.92. La clase Resistencia recibió el mayor peso debido a su menor representación en el corpus, mientras que Ira y Tristeza presentaron una mayor proporción relativa de ejemplos, recibiendo un peso ligeramente menor. Este ajuste fue incorporado directamente en la función de pérdida del modelo `loss function`, con el fin de mitigar los efectos del desbalance durante el proceso de aprendizaje supervisado.

#### 8.6.4.2. Optimización de hiperparámetros con Optuna

Se aplicó una estrategia de búsqueda de hiperparámetros mediante la biblioteca Optuna, con el fin de maximizar el rendimiento de los modelos. Optuna permite realizar una optimización eficiente utilizando técnicas de búsqueda bayesiana y poda temprana de ensayos no prometedores, útil en contextos de recursos computacionales limitados. Los valores óptimos seleccionados para cada modelo, luego de 5 ensayos por modelo evaluados con base en el F1-score macro sobre el conjunto de validación, se presentan en la tabla 35:

Tabla 35. Hiperparámetros óptimos seleccionados por Optuna por modelo

Modelo	Tasa de aprendizaje	Tamaño de lote	Épocas	Regularización
RoBERTa	$1.45 \times 10^{-5}$	16	5	0.0359
ELECTRA	$2.07 \times 10^{-5}$	8	6	0.0546
DeBERTa	$1.15 \times 10^{-5}$	8	6	0.0631
XLNet	$2.48 \times 10^{-5}$	8	5	0.0358

Nota: Elaboración propia

Esta búsqueda automatizada permitió adaptar cada modelo a las particularidades del conjunto de datos, mejorando su capacidad de generalización en el marco del entrenamiento supervisado. La incorporación de regularización mediante weight decay, así como el ajuste fino de la tasa de aprendizaje y el número de épocas, contribuyeron a mitigar el sobreajuste observado en algunos ensayos preliminares.

#### 8.6.4.3. Evaluación de modelos

La Tabla 36 muestra el rendimiento comparativo de los cuatro modelos evaluados. DeBERTa fue el modelo con mejor desempeño general, obteniendo un F1 macro de 0.891, seguido de cerca por RoBERTa. ELECTRA y XLNet mostraron desempeños aceptables. Estos resultados respaldan la elección de modelos basados en arquitecturas recientes como DeBERTa para tareas de clasificación emocional en contextos de conflicto.


Tabla 36. Comparación del rendimiento de modelos de clasificación emocional

Modelo	Accuracy	F1 macro	Precisión	Recall
DeBERTa	0.895	0.891	0.894	0.890
RoBERTa	0.871	0.868	0.870	0.868
ELECTRA	0.781	0.780	0.783	0.780
XLNet	0.790	0.788	0.799	0.792

Nota: Elaboración propia

La Ilustración 43 muestra una comparación detallada del F1-score obtenido por cada modelo en la clasificación de las cinco emociones definidas. El modelo DeBERTa obtuvo los mejores resultados en todas las categorías, destacándose en Tristeza (0.94), Ira (0.91) y Esperanza (0.90), y con un rendimiento estable en Resistencia y Sarcasmo. RoBERTa se posicionó como el segundo mejor modelo, manteniendo un desempeño competitivo en casi todas las emociones, especialmente en Tristeza (0.93), donde se acerca al rendimiento de DeBERTa. ELECTRA y XLNet mostraron rendimientos inferiores, con F1-scores más bajos, particularmente en la emoción de Sarcasmo, donde ambos modelos descendieron por debajo del 0.72.

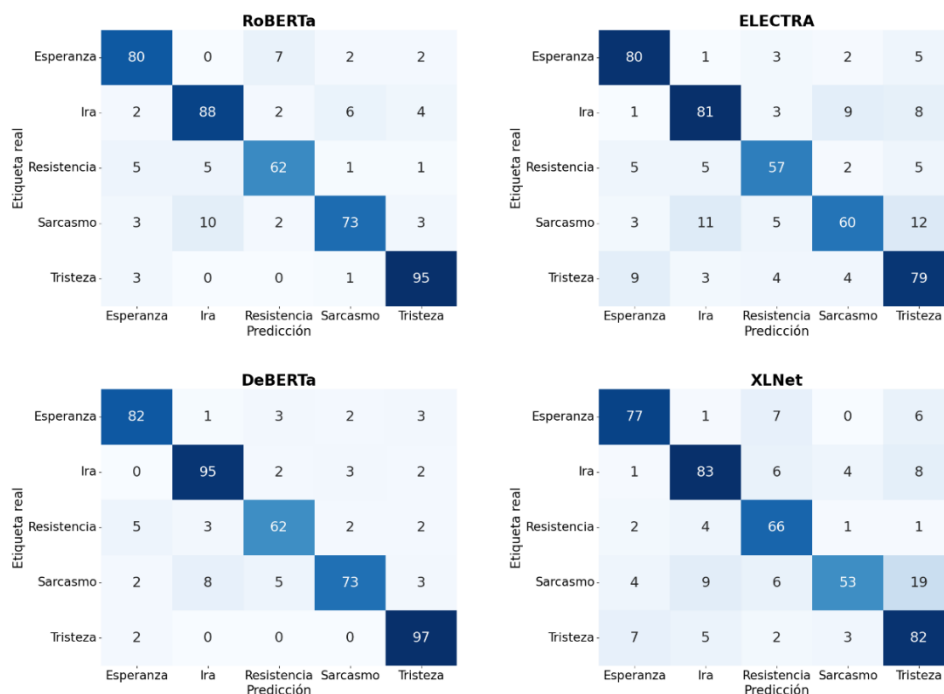
Ilustración 43. Comparación de F1-score por emoción y modelo



Nota: Elaboración propia

Los resultados demuestran que las emociones más difíciles de clasificar fueron Sarcasmo y Resistencia (ver Ilustración 44), posiblemente debido a su naturaleza discursiva ambigua o al menor número de ejemplos en el corpus. Las emociones más fáciles de identificar fueron Tristeza y Esperanza, con puntuaciones elevadas y consistentes entre modelos, lo que sugiere una mayor cohesión léxica en esos casos.


