

UNIVERSIDAD NACIONAL MICAELA BASTIDAS DE APURÍMAC
FACULTAD DE INGENIERÍA

ESCUELA ACADÉMICO PROFESIONAL DE INGENIERÍA INFORMÁTICA Y SISTEMAS



Informe de Investigación

Un modelo basado en redes neuronales recurrentes para el análisis de sentimientos con
información de Apurímac en Facebook

Presentado por:

Yonatan Mamani Coaquira

Abancay, Peru

2025





UNIVERSIDAD NACIONAL
MICAELA BASTIDAS
DE APURÍMAC

VICERECTORADO DE
INVESTIGACIÓN

DIRECCIÓN DE INSTITUTOS
DE INVESTIGACIÓN

25
AÑOS
BODAS DE PLATA

Res. 45

"Año de la recuperación y consolidación de la economía peruana"

Abancay, 21 de agosto del 2025



CARTA N° 0292- 2025-DIIN-VRIN-UNAMBA

Señor:

Dr. Wilson Mollocondo Flores
VICERRECTOR DE INVESTIGACION DE LA UNAMBA

Presente. -

**ASUNTO: SOLICITO RECONOCIMIENTO CON ACTO RESOLUTIVO,
POR CULMINACIÓN DE PROYECTO AUTOFINANCIADO**

REFERENCIA: CARTA N°15-2025-YMC-EPIIS-FI-UNAMBA

Reg. N 563

De mi mayor consideración,

Mediante la presente me dirijo a usted con el fin de saludarlo y remitir el documento de la referencia, del informe final titulado: "Un modelo basado en redes neuronales recurrentes para el análisis de sentimientos con información de Apurímac en Facebook"; proyecto autofinanciado con **RESOLUCIÓN DE VICERRECTORADO DE INVESTIGACION N°041-2023-VRIN(I)UNAMBA** de fecha 21 de marzo del 2023, del **Mtro. Yonatan Mamani Coaquira** docente de la Escuela Profesional de Ingeniería Informática y Sistemas de la UNAMBA.

Por lo expuesto, solicito el reconocimiento con acto resolutivo por la culminación de proyecto.

Sin otro particular, quedo a su disposición para cualquier consulta.

Atentamente,


Dr. Eddy Mamani Vilca
Director de Institutos de Investigación
UNAMBA

C/c:
Archivo
EMV/DIIN
Sec/DTN

UNIVERSIDAD NACIONAL MICAELA
BASTIDAS DE APURIMAC
VICERRECTORADO DE INVESTIGACIÓN
Proveído: Secret.
Para: Proyecto Resolu
Fecha: 25/08/25 Firma: 



Un modelo basado en redes neuronales recurrentes para el análisis de sentimientos con
información de Apurímac en Facebook

Línea de investigación: Ingeniería informática, industria y sociedad

Esta publicación está bajo una Licencia Creative Commons



ÍNDICE

	Pág.
INTRODUCCIÓN	1
RESUMEN	2
ABSTRACT	3
CAPÍTULO I	4
PLANTEAMIENTO DEL PROBLEMA	4
1.1. Descripción del problema	4
1.2. Enunciado del problema	5
1.2.1. Problema general	5
1.2.2. Problemas específicos	5
1.2.3. Justificación	5
CAPÍTULO II	6
OBJETIVOS	6
2.1. Objetivos de la investigación	6
2.1.1. Objetivo general	6
2.1.2. Objetivos específicos	6
2.2. Operacionalización de las variables	6
CAPÍTULO III	7
MARCO TEÓRICO REFERENCIAL	7
3.1. Antecedentes	7
3.2. Marco teórico	9
3.2.1. Análisis de sentimientos	9
3.2.2. Tipos de datos para análisis de sentimientos	9
3.2.3. Tareas de análisis de sentimientos	9
3.2.4. Niveles de análisis de sentimientos	10
3.2.5. Redes neuronales artificiales	10
3.2.6. Redes neuronales convolucionales (RNC)	11
3.2.7. Redes neuronales recurrentes	12
3.2.8. Contexto de la Región Apurímac	13
3.2.9. Características demográficas y socioeconómicas	13
3.2.10. Actividad económica	13
3.2.11. Relevancia de las redes sociales en la región	14
3.2.12. Facebook como red social de estudio	14
3.3. Marco conceptual	14
3.3.1. Opinión en redes sociales	14
3.3.2. Información de Apurímac	14
3.3.3. Análisis de sentimientos	15
3.3.4. Análisis de emociones	15
3.3.5. Modelos híbridos	15
CAPÍTULO IV	16



METODOLOGÍA	16
4.1. Tipo y nivel de investigación	16
4.2. Diseño de investigación	16
4.3. Procedimiento	17
4.4. Población y muestra	18
4.5. Técnicas e instrumentos	18
CAPÍTULO V	19
RESULTADOS Y DISCUSIONES	19
5.1. Metodología	19
5.1.1. Conjunto de datos	20
5.1.2. Preprocesamiento	21
5.1.3. Word Embedding	23
5.1.4. Modelo híbrido	23
5.1.5. Concatenación y capa de conexión	28
5.1.6. Salida de clasificación	30
5.2. Análisis de resultados	31
5.2.1. Comparación de modelos basados en BERT en idioma español	31
5.2.2. Comparación de embeddings en español con algoritmos de clasificación supervisados	33
5.2.3. Comparación de modelos híbridos con embeddings en español	34
5.2.4. Comparación de predicción de emociones de comentarios de Apurímac en Facebook	36
5.2.5. Comparación de frecuencia y polaridad léxica de comentarios de Apurímac en Facebook	39
5.3. Discusión	41
CAPÍTULO VI	43
CONCLUSIONES Y RECOMENDACIONES	43
6.1. Conclusiones	43
6.2. Recomendaciones	44
REFERENCIAS BIBLIOGRÁFICAS	45



ÍNDICE DE TABLAS

	Pág.
Tabla 1 — Operacionalización de las variables.	6
Tabla 2 — Técnicas utilizadas para el pre-procesamiento de datos.	22
Tabla 3 — Resultados de F1-macro con algoritmos supervisados y BETO.	33
Tabla 4 — Resultados de F1-macro con algoritmos supervisados y RoBERTuito.	34
Tabla 5 — Resultados de F1-macro con algoritmos supervisados y SaBERT.	34
Tabla 6 — Resultados de F1-macro con modelos híbridos y BETO.	35
Tabla 7 — Resultados de F1-macro con modelos híbridos y RoBERTuito.	35
Tabla 8 — Resultados de F1-macro con modelos híbridos y SaBERT.	36

ÍNDICE DE FIGURAS

	Pág.
Figura 1 — Rueda de emociones de Plutchik (Asociados, 2022).	9
Figura 2 — Ejemplo de una red neuronal artificial.	11
Figura 3 — Ejemplo de red neuronal convolucional (MathWorks [sin fecha]).	11
Figura 4 — Ejemplo de red neuronal recurrente (Wikipedia, 2022).	12
Figura 5 — Propuesta del modelo híbrido con RNNs.	24
Figura 6 — Propuesta de capas totalmente conectadas con salida de clases.	30
Figura 7 — Resultado de la función de pérdida por cada modelo basado en BERT.	31
Figura 8 — Resultado de F1-macro por cada modelo basado en BERT.	32
Figura 9 — Predicción de cantidad de emociones mediante la propuesta híbrida.	37
Figura 10 — Predicción de cantidad de emociones con modelo TweetNLP.	38
Figura 11 — Predicción de cantidad de emociones con modelo Pysentimiento.	38
Figura 12 — Predicción de cantidad de emociones con modelo XML-Roberta.	39
Figura 13 — Frecuencia de palabras más utilizadas en los comentarios de Apurímac.	40
Figura 14 — Nube de palabras positivas y negativas más frecuentes de los comentarios de Apurímac.	40



INTRODUCCIÓN

En la actualidad, el análisis de sentimientos y emociones en textos ha cobrado gran relevancia dentro del campo del Procesamiento de Lenguaje Natural (PLN), especialmente por su aplicación en el monitoreo del sentir social en contextos políticos, económicos y culturales. En regiones como Apurímac, donde las redes sociales se han convertido en una vía principal de expresión ciudadana, identificar automáticamente las emociones expresadas por los usuarios puede representar un recurso estratégico para la toma de decisiones en el ámbito público. Por otro lado, los modelos tradicionales de clasificación textual suelen presentar limitaciones cuando se enfrentan a variaciones lingüísticas o estructuras emocionales complejas presentes en textos en español.

