



Facultad de Ciencias de la Administración

Carrera de Ingeniería de Sistemas y Telemática

**CLASIFICACIÓN JERÁRQUICA DE LOS
TEXTOS DE LAS CONVERSACIONES DEL ECU
911 UTILIZANDO MODELOS DE LENGUAJE
LARGOS**

**Trabajo de titulación previo a la obtención del
grado de Ingeniero de Sistemas y Telemática**

Autor:
Juan Gabriel Flores Sánchez.

Director:
Marcos Patricio Orellana Cordero

Cuenca – Ecuador

Año
2025

DEDICATORIA

Dedico este trabajo a todas las personas que estuvieron presentes y me acompañaron durante mi formación universitaria, especialmente a mi familia por todo su apoyo. A mi esposa e hijo, quienes son mi mayor inspiración y motivación, y quienes me brindaron el tiempo y espacio necesarios para alcanzar esta meta tan importante.

En especial, dedico este trabajo a mi madrecita, quien, aunque hoy ya no está físicamente conmigo, su espíritu y amor continúan guiándome. Siempre me brindó su amor incondicional, sus oraciones y su sabiduría, ayudándome a superar cualquier desafío.

Gracias, mamá, por tu infinito amor. Que Dios Jehová te tenga en su santa gloria por siempre.

AGRADECIMIENTO

En primer lugar, agradezco a Dios Todopoderoso
por guiarme y bendecirme a lo largo de mi
trayectoria universitaria.

Extiendo mi más sincero agradecimiento al director
de mi trabajo de titulación, Ing. Marcos Orellana,
quien me orientó con sus valiosos consejos durante
todo el proceso de elaboración de este proyecto.

De igual manera, expreso mi gratitud al equipo de
investigación y desarrollo en informática, LIDI.

Agradezco a mis amigos y compañeros de aula,
quienes me acompañaron y brindaron su apoyo a lo
largo de esta etapa académica.

Un agradecimiento muy especial a mi esposa e hijo,
quienes me ofrecieron su apoyo y comprensión
durante esta importante etapa de mi vida.

Por último, quiero expresar mi más profundo
agradecimiento a mi querida madre, quien, aunque
ya no está conmigo, su espíritu me acompaña y me
da el aliento para seguir adelante. Mamá, gracias por
todo tu amor y esfuerzo; me siento muy orgulloso de
ser tu hijo y haber tenido la oportunidad de aprender
tanto de ti. Te amo, mamá.

Índice de contenidos

DEDICATORIA	i
AGRADECIMIENTO	ii
Índice de Contenidos.....	iii
Índice de figuras.....	iv
Índice de tablas.....	v
RESUMEN.....	vi
ABSTRACT.....	vi
1. Introducción	1
1.1.Objetivos.....	2
1.2.Marco teórico.....	2
2. Revisión de literatura	5
3. Métodos	9
3.1.Recolección.....	9
3.1.1. Análisis de los Datos.....	10
3.2.Preprocesamiento de Datos.....	11
3.2.1. Filtrar texto con técnicas de NER y POS	12
3.2.2. Normalizar texto	13
3.2.3. Filtrar palabras irrelevantes (<i>Stopwords</i>)	13
3.2.4. Filtrar expresiones de cortesía y formalismos.....	14
3.3.Modelado de temas	14
3.4.Generación de etiquetas para tópicos utilizando LLaMA 3.....	19
3.5.Clasificación jerárquica de temas	20
3.6.Evaluación del modelo.....	21
4. Resultados y Discusión	22
4.1.Introducción a los resultados	22
4.2.Parámetros en UMAP y HDBSCAN.....	22
4.3.Árbol jerárquico.....	23
4.4.Resultado de evaluación	24
5. Conclusión	27
6. Referencias.....	28

Índice de figuras

Figura 1 Esquema de Metodología Aplicada	9
Figura 2 Distribución de la longitud de texto.....	11
Figura 3 Modelo de Preprocesamiento	12
Figura 4 Palabras Frecuentes del Dataset.....	14
Figura 5 Algoritmo utilizando BERTopic y LLMs.....	15
Figura 6 Visualización de clúster UMAP y HDBSCAN	17
Figura 7 Temas generados	18
Figura 8 Mapa interactivo de distancia entre temas de BERTopic.	19
Figura 9 Visualización de temas	19
Figura 10 Visualización del Dendrograma	21
Figura 11 Árbol jerárquico generado	24
Figura 12 Evaluación con el modelo Jina embeddings	25
Figura 13 Evaluación con el modelo Jina embeddings ampliada a tres posibilidades.....	26