Ilustración 44. Matriz de confusión de los modelos de clasificación



Nota: Elaboración propia

A pesar de los óptimos resultados obtenidos con DeBERTa, se analizaron los resultados del mejor modelo en cada época a lo largo de los intentos realizados con OPTUNA. Se examinó el comportamiento del Validation Loss frente al F1 Macro por época para los mejores modelos (DeBERTa y RoBERTa), con el objetivo de minimizar el overfitting y evitar sesgos por exceso de generalización o memorización del modelo. La Ilustración 45 muestra el comportamiento por épocas de ambos modelos, evidenciando que la mejor época para RoBERTa fue la número 3, mientras que para DeBERTa fue la número 2.


Ilustración 45. Validation Loss vs F1 Macro



Nota: Elaboración propia

A pesar de que DeBERTa alcanzó el F1 Score más alto bajo un criterio de *early stopping*, RoBERTa mostró un mejor equilibrio entre desempeño y generalización, al registrar una menor *validation loss* con un F1 competitivo (ver Ilustración 46).

Ilustración 46. Desempeño óptimo sin overfitting por modelo



Nota: Elaboración propia

Este análisis refuerza la superioridad de modelos como DeBERTa y RoBERTa para tareas de clasificación emocional en contextos complejos, como el discurso digital asociado a conflictos geopolíticos.

## 9. Discusión

Este estudio proporciona evidencia sólida sobre las diferencias lingüísticas y narrativas en el discurso digital según la fuente emisora, en el contexto de conflictos geopolíticos complejos y sensibles como el palestino-israelí. Se confirma que la ciencia de datos y el

aprendizaje automático ofrecen herramientas prometedoras para el análisis de relaciones internacionales, especialmente ante el papel creciente de las plataformas digitales como emisoras de información y modeladoras de narrativas políticas en entornos altamente polarizados. La imposibilidad humana de analizar de forma exhaustiva corpus masivos se ve superada parcialmente gracias a los avances en procesamiento de lenguaje natural (PLN) y modelos de aprendizaje profundo. En este estudio, se aplicaron modelos *Transformer* para la clasificación emocional, revelando la presencia de emociones latentes altamente personalizadas, como la resistencia, que se manifiesta en discursos que combinan orgullo identitario con rechazo al adversario. Esta emoción, en particular, genera opiniones divididas y contribuye a la polarización discursiva en la comunidad internacional. Estas emociones pueden analizarse a la luz de la teoría de las emociones intergrupales, que sostiene que las emociones colectivas refuerzan identidades grupales, movilizan actitudes políticas y orientan conductas hacia grupos externos. La emoción de Resistencia es una emoción funcional que fortalece el sentido de pertenencia y legitima acciones de oposición frente al grupo adversario, cumpliendo un rol movilizador en contextos de confrontación. A su vez, la Tristeza expresada en narrativas con foco humanitario, evoca un reconocimiento compartido del sufrimiento y puede generar empatía intergrupal, aunque también puede reforzar sentimientos de victimización colectiva. La Esperanza emerge como una emoción más escasa pero políticamente significativa, vinculada a discursos que apuestan por la justicia, la mediación internacional o el alto al fuego. Estas emociones no solo revelan el tono afectivo de los discursos, sino que se articulan con marcos ideológicos e identitarios, como lo plantea esta teoría.

El proceso de etiquetado manual supuso un desafío considerable, dada la complejidad inherente de las emociones humanas, las cuales evocan múltiples significados simultáneos y pueden superponerse en el lenguaje. No obstante, la implementación de arquitecturas Transformer como DeBERTa, que incorpora innovaciones de ELECTRA mediante un enfoque de preentrenamiento basado en reemplazo de palabras en lugar de enmascaramiento tradicional (replaced token detection), demostró una alta capacidad para capturar matices afectivos en textos breves y ruidosos como los comentarios de YouTube. A pesar de estos logros, las limitaciones computacionales representaron un obstáculo significativo, especialmente en el ajuste fino de hiperparámetros y la evaluación masiva de modelos. Asimismo, se reconoce la existencia de sesgos potenciales durante el proceso

de anotación emocional, dada la subjetividad implicada en la interpretación del lenguaje afectivo en contextos tan cargados políticamente. En conjunto, la metodología automatizada empleada en este trabajo demuestra ser útil para el análisis de patrones discursivos y afectivos en conflictos geopolíticos, al permitir la identificación de estructuras narrativas dominantes y su relación con las emociones colectivas que circulan en plataformas digitales. Este enfoque dual, temático y emocional, aporta a la comprensión del modo en que se construyen, diseminan y polarizan las narrativas en tiempos de crisis internacional. No obstante, es importante señalar que el análisis de este tipo de contextos podría enriquecerse aún más mediante la incorporación de fuentes locales en idiomas distintos al inglés, como el árabe o el hebreo, que permitirían acceder a expresiones idiomáticas, referencias culturales y matices emocionales propios de cada comunidad. Este abordaje multilingüe ofrecería una visión más profunda y contextualizada del conflicto, especialmente al analizar cómo el lenguaje local construye significados, identidades y posicionamientos frente a los eventos que atraviesan las distintas poblaciones involucradas.

## **10. Conclusiones y Trabajo Futuro**

### **10.1. Conclusiones**

La revisión de la literatura reveló el creciente interés del uso de modelos de aprendizaje profundo y la implementación de técnicas de procesamiento de lenguaje natural en el análisis de fenómenos sociales y políticos. La literatura evidenció la existencia de estudios aplicados a conflictos políticos, campañas electorales y desinformación, sin embargo, el enfoque aplicado al análisis de emociones y tópicos en plataformas digitales como YouTube es aún poco explorado. Crecientes investigación documentan enfoques metodológicos pertinentes mediante embeddings, modelamiento de tópicos y clasificación emocional como técnicas clave para abordar grandes volúmenes de datos en contextos geopolíticos digitales.

Se logró diseñar e implementar exitosamente un pipeline automatizado que permitió la recolección, filtrado y limpieza de datos provenientes de canales de noticias en YouTube relacionados con el conflicto palestino-israelí. El sistema aseguró la obtención de datos representativos y actuales del periodo comprendido entre octubre de 2023 y marzo de

2025, lo que permitió garantizar trazabilidad, diversidad temática y lingüística, sentando una base sólida para análisis posteriores.