El presente trabajo de investigación propone analizar los sentimientos de comentarios en Facebook relacionados con la región de Apurímac mediante un modelo de redes neuronales recurrentes con LSTM, BiLSTM, GRU y BiGRU, integradas con una capa de Attention y considerando como datos de entrada embeddings de tipo contextual mediante SaBERT y BETO, entrenados específicamente con el idioma español. Este modelo fue entrenado y evaluado sobre un dataset de Detección de Emociones obtenidas del evento TASS 2020, desarrollado como parte del Workshop de Análisis Semántico organizado por SEPLN 2020. En el presente trabajo se abordan tareas de clasificación emocional, análisis de polaridad y exploración léxica para identificar patrones afectivos en los comentarios expresados en referencia a la región de Apurímac.

Los resultados alcanzados demuestran que el modelo propuesto no solo es capaz de clasificar sentimientos, sino que también permite interpretar el contenido emocional más representativo del contexto de dominio específico. El rendimiento del modelo fue validado mediante métricas como F1-score y además se contrastaron empíricamente las hipótesis planteadas mediante visualizaciones gráficas, análisis de palabras frecuentes y pruebas estadísticas descriptivas. De este modo, la presente investigación proporciona un modelo que puede ser utilizado para estudios de opinión pública, análisis social o políticas regionales con base en el entendimiento automático del lenguaje emocional.



RESUMEN

La presente investigación tiene como objetivo analizar los sentimientos de comentarios en Facebook relacionados con la región de Apurímac, debido a su relevancia social y cultural, así como a la necesidad de comprender las percepciones ciudadanas en contextos regionales. Para ello, se propuso un modelo de redes neuronales recurrentes aplicadas a textos en español extraídos de la red social Facebook con comentarios relacionados a la región de Apurímac. En ese sentido, se diseñó una arquitectura híbrida que integra embeddings contextuales preentrenados mediante SaBERT, utilizando técnicas de fine-tuning mediante LSTM, BiLSTM, GRU, BiGRU y una capa de Attention, entrenado sobre un corpus de Detección de Emociones obtenidas del evento TASS 2020, desarrollado como parte del Workshop de Análisis Semántico organizado por SEPLN 2020, y preprocesados para garantizar su calidad lingüística, con una división del conjunto de datos en entrenamiento (80%) y validación (20%). Los resultados obtenidos muestran que el modelo alcanza F1-macro de clasificación de 0.49, superando a modelos híbridos sin redes neuronales y con redes neuronales con base en LSTM o GRU con valores entre 0.16 a 0.47. Además, se logró identificar polaridades de sentimientos y términos frecuentes con carga emocional positiva y negativa, lo que demuestra su aplicabilidad en contextos sociales reales. La investigación concluye que el modelo propuesto contribuye analizar sentimientos y emociones en español en un entorno regional específico, representando una contribución relevante para el área de análisis de sentimientos.

Palabras clave: *análisis de sentimientos, análisis de emociones, word embedding, comentarios en español.*



ABSTRACT

The aim of this research is to analyse the sentiments of comments on Facebook related to the Apurímac region, due to its social and cultural relevance, as well as the need to understand citizens' perceptions in regional contexts. To do this, a model of recurrent neural networks applied to Spanish texts extracted from the social network Facebook with comments related to the Apurímac region was proposed. In this regard, a hybrid architecture was designed that integrates contextual embeddings pre-trained using SaBERT through LSTM, BiLSTM, GRU, BiGRU and an Attention layer, trained on a corpus of Emotion Detection obtained from the TASS 2020 event, developed as part of the Semantic Analysis Workshop organised by SEPLN 2020, and preprocessed to ensure its linguistic quality, with a division of the dataset into training (80%) and validation (20%). The results obtained show that the model achieves an F1-macro classification score of 0.49, surpassing hybrid models without neural networks and with LSTM or GRU-based neural networks with values between 0.16 and 0.47. In addition, it was possible to identify sentiment polarities and frequently used terms with positive and negative emotional connotations, demonstrating its applicability in real social contexts. The research concludes that the proposed model contributes to the analysis of sentiments and emotions in Spanish in a specific regional environment, representing a significant contribution to the field of sentiment analysis.

Keywords: *sentiment analysis, emotion analysis, word embedding, spanish comments.*



CAPÍTULO I PLANTEAMIENTO DEL PROBLEMA

1.1. Descripción del problema

El uso de redes sociales por las personas crece de manera exponencial, cada día se genera millones de información en diferentes plataformas informáticas, por ejemplo: Twitter, Facebook, WhatsApp, YouTube, etc., los diferentes usuarios expresan opinión manifestando sentimiento y emociones (Liu, 2015) en referencia a un servicio, evento y producto, estas opiniones pueden ser expresadas en texto, video, audio, emoticón e imagen. Estos datos publicados tienen información útil para empresas y sociedad que ayudan a tomar mejores decisiones en diferentes ámbitos como: educación, psicología, política, negocios, marketing, etc. (Zhang, Wang y Liu, 2018). Para comprender el lado emocional de cada persona en las redes sociales existe el área de Análisis de Sentimientos que permite clasificar sentimientos positivos, negativos o neutral, también emociones como: alegría, sorpresa, ira, disgusto, miedo y tristeza (Nasukawa y Yi, 2003).

Existe millones de información de opiniones diariamente, Perú y sus regiones tiene información en las redes sociales manifestadas por usuarios peruanos y extranjeros en referencia a diferentes actividades realizadas. En la región de Apurímac existen noticias y eventos que ocurren diariamente que son comentadas por usuarios mediante redes sociales, tener esta información ordenada sería de gran utilidad para las instituciones públicas y empresas privadas; sin embargo, existe la necesidad de recopilar información en las redes sociales y analizar los sentimientos que expresan los usuarios, esto permitiría comprender el comportamiento de la población en referencia al sentimientos, por ejemplo: noticias periodísticas, eventos, servicios, turismo. Así la región de Apurímac podría entender el nivel de opinión que tienen de la región.

Por lo expuesto, el presente trabajo propone un modelo de Inteligencia Artificial que permite clasificar la polaridad de sentimientos expresados para la región de Apurímac en Facebook.



1.2. Enunciado del problema

1.2.1. Problema general

¿Qué propuesta de modelo de redes neuronales recurrentes es más adecuada para analizar los sentimientos de comentarios en Facebook relacionados con la región de Apurímac?

1.2.2. Problemas específicos

- ¿Cómo clasificar los sentimientos de los comentarios en Facebook relacionados con la región de Apurímac?
- ¿Cuáles son las palabras más frecuentes en los comentarios de Facebook relacionados con la región de Apurímac?
- ¿Cuáles son las polaridades de palabras en los comentarios de Facebook relacionados con la región de Apurímac?

1.2.3. Justificación

El área de Lenguaje de Procesamiento Natural tiene como subtarea el análisis de sentimientos que permite clasificar sentimientos y emociones que expresa la persona. Estos sentimientos pueden ser expresados en texto, audio, video, emoticones o imagen. Sin embargo, gran parte de la información se encuentra en texto que deben ser reprocesadas para comprender el sentimiento. En este contexto, la presente investigación propone analizar los sentimientos de comentarios en Facebook relacionados con la región de Apurímac mediante un modelo de redes neuronales recurrentes. Apurímac responde a la necesidad de comprender las percepciones y emociones que la población expresa en Facebook, dado su importante contexto cultural, social y político. Por su parte, Facebook es una de las redes sociales más utilizadas en la región, lo que garantiza datos y una representación más amplia de la opinión pública local. Este modelo desarrollado será de gran utilidad basado en información específica de una región, esto con la finalidad de comprender los diferentes sentimientos que expresan las personas.