Índice de tablas

Tabla 1 Interacciones entre Operador y Alertante	10
Tabla 2 Datos estadísticos del Dataset	10
Tabla 3 Técnicas de NER y POS	12
Tabla 4 Técnicas de normalización de Texto.....	13
Tabla 5 Técnicas para descartar stopwords, redundancia y palabras cortas	13
Tabla 6 Parámetros de UMAP y HDBSCAN Aplicados a Embeddings	16
Tabla 7 Configuración CountVectorizer	17
Tabla 8 Cuantización del modelo LLaMA 3.1-8B-Instruct	20
Tabla 9 Parámetros utilizados para el generador de texto.....	20
Tabla 10 Coherencia de tópicos	24
Tabla 11 Métricas de evaluación de niveles	26
Tabla 12 Evaluación nivel dos	27
Tabla 13 Evaluación nivel tres	27

CLASIFICACIÓN JERÁRQUICA DE LOS TEXTOS DE LAS CONVERSACIONES DEL ECU 911 UTILIZANDO MODELOS DE LENGUAJE LARGOS

RESUMEN

El estudio desarrolló un método de clasificación jerárquica para analizar las conversaciones del ECU 911, integrando modelos de lenguaje con arquitectura *LLaMA* (ej. *LLaMa 3.1 8B Instruct*), utilizando la librería *BERTopic* y técnicas de *clustering* aglomerativo. El método organizó los textos en categorías y subcategorías, capturando relaciones semánticas complejas y ofreciendo un análisis temático claro en el dominio de seguridad ciudadana. El uso de métricas de coherencia y diversidad temática aseguró asignaciones confiables, mientras que las etiquetas generadas automáticamente facilitaron la interpretación de los tópicos. El principal aporte del estudio se basa en la adaptación de estas técnicas al idioma español, proponiendo una solución innovadora para gestionar grandes volúmenes de datos textuales en los textos de las llamadas de emergencias. Aunque se evidencian limitaciones, como el solapamiento temático y la necesidad de representaciones vectoriales específicas, los resultados demuestran la viabilidad y robustez del modelo. Este trabajo establece una base sólida para futuras investigaciones y aplicaciones en clasificación jerárquica en otros contextos.

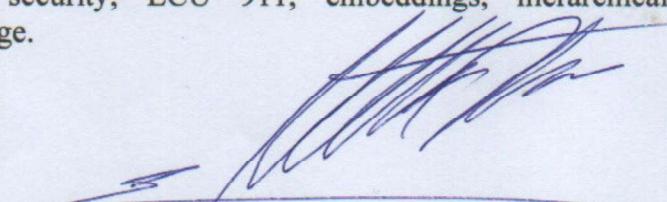
Palabras clave: *BERTTopic*, clasificación jerárquica, ECU 911, *embeddings*, inteligencia artificial, lenguaje natural, LLMs, seguridad ciudadana.

HIERARCHICAL CLASSIFICATION OF TEXTS FROM ECU 911 CONVERSATIONS USING LARGE LANGUAGE MODELS

ABSTRACT

The study developed a hierarchical classification method to analyze ECU 911 conversations, integrating language models with LLaMA architecture (e.g., LLaMA 3.1 8B Instruct), using the BERTopic library and agglomerative clustering techniques. The method organized texts into categories and subcategories, capturing complex semantic relationships and providing a clear thematic analysis in the domain of public safety. The use of coherence metrics and topic diversity ensured reliable assignments, while automatically generated labels eased the interpretation of topics. The main contribution of the study lies in the adaptation of these techniques to the Spanish language, proposing an innovative solution for managing large volumes of textual data in emergency call transcripts. Although limitations such as thematic overlap and the need for specific vector representations are clear, the results prove the model's feasibility and robustness. This work sets up a solid foundation for future research and applications in hierarchical classification across other contexts.

Keywords: *BERTtopic*, citizen security, ECU 911, *embeddings*, hierarchical classification, LLMs, natural language.



Marcos Orellana