La aplicación de técnicas de procesamiento de lenguaje natural, como la generación de embeddings semánticos y la reducción dimensional con UMAP, junto con el modelamiento de tópicos mediante K-Means, permitió identificar estructuras discursivas diferenciadas entre canales según su origen geopolítico. Asimismo, el fine-tuning de modelos Transformer para clasificación emocional demostró la presencia de emociones altamente contextualizadas, como resistencia, ira y esperanza, lo que revela la carga afectiva del discurso en este tipo de conflictos. Esto confirma la utilidad del enfoque computacional para representar y analizar dinámicas narrativas y afectivas en entornos digitales. La interpretación de los resultados dentro del marco del conflicto permitió identificar diferencias notables en las narrativas según la fuente emisora, aportando evidencia empírica al análisis del discurso digital en contextos geopolíticos.

Los modelos implementados fueron evaluados mediante métricas pertinentes como el F1 macro y la matriz de confusión, permitiendo comparar el rendimiento de diferentes arquitecturas basadas en *Transformers* (RoBERTa, DeBERTa, ELECTRA, XLNet). DeBERTa presentó el mejor desempeño general para la clasificación emocional, gracias a su arquitectura mejorada que le permite capturar con mayor precisión las relaciones semánticas en el texto, demostrando ser un modelo altamente efectivo en un corpus multitemático y emocionalmente complejo como los comentarios sobre el conflicto palestino-israelí. Pese a las limitaciones computacionales, DeBERTa demostró una capacidad notable para distinguir matices afectivos, incluso en textos breves y cargados de ambigüedad emocional.

## **10.2. Trabajo futuro**

Las limitaciones de la presente investigación sientan las bases a estudios de investigación futuros. En primer lugar, si bien se entrenaron modelos para clasificación emocional, el tamaño y balance del conjunto de datos restringieron la capacidad del modelo para generalizar adecuadamente. Una línea de mejora sería el fine-tuning multiclase con un volumen mayor de ejemplos etiquetados manualmente, lo cual permitiría capturar con mayor precisión la complejidad semántica y afectiva del discurso en contextos

de conflicto. La investigación evidenció que en estos contextos la carga emocional en los comentarios es multiclase.

Otra proyección importante es la incorporación del análisis multimodal. Este estudio se centró exclusivamente en el contenido textual, pero las narrativas digitales contemporáneas también se expresan a través de elementos visuales y auditivos. Integrar el análisis del video como objeto completo, incluyendo imagen, voz, música y montaje, mediante modelos multimodales, permitiría comprender más profundamente cómo se construyen las narrativas en plataformas como YouTube.

A su vez, este trabajo de investigación se limitó al idioma inglés. Futuras investigaciones podrían beneficiarse de la integración de otros idiomas clave, como el árabe o el hebreo, cuya ampliación multilingüe enriquecería el análisis y haría más robusta la interpretación al capturar expresiones lingüísticas locales, referencias culturales específicas y emociones propias del discurso en contextos regionales.

En cuanto a la infraestructura técnica, las limitaciones computacionales representaron un desafío para la experimentación más profunda. El uso de GPUs dedicadas en entornos como Google Cloud o AWS abriría la posibilidad de realizar entrenamientos más extensos, explorar arquitecturas más sofisticadas y optimizar hiperparámetros con mayor libertad, elevando la calidad del modelo final.

Trabajos futuros podrían también ampliar la muestra de canales informativos analizados, incluyendo una variedad más amplia de medios, tanto institucionales como alternativos, regionales e internacionales, aprovechando la capacidad de las ciencias de datos y permitiendo comparar cómo se construyen las narrativas según factores como el país de origen, la línea editorial o la ideología política del canal y contrastando discursos dominantes entre canales.

Otra línea de investigación futura podría centrarse en el análisis del discurso a lo largo del tiempo, analizando no solo un periodo concreto, sino estudiando cómo evolucionan los tópicos y emociones a lo largo del tiempo, en función de eventos clave o transiciones políticas, identificando patrones narrativos cíclicos o reconfiguraciones discursivas a lo largo del conflicto. En esta línea temporal, sería especialmente pertinente explorar la evolución de la intensidad emocional dentro de un mismo tópico, para detectar si eventos clave como resoluciones de la ONU, escaladas militares o intervenciones diplomáticas

modifican la carga afectiva de una narrativa particular. Esta perspectiva permitiría mapear no solo qué emociones dominan, sino cuándo y por qué se intensifican.

De igual forma, sería pertinente extender este análisis a otras plataformas digitales como Twitter (X), TikTok o Facebook, para comparar cómo varía el discurso según el formato, el tipo de interacción y el perfil de usuario. Este enfoque comparativo entre plataformas revelaría cómo se moldean las emociones y las narrativas en función del medio digital específico.

#### **Declaración de uso de herramientas de IA**

Durante la elaboración de este trabajo, se utilizó la herramienta ChatGPT-4-turbo exclusivamente con el propósito de mejorar la redacción y el estilo del texto. El contenido, los análisis, los resultados y las conclusiones aquí presentados son de completa autoría de la estudiante.