CAPÍTULO II OBJETIVOS

2.1. Objetivos de la investigación

2.1.1. Objetivo general

Analizar los sentimientos de comentarios en Facebook relacionados con la región de Apurímac mediante un modelo de redes neuronales recurrentes.

2.1.2. Objetivos específicos

- Clasificar los sentimientos de los comentarios en Facebook relacionados con la región de Apurímac.
- Identificar las palabras más frecuentes en los comentarios de Facebook relacionados con la región de Apurímac.
- Identificar la polaridad de palabras en los comentarios de Facebook relacionados con la región de Apurímac.

2.2. Operacionalización de las variables

Tabla 1 — Operacionalización de las variables.

Variable	Dimensión	Indicador	Índice/escala
Modelo red neuronal recurrente	Precisión del modelo	F1-macro	Numérico decimal (entre 0 - 1)
Analizar sentimientos	Clasificar sentimientos	Etiquetado de comentarios con sentimientos	Escala categórica nominal
	Palabras frecuentes	Número de apariciones	Escala de conteo
	Polaridad de palabras	Palabras positivas y negativas	Escala categórico (positiva/negativa)



CAPÍTULO III MARCO TEÓRICO REFERENCIAL

3.1. Antecedentes

El área de análisis de sentimientos sigue siendo importante para la clasificación y entendimiento de opiniones mediante el sentimiento y emociones que expresa una persona. Existen diferentes trabajos en la literatura que proponen diferentes modelos con algoritmos supervisados y redes neuronales artificiales para clasificación de sentimientos en diferentes dominios como salud, educación, política, turismo, entre otros.

El trabajo de Sánchez (Sánchez del Hoyo, 2019) denominado Análisis de Sentimientos con Twitter: Turismo y Política Electoral. Realizó análisis estadísticos y sentimientos con diferentes partes de las ciudades de España con información relacionado a turismo. Se utilizó API de Twitter para extraer información. Entre las palabras más frecuentes en la ciudad de Sevilla fueron: Turismo, Sevilla y España, también se puede observar que, en el análisis de comentarios por día, la ciudad de Madrid, Valencia y Córdoba tiene mayor cantidad de opiniones. Por otro lado, en relación a comentarios de política los comentarios con mayor frecuencia estaban relacionados a Pedro Sánchez y Alberto Rivera. De la misma forma, el trabajo de Gutiérrez y Andrés (Gutiérrez y Andrés, 2019) desarrolló una aplicación web para análisis de sentimientos con información relacionado con oportunidades de emprendimientos e inversión, esto permitió tomar mejores decisiones estratégicas durante el proceso de emprendimiento. Utilizó polaridad de positivos, negativos y neutral para categorizar las opiniones.

Por otro lado, el trabajo de Mamani-Coaquira (Mamani-Coaquira et al., 2021) propone un modelo para clasificación de sentimientos con algoritmos supervisados utilizando información relacionado al aislamiento social obligatorio por la Covid-19 en Perú, parte la método propuesto fue la extracción de características



analizando palabras juntas para comprender la oración; de tal manera que, se pueda encontrar un mejor modelo con algoritmo supervisados. El su resultado obtiene que el modelo Support Vector Machine (SVM) obtiene mejores resultados alcanzando 91.5% de accuracy, de la misma forma encontraron palabras frecuentes como: cuarentena, covid, casa y extrañar. Por otro lado, Zarate (2022) en su proyecto de tesis denominado análisis de sentimientos en información de medios periodísticos y redes sociales mediante redes neuronales recurrentes propone implementar un modelo para análisis de sentimientos con notas periodísticos y redes sociales de las instituciones Ministerio de la Cultura, Clínica Internacional, Defensoría del Pueblo y RÍMAC. Para lograr sus objetivos utilizó técnicas de web scraping y API de Twitter para la recopilación de datos. También desarrolló una aplicación web que permitió analizar los sentimientos, en este proceso manifiesta que eliminó datos con sesgo y estandarizó criterios de clasificación. Parte de sus resultados demuestra que el modelo alcanzó un 85.24% de precisión con notas periodísticas y 75.98% de precisión para comentarios en Twitter.

El trabajo de Navarro (2022) denominado Aprobación del Presidente de Perú basado en análisis de sentimientos en Twitter, tuvo como objetivo principal implementar un sistema automático para la estimación de la aprobación popular del presidente del Perú utilizando datos de Twitter. Implementaron modelos con redes neuronales artificiales utilizando 3400 tweets recolectados entre agosto y diciembre del 2021, durante el preprocesamiento aplicaron Word2vec para vectorizar las características de la oración en español, logrando así obtener un 90.61% de precisión con redes neuronales convolucionales y 84.50% con redes neuronales recurrentes. Concluye que el método propuesto es una alternativa rápida, eficiente y de bajo costo para monitorear y obtener la tasa de aprobación del presidente peruano.

En referencia a algunos trabajos descritos aún existe la necesidad de seguir aportando con nuevas propuestas que permitan comprender y clasificar los sentimientos con datos no estructurados y en idioma español.



3.2. Marco teórico

3.2.1. Análisis de sentimientos

Principalmente permite determinar la clasificación de sentimiento y emociones que expresa una persona en texto, los sentimientos pueden ser positivos, negativos o neutral, emociones son como: alegría, sorpresa, ira, disgusto, miedo y tristeza (Kastrati et al., 2021; Minaee et al., 2021; Cambria et al., 2013).



Figura 1 — Rueda de emociones de Plutchik (Asociados, 2022).

3.2.2. Tipos de datos para análisis de sentimientos

Para manifestar sentimientos y emociones se pueden realizar en diferentes tipos de datos por ejemplo en texto, imagen, vídeo, audio y emoticones (Yadav y Vishwakarma, 2020; Wang et al., 2022).

3.2.3. Tareas de análisis de sentimientos

Dentro de las tareas principales se encuentra minería de opiniones y emociones, estas manifestaciones de afecto pueden ser para algún objeto, producto, servicio, evento, organización, persona, etc. La minería de opinión se clasifica en las siguientes sub tareas: detección de subjetividad, clasificación de polaridad, detección de spam, resumen de opinión y detección del argumento expresado (Yadollahi, Shahraki y



Zaiane, 2017). La minería de emociones se clasifica en las siguientes sub tareas: detección de emoción, clasificación de polaridad, clasificación de emoción, detección de la causa de emoción (Yadollahi, Shahraki y Zaiane, 2017).

3.2.4. Niveles de análisis de sentimientos

En clasificación de sentimientos principalmente se tiene 3 niveles importantes que aborda esta disciplina académica, estos son: nivel de documento, nivel de frase y nivel de aspecto que puede tener una oración (Liu, 2020).

El nivel documento permite determinar la polaridad de la opinión de todo el contenido del texto; sin embargo, a nivel de frase se puede terminar la polaridad en partes de todo el contenido. Recientemente existen nuevos trabajos que están enfocadas analizar sentimientos con nivel de aspecto o determinando la entidad y clasificar su polaridad por cada uno de ellos.

3.2.5. Redes neuronales artificiales

Son procesos que permiten procesar información basado en sistemas nerviosos biológicos (paradigma de sistema inteligente), buscan encontrar una funcionalidad similar al cerebro humano. La presentación está basada en neuronas con múltiples conexiones entre ellas (Romero et al., 2007). Por otro lado, el término de Aprendizaje Automático es más utilizado para trabajos relacionados a Inteligencia Artificial utilizando algoritmos supervisados, no supervisados y por refuerzo, también modelos con redes neuronales artificiales. Esto permite enseñar a los ordenadores para que aprendan dando sugerencias o predicciones en diferentes dominios. Sin embargo, el Aprendizaje Profundo es un área con mayor crecimiento desarrollando modelos profundos, esto permite mejorar los procesos de aprendizaje con grandes cantidades de datos esto en referencia al uso de múltiples neuronas conectadas entre sí (Rouhiainen, 2018).



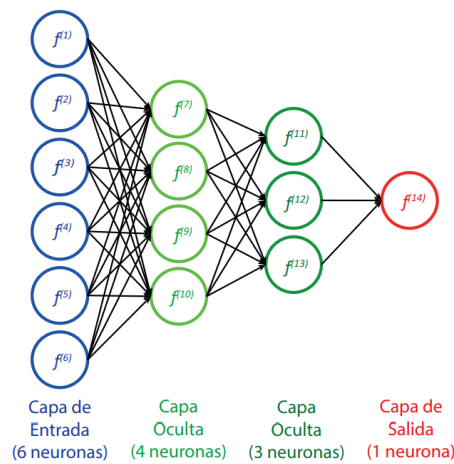


Figura 2 — Ejemplo de una red neuronal artificial.

3.2.6. Redes neuronales convolucionales (RNC)

Es una arquitectura de red neuronal profunda, permite encontrar patrones en imágenes, también son utilizadas para clasificación de datos en texto, audio, series temporales y señales (MathWorks, [sin fecha]).

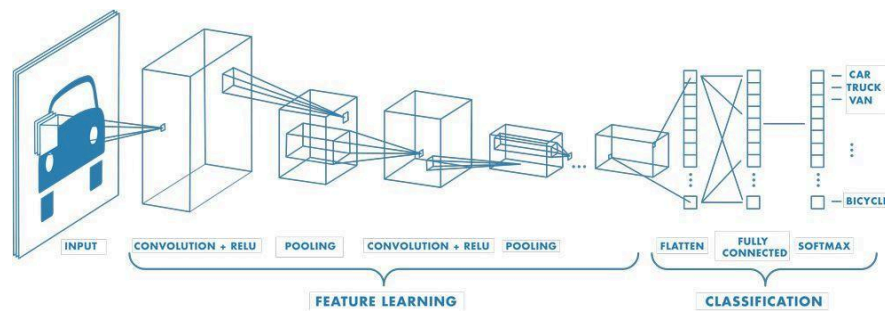


Figura 3 — Ejemplo de red neuronal convolucional (MathWorks [sin fecha]).

Una RNC puede tener diferentes capas que aprendan a reconocer múltiples características de una imagen, se aplican filtros para mejorar la identificación de la imagen, en las últimas capas se aplica la técnica de Flatten para vectorizar los datos de salida.

Este tipo de redes neuronales están siendo utilizadas para diferentes trabajos como clasificación de imágenes con grandes cantidades de imágenes. Sin embargo, existen algunos modelos híbridos para clasificación de sentimientos con RNC que han contribuido a mejorar la precisión.



3.2.7. Redes neuronales recurrentes

Este tipo de redes forma parte de redes neuronales artificiales, está basado en secuencia de datos con series de tiempo. Su utilidad está enfocada en tratamiento de texto como traducción de idiomas, corrector de ortografía, generación de texto, análisis de sentimientos y reconocimiento de voz; estas redes también tienen un proceso de entrenamiento para aprender. Su característica principal es que tiene memoria que permite tomar información de datos anteriores para luego ser utilizados como nuevos datos de entrada y resultados (IBM, [sin fecha]).




Figura 4 — Ejemplo de red neuronal recurrente (Wikipedia, 2022).

Este tipo de redes neuronales se clasifican en arquitecturas como Redes Neuronales Bidireccionales Recurrentes (BRNN). Estas redes bidireccionales permiten extraer informaciones futuras logrando una precisión adecuada. La otra arquitectura es Long Short-Term Memory (LSTM) permite aprender los datos a largo plazo con aplicaciones en la predicción de manera secuencial (IBM, [sin fecha]). LSTM puede capturar las dependencias temporales a largo plazo de manera efectiva, sin sufrir muchos obstáculos de optimización. Esto se utiliza para abordar los problemas de gama alta. Gated Recurrent Unit (GRU) es similar a LSTM porque permite trabajar con memoria a corto plazo, GRU para hacer que cada unidad recurrente capte de forma adaptativa dependencias de diferentes escalas temporales. De forma similar a la unidad LSTM, la GRU tiene unidades de Gating que modulan el flujo de información dentro de la unidad (Chung et al., 2014).



3.2.8. Contexto de la Región Apurímac

Apurímac es una región del sur del Perú caracterizada por su diversidad geográfica, que abarca desde profundos valles interandinos hasta zonas altoandinas. Su economía históricamente se ha sustentado en la agricultura y ganadería, aunque en las últimas décadas la minería, especialmente el megaproyecto Las Bambas, ha transformado significativamente su estructura económica. Administrativamente está organizado en siete provincias y destaca por una población mayoritariamente quechuahablante en zonas rurales (Aguilar Sanchez y Flores Moran, 2018; Zavala, 2023).

3.2.9. Características demográficas y socioeconómicas

La región de Apurímac presenta un patrón poblacional predominantemente rural, con altos índices de pobreza y desigualdad. Según estudios sobre desertificación y presión antrópica, factores como la densidad poblacional, el uso de leña y la carga pecuaria influyen directamente en la degradación del suelo y la sostenibilidad ambiental (Ibáñez y Damman, 2010).

Según estimaciones del CPI Research para 2024, Apurímac cuenta con aproximadamente 462 500 habitantes, cifra que representa alrededor del 1,4% de la población total del país (CPI, 2024). En términos de composición lingüística, el quechua tiene una presencia significativa como lengua materna, lo que implica que buena parte de los textos generados pueden presentar características bilingües o influencias idiomáticas locales.

3.2.10. Actividad económica

En el ámbito económico, la región depende principalmente de la agricultura, los servicios y una minería en crecimiento, con una población mayoritariamente rural que plantea retos en conectividad y acceso a servicios. Si bien Apurímac tiene su orientación agrícola, en los últimos años la actividad minera ha reducido en algunos sectores de la población destinada a cultivos, limitando el autoabastecimiento y provocando



migraciones hacia actividades extractivas económicamente (Reyes-Olivo y Soto, 2020).

3.2.11. Relevancia de las redes sociales en la región

En el contexto actual, las redes sociales no sólo cumplen funciones recreativas, sino que se han convertido en herramientas clave para la movilización social, la difusión de información y el comercio digital. En zonas con limitada infraestructura de medios tradicionales, como varias provincias de Apurímac, las redes sociales permiten fortalecer la participación ciudadana, difundir problemáticas socioambientales y promover productos locales.

3.2.12. Facebook como red social de estudio

Facebook se mantiene como la red social predominante en Perú, con más de 25 millones de usuarios registrados hasta junio de 2025 (Oré Arroyo, 2025; Helthon, 2023). Asimismo, el alcance de anuncios de Facebook abarca el 71,2 % de la población total del país a inicios de 2025 (Waynet, 2025). Otras plataformas como TikTok e Instagram también tienen presencia, pero Facebook sigue siendo la más utilizada para consumo de noticias e interacción social (Helthon, 2023).

3.3. Marco conceptual

3.3.1. Opinión en redes sociales

Las personas pueden manifestar una o varias opiniones en texto en diferentes redes sociales hacia un producto, servicio, etc., esta opinión puede tener múltiples polaridades de sentimientos o en algunos casos solo uno.

3.3.2. Información de Apurímac

La región de Apurímac, Perú tiene gran cantidad de seguidores que comparten información en redes sociales, son varios los usuarios que expresan opiniones en diferentes ámbitos como: salud, economía, agricultura, turismo, educación, etc. Esta información es valiosa para instituciones públicas y privadas.



3.3.3. Análisis de sentimientos

Clasificar la polaridad de sentimientos que expresa una persona en las redes sociales. Estos sentimientos pueden ser positivos, negativos y neutrales.

3.3.4. Análisis de emociones

El análisis de emociones consiste en identificar y clasificar las emociones expresadas en un texto, como alegría, tristeza, miedo, enojo, etc.

3.3.5. Modelos híbridos

Los modelos de Inteligencia Artificial aprenden por medio de neuronas interconectadas y existen diferentes arquitecturas como convolucionales y recurrentes. El modelo híbrido permite unir diferentes arquitecturas profundas para mejorar la precisión durante la clasificación de sentimientos.