## 11. Referencias

- Akiba, T., Sano, S., Yanase, T., Ohta, T., & Koyama, M. (2019). Optuna: A next-generation hyperparameter optimization framework. In *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining* (pp. 2623–2631). ACM. <https://doi.org/10.1145/3292500.3330701>
- Al Agha, I. M., & Abu Dahrooj, O. (2019). Multi-level analysis of political sentiments using Twitter data: A case study of the Palestinian–Israeli conflict. *Jordanian Journal of Computers and Information Technology*, 5(3), 195–215. <https://doi.org/10.5455/jicit.71-1562700251>
- Albanese, F., Pinto, S., Semeshenko, V., & Balenzuela, P. (2020). Analyzing mass media influence using natural language processing and time series analysis [Preprint]. *arXiv*. <https://doi.org/10.48550/arXiv.1909.08095>
- Ali, A., Khan, M., & Riaz, M. (2024). Examining the framing of the Israel-Palestine conflict: A textual analysis of international media news coverage. *Migration Letters*, 21(S11), 1212–1223. <https://migrationletters.com/index.php/ml/article/view/10899>
- Al-Sarraj, W. F., & Lubbad, H. M. (2018). Bias detection of Palestinian/Israeli conflict in Western media: A sentiment analysis experimental study. In *2018 International Conference on Promising Electronic Technologies (ICPET)* (pp. 13–18). IEEE. <https://doi.org/10.1109/ICPET.2018.00024>
- Alshahrani, A., Ghaffari, M., Amirizirtol, K., & Liu, X. (2020). Identifying optimism and pessimism in Twitter messages using XLNet and deep consensus. In *2020 International Joint Conference on Neural Networks (IJCNN)* (pp. 1–8). IEEE. <https://doi.org/10.1109/IJCNN48605.2020.9206948>
- Amure, R., & Agarwal, N. (2025). Modeling cross-platform narrative templates: A temporal knowledge graph approach. *Social Network Analysis and Mining*, 15, Article 42. <https://doi.org/10.1007/s13278-025-01429-8>
- Antonakaki, D., & Ioannidis, S. (2025). Israel-Hamas war through Telegram, Reddit and Twitter [Preprint]. *arXiv*. <https://doi.org/10.48550/arXiv.2502.00060>
- Badieah, C. H. S. F., Mulyono, S., Salim, C. A., Adli, M. F., Febriansah, M. T., Wiktasari, S., Sulaiman, N. S., & Yaqob, A. (2024). Leveraging transformer-based topic modeling using BERTopic for publication venue recommendation. In *2024 International Conference*

on *Electrical Engineering, Computer Science and Informatics (EECSI)* (pp. 556–562). IEEE. <https://doi.org/10.1109/EECSI63442.2024.10776045>

Beinin, J., & Hajjar, L. (2014). *Palestine, Israel and the Arab–Israeli Conflict: A Primer*. Middle East Research and Information Project. <https://merip.org/palestine-israel-primer/>

Belcastro, L., Cantini, R., Marozzo, F., Talia, D., & Trunfio, P. (2020). Learning political polarization on social media using neural networks. *IEEE Access*, 8, 47177–47187. <https://doi.org/10.1109/ACCESS.2020.2978950>

Biswas, S., Wardat, M., & Rajan, H. (2022). The art and practice of data science pipelines: A comprehensive study of data science pipelines in theory, in-the-small, and in-the-large. In *Proceedings of the 44th International Conference on Software Engineering (ICSE 2022)* (pp. 2091–2103). ACM. <https://doi.org/10.1145/3510003.3510057>

Borah, D., Ara Begum, Y., Bajpai, A., & Choudhury, R. (2022). The impact of social media on political discourse: A multidisciplinary analysis. *Migration Letters*, 19(S2), 1518–1528. Retrieved from <https://migrationletters.com/index.php/ml/article/view/10374>

Cao, M. (2024). Social media attention to geopolitical conflicts: An analysis of Weibo users' comments on the Israeli–Palestinian conflict. *Lecture Notes in Education Psychology and Public Media*, 58(1), 217–223. <https://doi.org/10.54254/2753-7048/58/20241760>

Celik, A., Boz, N., & El-awaisi, K. (2024). The Role of X “Twitter” in the Palestinian-Israeli Conflict: A Focus on MFA’s Official Accounts. *Ulisa: Journal of International Studies*, 8(1), 1–13. <https://dergipark.org.tr/en/pub/ulisa/issue/85839/1497820>

Chalkias, I., Tzafilkou, K., Karapiperis, D., & Tjortjis, C. (2023). Learning analytics on YouTube educational videos: Exploring sentiment analysis methods and topic clustering. *Electronics*, 12(18), 3949. <https://doi.org/10.3390/electronics12183949>

Clark, K., Luong, M.-T., Le, Q. V., & Manning, C. D. (2020). ELECTRA: Pre-training text encoders as discriminators rather than generators [Paper presentation]. In *International Conference on Learning Representations (ICLR) 2020*. arXiv. <https://doi.org/10.48550/arXiv.2003.10555>

Cortiz, D. (2021). Exploring transformers in emotion recognition: A comparison of BERT, DistilBERT, RoBERTa, XLNet and ELECTRA [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2104.02041>

De Faveri, F. L., Cosuti, L., Tricomi, P. P., & Conti, M. (2023). Twitter bots influence on the Russo-Ukrainian War during the 2022 Italian general elections. In *Security and privacy*

*in social networks and big data (Lecture Notes in Computer Science, Vol. 14097, pp. 38–57)*. Springer. [https://doi.org/10.1007/978-981-99-5177-2\\_3](https://doi.org/10.1007/978-981-99-5177-2_3)

Dean, M. C., & Porter, B. (2024). Sentiment analysis of Russian-language social media posts discussing the 2022 Russian invasion of Ukraine. *Armed Forces & Society*. <https://doi.org/10.1177/0095327X241235987>

Deubel, A., Breuer, J., Kohne, J., & Mohseni, M. R. (2024). Overview of working with data from YouTube (GESIS Guides to Digital Behavioral Data No. 12). GESIS–Leibniz Institute for the Social Sciences. <https://doi.org/10.60762/ggdbd24012.1.0>

Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2018). BERT: Pre-training of deep bidirectional transformers for language understanding [Preprint]. *arXiv*. <https://doi.org/10.48550/arXiv.1810.04805>

Ethayarajh, K. (2019). How contextual are contextualized word representations? Comparing the geometry of BERT, ELMo, and GPT-2 embeddings [Conference paper]. In *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)* (pp. 55–65). Association for Computational Linguistics. <https://doi.org/10.18653/v1/D19-1006>

Fagni, T., & Cresci, S. (2022). Fine-grained prediction of political leaning on social media with unsupervised deep learning. *Journal of Artificial Intelligence Research, 73*, 633–672. <https://doi.org/10.1613/JAIR.1.13112>

Fan, M.-H., Liao, E.-C., & Chen, M.-Y. (2014). A TAIEX forecasting model based on changes of keyword search volume on Google Trends. In *2014 IEEE International Symposium on Independent Computing (ISIC 2014)* (pp. 96–99). IEEE. <https://doi.org/10.1109/INDCOMP.2014.7011756>