CAPÍTULO IV METODOLOGÍA

4.1. Tipo y nivel de investigación

La presente investigación es de tipo aplicada con un enfoque cuantitativo, porque permitió resolver los problemas utilizando conocimientos teóricos con la finalidad de entregar soluciones. El alcance de la investigación es descriptivo porque va a describir y analizar las características de los datos como: clasificar sentimientos, frecuencias de palabras e identificar palabras positivas y negativas sin manipular variables ni establecer relaciones de causalidad directa (Hernández-Sampieri y Mendoza-Torres, 2018).

4.2. Diseño de investigación

El diseño es no-experimental de tipo transversal porque no se manipulan variables, ni se controlan condiciones. Solo se recolectan y analizan datos existentes en redes sociales en un periodo determinado (Hernández-Sampieri y Mendoza-Torres, 2018; Ramos-Galarza, 2021). A continuación se presenta un esquema visual del diseño.



Donde

M es la muestra total.

D_t es la recolección de datos en un solo momento de tiempo.

O_x es la variable modelo red neuronal recurrente.

O_y es la variable analizar sentimientos.

r_{xy} es la relación de la variable O_x hacia O_y .



4.3. Procedimiento

La presente investigación se desarrolló a lo largo de un proceso sistemático estructurado en cinco etapas generales de forma secuencial, desde la planificación hasta la elaboración del informe final. A continuación, se detallan las fases que se desarrollaron en el presente estudio:

a) **Formulación y diseño del proyecto**

En esta etapa se definió el problema de investigación, los objetivos generales y específicos, y la hipótesis principal junto con las hipótesis específicas orientadas al análisis de sentimientos y emociones en textos relacionados a la región de Apurímac. Asimismo, se revisó el estado del arte en modelos de clasificación emocional en idioma español, con énfasis en arquitecturas híbridas de redes neuronales y el uso de embeddings contextuales.

b) **Recolección y preparación de datos**

Se recopilaron comentarios en español provenientes de la red social Facebook, filtrando publicaciones relacionadas con temáticas sociales, culturales o políticas de la región de Apurímac. Asimismo, se utilizó el dataset de Detección de Emociones obtenidas del evento TASS 2020, desarrollado como parte del Workshop de Análisis Semántico organizado por SEPLN 2020.

c) **Implementación del modelo híbrido**

El modelo propuesto integró vectores pre-entrenados de SaBERT (modelo BERT especializado en español) como entrada, seguido por la implementación de varias capas recurrentes: LSTM, BiLSTM, GRU y BiGRU, junto con una capa de atención (Attention Layer) encargada de capturar patrones emocionales relevantes.

Donde el conjunto de datos fue dividido en 80% para entrenamiento, y 20% para validación.

d) **Evaluación y análisis de resultados**

Los resultados del modelo se evaluaron utilizando métricas estándar como: precisión, accuracy, recall y F1-macro.

Además, se realizaron comparaciones con modelos base como BETO, RoBERTuito, TweetNLP y XLM-RoBERTa, utilizando visualizaciones gráficas



y análisis tabulares. Para verificar estadísticamente las diferencias de rendimiento entre modelos.

También se aplicaron técnicas de análisis léxico para determinar:

- Palabras más frecuentes,
- Palabras con carga positiva y negativa,
- Distribución de polaridades y emociones.

Estas evidencias se visualizaron con gráficos de barras, nubes de palabras y diagramas de frecuencia.

e) Redacción de resultados y discusión

Con base en los resultados obtenidos, se elaboraron las secciones de:

- Análisis de resultados, destacando el rendimiento del modelo híbrido.
- Discusión, interpretando el impacto de los hallazgos frente a estudios previos y contextualizando los resultados en el ámbito social de Apurímac.

f) Elaboración de informe final, asegurando coherencia metodológica y soporte empírico en la validación de los objetivos.

4.4. Población y muestra

La población son los comentarios en Facebook con información relacionado a la región de Apurímac y el conjunto de datos Detección de Emociones obtenidas del evento TASS 2020, con un total de 12140 mil comentarios.

N = 12140
n = 5886

Donde

N: población total en comentarios.
n: muestra en comentarios (utilizado para entrenamiento).

4.5. Técnicas e instrumentos

En la presente investigación se utilizó la técnica de observación, esto sirvió para visualizar los datos textuales provenientes de comentarios publicados en Facebook. Asimismo, los instrumentos utilizados fueron API para extracción de comentarios y base de datos para almacenar los comentarios extraídos.



CAPÍTULO V RESULTADOS Y DISCUSIONES

5.1. Metodología

La arquitectura del modelo híbrido propuesto, fue diseñado para la clasificación de emociones en textos en idioma español. Esta propuesta fue entrenada con el conjunto de datos TASS 2020 - Tarea 2: Detección de emociones, uno de los benchmarks más usados en el campo del procesamiento del lenguaje natural en español. El flujo de procesamiento del modelo inicia con una etapa de preprocesamiento textual, en la que se realiza la tokenización, normalización del texto y eliminación de elementos irrelevantes. Una vez que los textos son limpiados y segmentados en tokens, se procede a la generación de representaciones vectoriales del lenguaje a través del modelo SaBERT, una variante del modelo BERT entrenado específicamente con grandes corpus en español. Estas representaciones, conocidas como word embeddings contextualizados, capturan tanto el significado semántico como el contexto sintáctico de cada palabra, lo cual es fundamental para detectar matices emocionales en el lenguaje humano.

Posteriormente, estos vectores son introducidos de manera paralela en cuatro arquitecturas de redes neuronales recurrentes (RNN): una LSTM (Long Short-Term Memory), BiLSTM (Bidirectional LSTM), GRU (Gated Recurrent Unit) y BiGRU (Bidirectional GRU). La elección de estas redes recurrentes busca explorar distintas capacidades de modelado secuencial y bidireccional del lenguaje. Mientras que las variantes simples (LSTM y GRU) procesan las oraciones en una sola dirección, las variantes bidireccionales (BiLSTM y BiGRU) permiten captar dependencias tanto pasadas como futuras dentro de la secuencia textual, enriqueciendo así la comprensión del mensaje emocional implícito.

Las salidas generadas por estas cuatro redes recurrentes son concatenadas y procesadas a través de una capa de atención. Esta capa actúa como un mecanismo



de filtrado que permite al modelo enfocarse en las partes del texto más relevantes para la identificación emocional, asignando mayores pesos a aquellos elementos lingüísticos que tienen mayor carga afectiva. De esta manera, se optimiza la calidad de las representaciones intermedias que alimentan a la siguiente capa del modelo.

Finalmente, el vector resultante es alimentado a una capa completamente conectada (fully connected) que actúa como clasificador final. Esta capa está configurada para predecir una de las siete clases emocionales definidas por la tarea de TASS 2020: enojo (anger), disgusto (disgust), miedo (fear), alegría (joy), tristeza (sadness), sorpresa (surprise) y una categoría adicional denominada otros (others) que agrupa emociones no definidas en las seis anteriores.

La arquitectura propuesta, al combinar embeddings semánticos pre-entrenados con múltiples redes recurrentes y un mecanismo de atención, logra capturar de manera robusta la complejidad emocional del lenguaje en español, mostrando un desempeño competitivo frente a modelos baselines y contribuyendo significativamente al campo del análisis de emociones y sentimientos en lenguaje de procesamiento natural.

5.1.1. Conjunto de datos

En esta sección se describe el conjunto de datos que fue utilizado para el diseño, entrenamiento, validación y evaluación del modelo propuesto, orientado a la clasificación automática de emociones y sentimientos en textos escritos en español por comentarios en Facebook.

Para los procesos de entrenamiento y validación, se empleó el corpus correspondiente a la Detección de Emociones obtenidas del evento TASS 2020, desarrollado como parte del Workshop de Análisis Semántico organizado por SEPLN 2020. Este corpus incluyó textos recolectados de la red social Twitter, caracterizados por un lenguaje informal y con mucho ruido, espontáneo y contextual. Cada entrada en el corpus estuvo etiquetada manualmente con una de las siete categorías emocionales definidas en la tarea: enojo (anger), disgusto (disgust), miedo (fear),



alegría (joy), tristeza (sadness), sorpresa (surprise) y otros (others). Esta última categoría agrupó aquellos textos que no pudieron ser clasificados dentro de las 6 emociones básicas.