Filip, T., Pavlíček, M., & Sosík, P. (2024). Fine-tuning multilingual language models in Twitter/X sentiment analysis: A study on Eastern-European V4 languages [Preprint]. *arXiv*. <https://doi.org/10.48550/arXiv.2408.02044>

Foidl, H., Golendukhina, V., Ramler, R., & Felderer, M. (2023). Data pipeline quality: Influencing factors, root causes of data-related issues, and processing problem areas for developers [Preprint]. *arXiv*. <https://doi.org/10.48550/arXiv.2309.07067>

Galke, L., Scherp, A., Diera, A., Karl, F., Lin, B. X., Khera, B., Meuser, T., & Singhal, T. (2022). Are we really making much progress in text classification? A comparative review [Preprint]. *arXiv*. <https://doi.org/10.48550/arXiv.2204.03954>

Georgiev, A., Valkanov, V., & Georgiev, P. (2024, October). A comparative analysis of Jenkins as a data pipeline tool in relation to dedicated data pipeline frameworks. In *2024 International Conference on Automatics and Informatics (ICAI)* (pp. 508–512). IEEE. <https://doi.org/10.1109/ICAI63388.2024.10851591>

Gu, M.-H., Kwon, J., Jeong, J. P., & Kwon, S. (2022). An emotion classification scheme for English text using natural language processing. In *2022 13th International Conference on Information and Communication Technology Convergence (ICTC)* (pp. 1941–1946). IEEE. <https://doi.org/10.1109/ICTC55196.2022.9952880>

Hashemi, M. (2023). Geographical visualization of tweets, misinformation, and extremism during the USA 2020 presidential election using LSTM, NLP, and GIS. *Journal of Big Data*, 10, Article 125. <https://doi.org/10.1186/s40537-023-00797-2>

He, P., Gao, J., & Chen, W. (2021). DeBERTaV3: Improving DeBERTa using ELECTRA-style pre-training with gradient-disentangled embedding sharing (Tech. Rep.). *arXiv*. <https://doi.org/10.48550/arXiv.2111.09543>

He, P., Liu, X., Gao, J., & Chen, W. (2020). DeBERTa: Decoding-enhanced BERT with disentangled attention. *arXiv*. <https://arxiv.org/abs/2006.03654>

Ho, Y., & Wookey, S. (2020). The real-world-weight cross-entropy loss function: Modeling the costs of mislabeling. *IEEE Access*, 8, 4806–4813. <https://doi.org/10.1109/ACCESS.2019.2962617>

Hofmann, V., Dong, X., Pierrehumbert, J. B., & Schütze, H. (2022). Modeling ideological salience and framing in polarized online groups with graph neural networks and structured sparsity. In *Findings of the Association for Computational Linguistics: NAACL 2022* (pp. 536–550). Association for Computational Linguistics. <https://doi.org/10.18653/v1/2022.findings-naacl.41>

Howard, J., & Ruder, S. (2018). Universal language model fine-tuning for text classification [Preprint]. *arXiv*. <https://arxiv.org/abs/1801.06146>

Hu, Y., Hosseini, M. S., Parolin, E. S., Osorio, J., Khan, L., Brandt, P. T., & D’Orazio, V. J. (2022). ConflIBERT: A pre-trained language model for political conflict and violence. In *Proceedings of the 2022 Conference of the North American Chapter of the Association*

for *Computational Linguistics: Human Language Technologies* (pp. 5469–5482). Association for Computational Linguistics. <https://doi.org/10.18653/v1/2022.naacl-main.400>

Humayoun, M., & Akhtar, N. (2022). CORPURES: Benchmark corpus for Urdu extractive summaries and experiments using supervised learning. *Intelligent Systems with Applications*, 16, Article 200129. <https://doi.org/10.1016/j.iswa.2022.200129>

Hutchison, E., & Bleiker, R. (2014). Theorizing emotions in world politics. *International Theory*, 6(3), 491–514. <https://doi.org/10.1017/S1752971914000232>

Imtiaz, R., Ali, A., & Bashir, M. (2024). Analyzing Public Sentiment: A Deep Dive into Twitter Discourse on the 2022 No Confidence Motion in Pakistan. En *Proceedings of the 2024 5th International Conference on Advancements in Computational Sciences (ICACS)* (pp. 1–6). IEEE. <https://doi.org/10.1109/ICACS60934.2024.10473299>

Instituto de Ingeniería del Conocimiento (IIC). (2021). *La metodología CRISP-DM en ciencia de datos*. <https://www.iic.uam.es/innovacion/metodologia-crisp-dm-ciencia-de-datos/>

Jackson, A. (2019, May 10). The mathematics of UMAP [Technical report]. Recuperado de [https://adelejackson.com/files/Maths\\_of\\_UMAP.pdf](https://adelejackson.com/files/Maths_of_UMAP.pdf)

Januzaj, Y., Beqiri, E., & Luma, A. (2023). Determining the optimal number of clusters using Silhouette Score as a data mining technique. *International Journal of Online and Biomedical Engineering*, 19(4), 174–182. <https://doi.org/10.3991/ijoe.v19i04.37059>

Kaiser, J., Vaccari, C., & Chadwick, A. (2022). Partisan blocking: Biased responses to shared misinformation contribute to network polarization on social media. *Journal of Communication*, 72(2), 214–240. <https://doi.org/10.1093/joc/jqac002>

Khalidi, R. (2020). *The hundred years' war on Palestine: A history of settler colonialism and resistance, 1917–2017*. Metropolitan Books.