Con el propósito de realizar una comparación objetiva entre el modelo propuesto y enfoques existentes, se utilizó también el conjunto de prueba de Detección de Emociones, el cual estuvo compuesto por 857 registros de textos. A diferencia del corpus de entrenamiento con 5886 registros de textos, este conjunto de pruebas no incluyó etiquetas emocionales, por lo que sirvió como base para la evaluación externa de las predicciones realizadas por el modelo propuesto.

Asimismo, con el objetivo de explorar la capacidad de generalización del modelo en un dominio distinto, se construyó un segundo conjunto de datos complementario, conformado por comentarios extraídos de la red social Facebook, utilizando como criterio de filtrado una colección de hashtags relacionados con la región de Apurímac, Perú. Este proceso permitió recopilar un total de 5397 comentarios, provenientes de publicaciones vinculadas a temas sociales, culturales, políticos y económicos. Al igual que el conjunto de datos de prueba Detección de emociones de TASS, este corpus tampoco incluyó etiquetas de emociones en cada comentario, por lo que fue empleado como caso de validación indirecta en un contexto real y localizado.

Ambos conjuntos de datos de evaluación sin etiquetas permitieron analizar el comportamiento del modelo propuesto en escenarios fuera del dominio original de entrenamiento, lo que resultó clave para valorar su robustez y su aplicación práctica en contextos reales del ámbito del idioma español.

5.1.2. Preprocesamiento

En esta sección se resumen las técnicas de preprocesamiento aplicadas al corpus de análisis de emociones en español. Estas técnicas permiten limpiar, normalizar y estructurar los textos de entrada, eliminando



elementos irrelevantes (como URLs, menciones o emojis) y unificando aspectos lingüísticos (como la capitalización, ortografía y formato). Este proceso garantiza que los datos sean adecuados para el entrenamiento de modelos de aprendizaje automático y facilita una mejor extracción de características emocionales relevantes durante la etapa de clasificación.

Tabla 2 — Técnicas utilizadas para el pre-procesamiento de datos.

Técnica	Descripción
Conversión a minúsculas	Unifica el uso de mayúsculas y minúsculas para evitar duplicidad léxica y mejorar la coherencia del análisis.
Eliminación de palabras innecesarias	Se eliminan términos genéricos como “hashtag” o “user” que no aportan significado emocional.
Eliminación de menciones	Se eliminan referencias directas a usuarios (@usuario) para evitar ruido en el contenido emocional.
Eliminación de URLs	Se remueven hipervínculos que pueden introducir sesgos o distracciones externas al análisis textual.
Eliminación de signos de puntuación	Se suprimen símbolos ortográficos no esenciales, como comas o signos de exclamación, que no alteran la carga emocional.
Eliminación de emojis y emoticonos ASCII	Se eliminan representaciones gráficas de emociones para centrarse exclusivamente en el análisis textual.
Filtrado de caracteres no españoles	Se conservan solo los caracteres del alfabeto español, eliminando símbolos o letras extranjeras.
Normalización ortográfica	Se eliminan tildes y se reemplaza la “ñ” por “n” para estandarizar el vocabulario, aunque se reconoce una posible pérdida de precisión léxica.
Normalización de espacios en blanco	Se ajustan los espacios para mantener una estructura uniforme en el texto.
Corrección de caracteres repetidos	Se corrigen errores de tipeo como letras repetidas sin alterar expresiones emocionales frecuentes.
Lematización y eliminación de	Se reducen las palabras a su forma base



stopwords	y se eliminan términos sin valor semántico, conservando negaciones importantes para el análisis emocional.
Codificación numérica	Se transforman las etiquetas de emoción en valores numéricos para facilitar su uso por los algoritmos de clasificación.

5.1.3. Word Embedding

Para representar computacionalmente las palabras presentes en los textos del corpus, se utilizaron modelos de word embedding basados en arquitecturas del tipo *Transformer*, en particular SaBERT y BETO, ambos entrenados con grandes volúmenes de texto en español. Estos modelos generan representaciones vectoriales densas y contextualizadas, capaces de capturar tanto el significado semántico de las palabras como el contexto sintáctico en que se insertan. SaBERT (Spanish BERT) es una adaptación del modelo BERT pre-entrenado con corpora específicos del español, como Wikipedia y textos periodísticos, lo que le permite interpretar con mayor precisión los matices del idioma. Por su parte, BETO modelo desarrollado por la Universidad del País Vasco, también está especializado en español y ha mostrado un rendimiento sobresaliente en tareas de análisis semántico y comprensión del lenguaje, según diversos *benchmarks*. Ambos modelos permiten transformar oraciones o documentos en conjuntos de vectores numéricos que sirven como entrada para los clasificadores de emociones. Estas representaciones no solo superan en calidad a los embeddings tradicionales como Word2Vec o GloVe, sino que también conservan las dependencias contextuales entre palabras, aspecto esencial para detectar emociones implícitas en estructuras lingüísticas complejas.

5.1.4. Modelo híbrido

Con el objetivo de reconocer la información dinámica de forma secuencial y contextual de las emociones expresadas en texto, se desarrolló un modelo híbrido que integra múltiples arquitecturas de redes neuronales recurrentes junto con un mecanismo de atención. El modelo



combina las ventajas de distintas variantes de RNN, específicamente LSTM, BiLSTM, GRU y BiGRU, con una capa de atención (Attention Layer), la cual permite resaltar las palabras más relevantes para la clasificación de emociones.

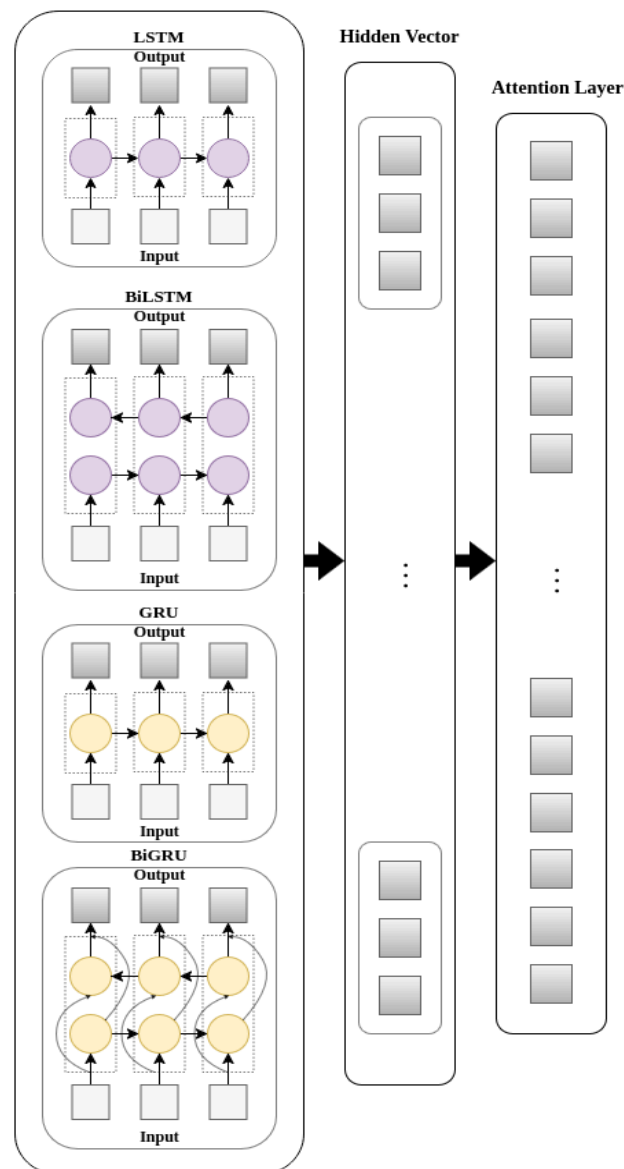


Figura 5 — Propuesta del modelo híbrido con RNNs.

a) Long Short-Term Memory

Las redes LSTM fueron diseñadas para superar el problema del desvanecimiento del gradiente en las RNN tradicionales. Incorporan una estructura de memoria que controla la información que se



conserva o se olvida mediante compuertas. La representación de LSMT es la siguiente ecuación.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

$$\hat{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$$

$$C_t = f_t * C_{t-1} + i_t * \hat{C}_t$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

$$h_t = o_t * \tanh(C_t)$$

Donde

x_t es la entrada en el paso de tiempo t .

h_t es el estado oculto.