Khurana, N., & Prabhu, V. (2024). Sentiment analysis using transformer models (BERT, ALBERT, RoBERTa, and DeBERTa) on a SMILE Twitter dataset. En *2024 International Conference on Innovation and Novelty in Engineering and Technology (INNOVA 2024 – Proceedings)*. Institute of Electrical and Electronics Engineers (IEEE). <https://doi.org/10.1109/INNOVA63080.2024.10847030>

Krell, M. M., Kosec, M., Perez, S. P., & Fitzgibbon, A. (2021). Efficient sequence packing without cross-contamination: Accelerating large language models without impacting performance [Preprint]. *arXiv*. <https://arxiv.org/abs/2107.02027>

Kubin, E., & von Sikorski, C. (2021). The role of (social) media in political polarization: A systematic review. *Annals of the International Communication Association*, 45(3), 188–206. <https://doi.org/10.1080/23808985.2021.1976070>

Kumar, M., Khan, L., & Chang, H. T. (2025). Evolving techniques in sentiment analysis: A comprehensive review. *PeerJ Computer Science*, 11, e2592. <https://doi.org/10.7717/PEERJ-CS.2592>

Kumar, V., & Baghel, A. S. (2025). BERTopic: a model to solve cold start problem in software bug recommendation system. *International Journal of Information Technology*, 17, 3125–3130. <https://doi.org/10.1007/s41870-025-02470-8>

Ledwich, M., & Zaitsev, A. (2019). Algorithmic extremism: Examining YouTube's rabbit hole of radicalization [Preprint]. *arXiv*. <https://doi.org/10.48550/arXiv.1912.11211>

Li, H. O. Y., Bailey, A., Huynh, D., & Chan, J. (2020). YouTube as a source of information on COVID-19: A pandemic of misinformation? *BMJ Global Health*, 5(5), e002604. <https://doi.org/10.1136/bmjgh-2020-002604>

Liang, T., Mu, Y., Kim, S., Kuate, D. L. K., Lang, J., Vos, R., & Song, X. (2023). Classification-Aware Neural Topic Model Combined With Interpretable Analysis – For Conflict Classification [Preprint]. *arXiv*. <https://doi.org/10.48550/arXiv.2308.15232>

Liu, Y., Ott, M., Goyal, N., Du, J., Joshi, M., Chen, D., Levy, O., Lewis, M., Zettlemoyer, L., & Stoyanov, V. (2019). RoBERTa: A robustly optimized BERT pretraining approach [Preprint]. *arXiv*. <https://doi.org/10.48550/arXiv.1907.11692>

Lotfi, C., Srinivasan, S., Ertz, M., & Latrous, I. (2022). Web scraping techniques and applications: A literature review. En *SCRS Conference Proceedings on Intelligent Systems* (pp. 381–394). Soft Computing Research Society. <https://doi.org/10.52458/978-93-91842-08-6-38>

Lucić, D., Katalinić, J., & Dokman, T. (2020). Sentiment analysis of the Syrian conflict on Twitter. *Medijske studije*, 11(22), 46–61. <https://doi.org/10.20901/ms.11.22.3>

Ma, L., Chen, R., Ge, W., Rogers, P., Lyn-Cook, B., Hong, H., Tong, W., Wu, N., & Zou, W. (2025). AI-powered topic modeling: Comparing LDA and BERTopic in analyzing

opioid-related cardiovascular risks in women. *Experimental Biology and Medicine*, 250, Article 10389. <https://doi.org/10.3389/ebm.2025.10389>

Hernández López, V. M., & Cuellar, J. E. (2025). Mapping controversies using artificial intelligence: An analysis of the Hamas–Israel conflict on YouTube [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2504.12177>

Mao, Y., Liu, Q., & Zhang, Y. (2024). Sentiment analysis methods, applications, and challenges: A systematic literature review. *Journal of King Saud University – Computer and Information Sciences*, 36(4), Article 102048. <https://doi.org/10.1016/j.jksuci.2024.102048>

Markham, A., & Buchanan, E. (2012). Ethical decision-making and Internet research: Recommendations from the AoIR Ethics Working Committee (Version 2.0) [Informe técnico]. Association of Internet Researchers. <http://www.aoir.org/reports/ethics2.pdf>

Mersha, M. A., Yigezu, M. G., & Kalita, J. (2024). Semantic-driven topic modeling using transformer-based embeddings and clustering algorithms [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2410.00134>

Mohammad, S. M. (2016). Sentiment analysis: Automatically detecting valence, emotions, and other affectual states from text. En *Emotion Measurement* (pp. 201–237). Elsevier. <https://doi.org/10.1016/B978-0-12-821124-3.00011-9>

Mohammadi, H. A., Momand, Z., Habibi, P., Ramaki, N., Fazli, B. S., Rohany, S. Z., & Samsoor, I. (2023). Analyzing textual data for fatality classification in Afghanistan's armed conflicts: A BERT approach [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2310.08653>

Muhammad, A. N., Bukhori, S., & Pandunata, P. (2019). Sentiment analysis of positive and negative YouTube comments using Naïve Bayes–Support Vector Machine (NBSVM) classifier [Conference paper]. En *Proceedings of the 2019 International Conference on Computer Science, Information Technology, and Electrical Engineering (ICOMITEE)*. <https://doi.org/10.1109/ICOMITEE.2019.8920923>

Mustofa, B. A., Laksito, W., & Saptomo, Y. (2025). Use of Natural Language Processing in Social Media Text Analysis. *Journal of Artificial Intelligence and Engineering Applications*, 4(2), 1235–1238. <https://doi.org/10.59934/jaiea.v4i2.875>

Naseem, U., Razzak, I., Eklund, P., & Musial, K. (2020). T-DICE: Irony and sarcasm identification using a Transformer-based deep intelligent contextual embedding with attention-based BiLSTM [Conference paper]. *2020 International Joint Conference on Neural Networks (IJCNN)*. <https://www.researchgate.net/publication/343389949>

Nasereddin, S. (2024). Impact of social media platforms on international public opinion during the Israel war on Gaza. *Global Change, Peace & Security*, 35(1), 5–31. <https://doi.org/10.1080/14781158.2024.2415908>

Navarro, E., & Homayouni, H. (2023). Topic modeling in cardiovascular research publications [Conference paper]. *Proceedings of the 2023 KDD Conference*. Association for Computing Machinery. <https://kdd.org/kdd2023/wp-content/uploads/2023/08/navarro2023topic.pdf>

Oguejiofor, P. O. (2024). The role of social media in shaping narratives and perceptions in the Israeli-Gaza conflict that escalated in October 2023. *International Journal of Academic Multidisciplinary Research (IJAMR)*, 8(4), 74–82. <https://ijeais.org/wp-content/uploads/2024/4/IJAMR240417.pdf>