C_t es el estado de la celda en tiempo t .

W_f, W_i, W_c, W_o son pesos de cada puerta.

b_f, b_i, b_c, b_o son sesgos asociados a cada puerta.

σ es la función de sigmoide.

\tanh es la función tangente hiperbólica.

b) Bidirectional LSTM

El BiLSTM extiende el LSTM al procesar la secuencia en dos direcciones (adelante y atrás), lo que permite capturar dependencias tanto pasadas como futuras.

$$h_t^{\rightarrow} = LSTM_{fw}(x_t), \quad h_t^{\leftarrow} = LSTM_{bw}(x_t)$$

$$h_t = [h_t^{\rightarrow}; h_t^{\leftarrow}]$$



Donde

x_t es la entrada en el paso de tiempo t .

h_t^{\rightarrow} es el estado oculto en la dirección hacia adelante.

h_t^{\leftarrow} en la dirección inversa.

$h_t = [h_t^{\rightarrow}; h_t^{\leftarrow}]$ concatenación de estados ocultos para capturar contexto anterior y posterior del texto.

c) Gated Recurrent Unit

El GRU es una variante simplificada del LSTM que utiliza solo dos compuertas: actualización y reinicio, lo que reduce la complejidad computacional manteniendo un buen rendimiento.

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t])$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t])$$

$$\hat{h}_t = \tanh(W_h \cdot [r_t * h_{t-1}, x_t])$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \hat{h}_t$$

Donde

x_t es la entrada en el paso de tiempo t .

h_t es el estado oculto en el tiempo t .

z_t puerta de actualización para conservar el estado anterior.

r_t puerta de reinicio que controla el estado anterior se ignora.

\hat{h}_t estado oculto candidato para reemplazar parcialmente a h_t .

W_z, W_r, W_h son pesos de cada puerta.

d) Bidirectional GRU

De manera similar al BiLSTM. El BiGRU procesa la secuencia en ambas direcciones, combinando la salida de la red GRU hacia adelante y hacia atrás:

$$h_t = [h_t^{\rightarrow}; h_t^{\leftarrow}]$$

Donde

h_t^{\rightarrow} es el estado oculto GRU en la dirección hacia adelante.

h_t^{\leftarrow} estado oculto GRU en la dirección hacia atrás.

$h_t = [h_t^{\rightarrow}; h_t^{\leftarrow}]$ concatenación de estados ocultos para capturar contexto anterior y posterior del texto.

e) Attention Layer

Para mejorar la capacidad del modelo de identificar las palabras o frases más relevantes emocionalmente, se integró una capa de atención aditiva que aprende pesos para cada vector de salida de las redes recurrentes.

$$u_t = \tanh(W_w \cdot h_t + b_w)$$

$$\alpha_t = \frac{\exp(u_t^T u_w)}{\sum_t \exp(u_t^T u_w)}$$

$$v = \sum_t \alpha_t \cdot h_t$$

Donde

h_t es la salida de la red recurrente en el tiempo t .



u_t representación transformada del estado oculto para calcular relevancia.

α_t es el peso de la atención.

v es la representación final atendida de la secuencia.

W_w, b_w pesos y sesgo de la capa de atención.

5.1.5. Concatenación y capa de conexión

Luego del procesamiento de las secuencias por parte de las redes recurrentes (LSTM, BiLSTM, GRU y BiGRU), el modelo híbrido requiere integrar toda esta información en una única representación que capture diversas perspectivas del contenido emocional. Para ello, se aplicó una operación de concatenación, seguida de una capa totalmente conectada (fully connected) que actúa como clasificador final de emociones.

a) Concatenación

Cada arquitectura recurrente genera un vector de salida (o un conjunto de vectores si es una red bidireccional) representando distintas formas de codificar la secuencia. Para integrar esta información, se concatenan los vectores de salida finales de los cuatro modelos.

$$H = [h^{Lstm}; h^{Bilstm}; h^{Gru}; h^{Bigru}]$$

Donde

$$h^{Lstm} \in R^{d_1}$$

$$h^{Bilstm} \in R^{d_2}$$

$$h^{Gru} \in R^{d_3}$$

$$h^{Bigru} \in R^{d_4}$$

$$H \in R^d \text{ donde } d = d_1 + d_2 + d_3 + d_4$$

Esta operación forma un único vector de características enriquecido que contiene información capturada por cada red neuronal recurrente.

b) Capa totalmente conectada (*fully connected layer*)

Una vez obtenido el vector de características combinadas H , este vector se introduce en una capa densa que transforma la representación de entrada en una distribución sobre las clases de emociones, mediante una función lineal seguida de una activación softmax.

$$y = \text{softmax}(W \cdot H + b)$$

Donde:

$H \in R^d$ es el vector de entrada concatenada.

$W \in R^{K \times d}$ es la matriz de pesos de la capa densa.

$b \in R^K$ es el vector de sesgos (*bias*).

K es el número total de clases emocionales.

$y \in R^K$ es el vector de salida con probabilidades para cada clase de emociones.

La función softmax garantiza que las salidas se interpreten como una distribución de probabilidad, donde cada vector y_k representa la probabilidad de que el texto pertenezca a la clase de emociones k :

$$y_k = \frac{e^{z_k}}{\sum_{j=1}^K e^{z_j}}$$

Donde

$z = W \cdot H + b$ son valores calculados antes de aplicar softmax.

y_k es probabilidad para que el texto pertenezca a la clase k .

e^{z_k} es valor exponencial para la clase k .

$\sum_{j=1}^K e^{z_j}$ es normalización para convertir en probabilidades.

5.1.6. Salida de clasificación

Luego de realizar la conexión de capas. El modelo asigna una etiqueta de emoción correspondiente al texto de entrada eligiendo la clase con mayor probabilidad en el vector y .

$$\hat{y} = \arg \max_k (y_k)$$

Donde
 \hat{y} es la clase predicha
 y_k es la probabilidad de la clase k calculada por softmax.
 $\arg \max_k (y_k)$ es la selección de la clase con mayor probabilidad.

Este enfoque permite que el modelo no solo combine representaciones heterogéneas de la secuencia, sino que también aprenda automáticamente los patrones relevantes para clasificar emociones, gracias al proceso que permite la capa densa.




Figura 6 — Propuesta de capas totalmente conectadas con salida de clases.

5.2. Análisis de resultados

5.2.1. Comparación de modelos basados en BERT en idioma español

La Figura 7 muestra la línea de evolución de la función de pérdida experimentando en 10 épocas de entrenamiento, donde se consideró 5 modelos basados en arquitecturas BERT, estos modelos fueron adaptados al idioma español como son: BETO, RoBERTuito, roBERTaES, BERTin y SaBERT. Se observa que los modelos BETO, RoBERTuito y roBERTaES muestran una reducción y estable de la función de pérdida, alcanzando valores cercanos a cero en las últimas épocas, lo que indica una alta capacidad de aprendizaje y generalización sobre el conjunto de datos de emociones. El modelo RoBERTuito destaca por su rápida convergencia desde las primeras épocas. Por otro lado, el modelo BERTin muestra un comportamiento irregular, con una función de pérdida inicial alta, seguido de una disminución más lenta en comparación con los otros modelos, esto indica que existen dificultades para ajustarse al conjunto de datos. Sin embargo, SaBERT presenta una curva de pérdida decreciente y estable, aunque con una tasa de aprendizaje más ordenada. Estos resultados evidencian que los modelos pre-entrenados específicamente con conjunto de datos en español y relacionado a comentarios en Facebook, como RoBERTuito y roBERTaES, tienden a adaptarse mejor a tareas de clasificación de emociones, en comparación con modelos menos especializados como BERTin.




Figura 7 — Resultado de la función de pérdida por cada modelo basado en BERT.