Ong, S. W. (2025). Framing the Xi–Biden meeting in news coverage: A cross-national comparative analysis. *Global Media and China*. Advance online publication. <https://doi.org/10.1177/20594364251316958>

Oyewola, D. O., Oladimeji, L. A., Julius, S. O., Kachalla, L. B., & Dada, E. G. (2023). Optimizing sentiment analysis of Nigerian 2023 presidential election using two-stage residual long short term memory. *Heliyon*, 9(4), e14836. <https://doi.org/10.1016/j.heliyon.2023.e14836>

Patil, R., Boit, S., Gudivada, V., & Nandigam, J. (2023). A survey of text representation and embedding techniques in NLP. *IEEE Access*, 11, 36120–36146. <https://doi.org/10.1109/ACCESS.2023.3266377>

Patkar, A., Chandrashekhar, S., Mohan, R., & Kadiyala, R. (2023). AdityaPatkar at WASSA 2023 Empathy, Emotion, and Personality Shared Task: RoBERTa-Based Emotion Classification of Essays, Improving Performance on Imbalanced Data. En *Proceedings of the 13th Workshop on Computational Approaches to Subjectivity, Sentiment, & Social Media Analysis* (pp. 531–535). Association for Computational Linguistics. <https://doi.org/10.18653/v1/2023.wassa-1.46>

Petridis, C. (2024). Text classification: Neural networks vs. machine learning models vs. pre-trained models [Preprint]. *arXiv*. <https://doi.org/10.48550/arXiv.2412.21022>

Philo, G., & Berry, M. (2004). *Bad News from Israel*. Pluto Press. <http://www.researchgate.net/publication/45243578>

Plutchik, R. (1980). A general psychoevolutionary theory of emotion. In R. Plutchik & H. Kellerman (Eds.), *Emotion: Theory, research, and experience* (Vol. 1, pp. 3–33). Academic Press

Pöhlmann, G., Ma, C., Suter, V., Meckel, M., & Steinacker, L. (2025). Decoding policy narratives: A topic modeling approach to national quantum technology strategies [Conference paper]. *Proceedings of the Hawaii International Conference on System Sciences (HICSS)*. <https://doi.org/10.24251/HICSS.2025.235>

Rainio, O., Teuvo, J., & Klén, R. (2024). Evaluation metrics and statistical tests for machine learning. *Scientific Reports*, 14, Article 6086. <https://doi.org/10.1038/s41598-024-56706-x>

Raj, A., Bosch, J., Olsson, H. H., & Wang, T. J. (2020). Modelling Data Pipelines. En *Proceedings of the 2020 46th Euromicro Conference on Software Engineering and Advanced Applications (SEAA)* (pp. 13–20). IEEE. <https://doi.org/10.1109/SEAA51224.2020.00014>

Ramos, L., & Chang, O. (2023). Sentiment Analysis of Russia-Ukraine Conflict Tweets Using RoBERTa. *Uniciencia*, 37(1), 421–431. <https://doi.org/10.15359/ru.37-1.23>

Rheindorf, M., & Wodak, R. E. (2018). Borders, fences, and limits—Protecting Austria from refugees: Metadiscursive negotiation of meaning in the current refugee crisis. *Journal of Immigrant and Refugee Studies*, 16(1–2), 15–38. <https://doi.org/10.1080/15562948.2017.1302032>

Romero-Rodríguez, L. M., Tejedor, S., & Montealegre, M. V. P. (2021). Actitudes populistas y percepciones de la opinión pública y los medios de comunicación: Estudio correlacional comparado entre España y Colombia. *Revista Latina de Comunicación Social*, (79), 43–66. <https://doi.org/10.4185/RLCS-2021-1507>

Salgado Reyes, N., & Trujillo Moreno, G. E. (2024). Sentiment analysis in social network data: Application of natural language processing and machine learning techniques to analyze opinions and feelings in social network data in the context of information systems. *Dominio de las Ciencias*, 10(1), 314–327. <https://doi.org/10.23857/dc.v10i1.3714>

Sasley, B. E. (2011). Theorizing states' emotions. *International Studies Review*, 13(3), 452–476. <https://doi.org/10.1111/j.1468-2486.2011.01049.x>

Saxena, A., Prasad, M., Gupta, A., Bharill, N., Patel, O. P., Tiwari, A., Er, M. J., Ding, W., & Lin, C.-T. (2017). A review of clustering techniques and developments. *Neurocomputing*, 267, 664–681. <https://doi.org/10.1016/j.neucom.2017.06.053>

Schröer, C., Kruse, F., & Gómez, J. M. (2021). A systematic literature review on applying CRISP-DM process model. *Procedia Computer Science*, 181, 526–534. <https://doi.org/10.1016/j.procs.2021.01.199>

Sharifani, K., & Amini, M. (2023). Machine learning and deep learning: A review of methods and applications. *World Information Technology and Engineering Journal*, 10(7), 3897–3904. SSRN. <https://ssrn.com/abstract=4458723>

Shinde, P. P., & Shah, S. (2018). A review of machine learning and deep learning applications. En *Proceedings of the 2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)* (pp. 1–6). IEEE. <https://doi.org/10.1109/ICCUBEA.2018.8697857>

Singh, L., Kamboj, S., Kaur, T., Tamanna, & Singh, P. (2024). Exploring changes in public opinion, political campaigns, and political behavior through data science and machine learning. En *Proceedings of the 2nd International Conference on Artificial Intelligence and Machine Learning Applications: Healthcare and Internet of Things (AIMLA 2024)*. IEEE. <https://doi.org/10.1109/AIMLA59606.2024.10531470>

Singha, A. K., Paul, A., Sonti, S., Guntur, K., Chiranjeevi, M., & Dhuli, S. (2024). BERT-based detection of fake Twitter profiles: A case study on the Israel-Palestine war. En *Proceedings of the 15th International Conference on Computing Communication and Networking Technologies (ICCCNT 2024)* (pp. 1–6). IEEE. <https://doi.org/10.1109/ICCCNT61001.2024.10724386>

Sinha, A., Rout, B., Mohanty, S., Mishra, S. R., Mohapatra, H., & Dey, S. (2024). Exploring sentiments in the Russia-Ukraine conflict: A comparative analysis of KNN, decision tree and logistic regression machine learning classifiers. *Procedia Computer Science*, 235, 1068–1076. <https://doi.org/10.1016/j.procs.2024.04.101>

Supriyono, Wibawa, A. P., Suyono, & Kurniawan, F. (2024). Advancements in natural language processing: Implications, challenges, and future directions. *Telematics and Informatics Reports*, 16, Article 100173. <https://doi.org/10.1016/j.teler.2024.100173>

Takenaka, Y. (2025). Performance evaluation of emotion classification in Japanese using RoBERTa and DeBERTa [Preprint]. *arXiv*. <https://doi.org/10.48550/arXiv.2505.00013>

Trezza, D. (2023). To scrape or not to scrape, this is dilemma: The post-API scenario and implications on digital research. *Frontiers in Sociology*, 8, Article 1145038. <https://doi.org/10.3389/fsoc.2023.1145038>

Tsiourlini, M., Tzafilkou, K., Karapiperis, D., & Tjortjis, C. (2024). Text Analytics on YouTube Comments for Food Products. *Information*, 15(10), 599. <https://doi.org/10.3390/info15100599>

Tsz, R., Lo, W., He, B., & Ounis, I. (2005). Automatically Building a Stopword List for an Information Retrieval System. [Manuscrito no publicado]. Department of Computing Science, University of Glasgow. [https://terrierteam.dcs.gla.ac.uk/publications/rtlo\\_DIRpaper.pdf](https://terrierteam.dcs.gla.ac.uk/publications/rtlo_DIRpaper.pdf)

Ulloa, D. S. (2023). A process for topic modelling via word embeddings [Preprint]. *arXiv*. <https://arxiv.org/abs/2312.03705>

Ünver, H. A. (2019). *Computational international relations: What can programming, coding and internet research do for the discipline? All Azimuth: A Journal of Foreign Policy and Peace*, 8(2), 157–182. <https://doi.org/10.20991/allazimuth.476433>

Van Dijk, T. A. (1999). *El análisis crítico del discurso*. *Anthropos (Barcelona)*, 186, 23–36. <http://pdfs.semanticscholar.org/f8e1/1e8fe6e078174cbfe9b4f17965d08babf5bf.pdf>

Van Niekerk, B., & Maharaj, M. (2013). Social media and information conflict. *International Journal of Communication*, 7, 1162–1184. <https://ijoc.org/index.php/ijoc/article/view/1658/919>

Vargas-Calderón, V., Parra-A., N., Camargo, J. E., & Vinck-Posada, H. (2019). Event detection in Colombian security Twitter news using fine-grained latent topic analysis [Preprint]. *arXiv*. <https://arxiv.org/abs/1911.08370>

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). *Attention is all you need* [Conference paper]. En *Advances in Neural Information Processing Systems*, 30, 5998–6008. <https://arxiv.org/abs/1706.03762>

Voytek, B. (2017). Social media, open science, and data science are inextricably linked. *Neuron*, 96(6), 1219–1222. <https://doi.org/10.1016/j.neuron.2017.11.015>

Wallace, E., Gardner, M., & Singh, S. (2020). Interpreting predictions of NLP models. En *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing: Tutorial Abstracts* (pp.20–23). Association for Computational Linguistics. <https://doi.org/10.18653/v1/2020.emnlp-tutorials.3>

Waluyohadi, & Łopatka, A. (2022). 90 days to achieve monetization: Implementing design thinking in a YouTube channel. *Procedia Computer Science*, 207, 4207–4216. <https://doi.org/10.1016/j.procs.2022.09.484>

Wang, L., Yang, N., Huang, X., Jiao, B., Yang, L., Jiang, D., Majumder, R., & Wei, F. (2022). *Text embeddings by weakly-supervised contrastive pre-training* [Preprint]. *arXiv*. <https://doi.org/10.48550/arXiv.2212.03533>

Wilkerson, J., & Casas, A. (2017). *Large-Scale Computerized Text Analysis in Political Science: Opportunities and Challenges*. *Annual Review of Political Science*, 20, 529–544. <https://doi.org/10.1146/annurev-polisci-052615-025542>

Yadav, A. K., Gupta, T., Kumar, M., & Yadav, D. (2025). A hybrid model integrating LDA, BERT, and clustering for enhanced topic modeling. *Quality & Quantity*. Advance online publication. <https://doi.org/10.1007/s11135-025-02077-y>

Yang, W., Alsarra, S., Abdeljaber, L., Zawad, N., Delaram, Z., Osorio, J., Khan, L., Brandt, P. T., & D'Orazio, V. (2023). *ConflIBERT-Spanish: A pre-trained Spanish language model for political conflict and violence*. En *Proceedings of the 2023 7th IEEE Congress on Information Science and Technology (CIST)* (pp.287–292). IEEE. <https://doi.org/10.1109/CiSt56084.2023.10409883>

Yang, Z., Dai, Z., Yang, Y., Carbonell, J., Salakhutdinov, R., & Le, Q. V. (2019). XLNet: Generalized autoregressive pretraining for language understanding [Conference paper]. En *Advances in Neural Information Processing Systems*, 32, 5754–5764. <https://doi.org/10.48550/arXiv.1906.08237>

You, S. D., Hsiao, P. Y., & Tsai, S. (2023). *Reinforcement learning for stock price trading with keywords in Google Trends*. En *Proceedings of the 2023 9th International Conference on Applied System Innovation (ICASI 2023)* (pp.109–111). IEEE. <https://doi.org/10.1109/ICASI57738.2023.10179534>

Zeitsoff, T. A. (2017). *How social media is changing conflict*. *Journal of Conflict Resolution*, 61(9), 1970–1991. <https://doi.org/10.1177/0022002717721392>

Zogan, H., Razzak, I., Jameel, S., & Xu, G. (2024). NarrationDep: Narratives on social media for automatic depression detection [Preprint]. *arXiv*. <https://doi.org/10.48550/arXiv.2407.17174>