La Figura 8 muestra el comportamiento de la métrica F1-macro en la evaluación 10 épocas de entrenamiento para los modelos BETO, RoBERTuito, roBERTaES, BERTin y SaBERT. Esta métrica, permitió identificar claramente el comportamiento de precisión en la clasificación de emociones. Se observa que los modelos RoBERTuito, BETO, SaBERT y RoBERTaES alcanzan valores estables de F1-macro entre 0.50 y 0.55 desde el inicio de las primeras épocas, lo cual evidencia su capacidad para identificar de manera consistente múltiples emociones. En tal sentido, el modelo RoBERTuito destaca ligeramente con un rendimiento más alto en la mayoría de las épocas. Por otro lado, el modelo BERTin presenta un rendimiento significativamente inferior durante las primeras 5 épocas, con valores por debajo de 0.20, y partir de la 6 época muestra una mejora progresiva hasta encontrar la estabilidad en 0.33. Esta baja precisión inicial puede atribuirse a una menor entendimiento del conjunto de datos en español. Estos resultados confirman la superioridad de los modelos entrenados con conjunto de datos en español y relacionados a comentarios en redes sociales y refuerzan el valor del pre-entrenamiento contextualizado en dominios específicos para tareas de clasificación de emociones.

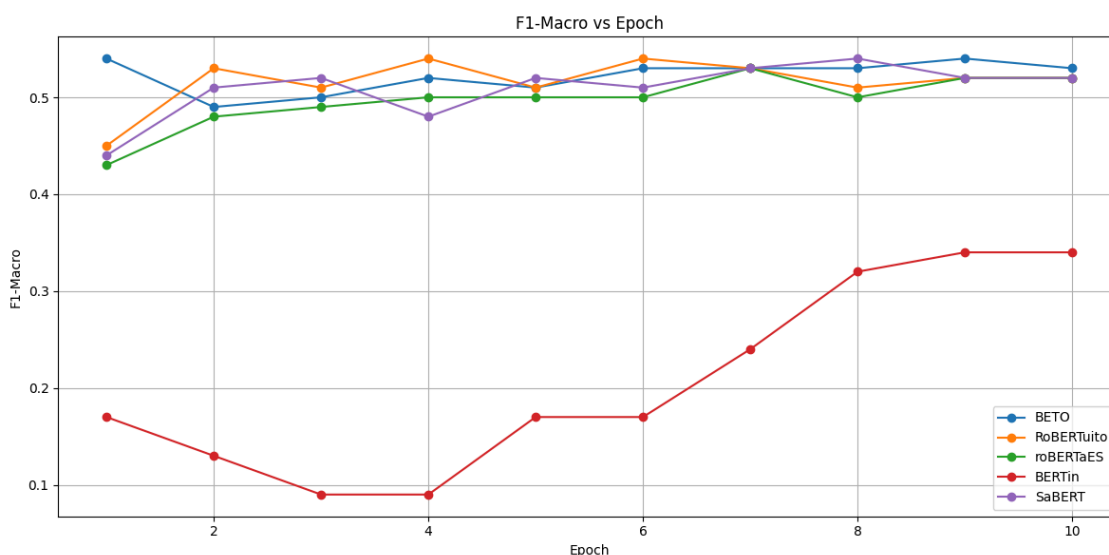


Figura 8 — Resultado de F1-macro por cada modelo basado en BERT.



5.2.2. Comparación de embeddings en español con algoritmos de clasificación supervisados

Los embeddings generados por el modelo BETO obtuvieron mejores resultados al emplear los algoritmos de clasificación SVM con 0.41 y Logistic Regression con 0.40. Estos valores de F1-macro sugieren que las representaciones semánticas producidas por BETO son más eficientemente. Por otro lado, los clasificadores basados en árboles, como Random Forest con 0.28 y XGBoost con 0.36 en F1-macro, mostraron un rendimiento inferior, lo que puede indicar una menor adaptabilidad a la estructura distribuida de estos embeddings. En tal sentido, el modelo BETO logra un rendimiento moderado, pero claramente más estable con clasificadores lineales.

Tabla 3 — Resultados de F1-macro con algoritmos supervisados y BETO.

Modelo embedding	Clasificador	F1-macro
BETO	SVM	0.41
BETO	LR	0.40
BETO	RF	0.28
BETO	XGBoost	0.36

Por otro lado, los embeddings generados del modelo RoBERTuito superan en rendimiento a los de BETO en todos los clasificadores evaluados. En particular, el uso de SVM con 0.44 y Logistic Regression con 0.43 en F1-macro, muestra una capacidad para el entendimiento de las palabras, lo cual es coherente con el hecho de que RoBERTuito ha sido entrenado con datos específicos obtenidos de redes sociales, lo que permite una mayor sensibilidad al lenguaje emocional e informal. Al igual que con BETO, los algoritmos basados en árboles Random Forest y XGBoost presentan menor efectividad, aunque en este caso XGBoost con 0.38 F1-macro tiene un comportamiento más competitivo.

Tabla 4 — Resultados de F1-macro con algoritmos supervisados y RoBERTuito.

Modelo embedding	Clasificador	F1-macro
RoBERTuito	SVM	0.44
RoBERTuito	LR	0.43
RoBERTuito	RF	0.29
RoBERTuito	XGBoost	0.38

Así mismo, el modelo SaBERT muestra un rendimiento estable y consistente, con valores similares entre SVM y Logistic Regression con 0.43 en F1-macro. A diferencia de los modelos anteriores, SaBERT presenta una mejora en el rendimiento con clasificadores no lineales, como Random Forest con 0.34 y XGBoost con 0.39 en F1-macro, esto manifiesta que sus embeddings pueden contener estructuras de representación más complejas que benefician a modelos más flexibles. Esta interpretación tiene relación con el modelo SaBERT, al estar específicamente pre-entrenado en corpus del español, generando vectores semánticos y adaptados al idioma.

Tabla 5 — Resultados de F1-macro con algoritmos supervisados y SaBERT.

Modelo embedding	Clasificador	F1-macro
SaBERT	SVM	0.43
SaBERT	LR	0.43
SaBERT	RF	0.34
SaBERT	XGBoost	0.39

5.2.3. Comparación de modelos híbridos con embeddings en español

En esta sección se explican los resultados obtenidos mediante modelos híbridos con redes neuronales recurrentes. El modelo BETO, al ser combinado con arquitecturas híbridas de redes recurrentes, muestra una mejora considerable en el rendimiento al pasar de una estructura de doble

capa bidireccional (BiLSTM + BiGRU) a una arquitectura que incluye múltiples modelos recurrentes (LSTM, BiLSTM, GRU, BiGRU) y una capa de atención. El aumento del F1-macro de 0.42 a 0.47 evidencia que una mayor diversidad en las unidades recurrentes permite capturar con mayor eficacia patrones emocionales en el texto, aprovechando la contextualización semántica. Esto sugiere que los embeddings de BETO se adaptan bien a arquitecturas complejas y profundas, mejorando la generalización del modelo.

Tabla 6 — Resultados de F1-macro con modelos híbridos y BETO.

Modelo embedding	Modelo híbrido	F1-macro
BETO	BiLSTM + BiGRU + Attention	0.42
BETO	LSTM + BiLSTM + GRU + BiGRU + Attention	0.47

Por otro lado, los resultados obtenidos al utilizar embeddings de RoBERTuito son inferiores. El modelo híbrido más complejo incluso presenta un descenso en el rendimiento (de 0.16 a 0.14), lo cual puede deberse a una incompatibilidad entre la representación semántica generada por RoBERTuito y las capas profundas de tipo recurrente. Este modelo ha sido pre-entrenado con datos de redes sociales, por lo que podría ser más adecuado para clasificadores tradicionales y menos efectivo en entornos neuronales más profundos, donde sus embeddings tienden a sobreajuste o no convergen adecuadamente. Estos resultados sugieren que RoBERTuito no es la opción óptima cuando se emplean modelos híbridos complejos.

Tabla 7 — Resultados de F1-macro con modelos híbridos y RoBERTuito.

Modelo embedding	Modelo híbrido	F1-macro
RoBERTuito	BiLSTM + BiGRU + Attention	0.16
RoBERTuito	LSTM + BiLSTM + GRU + BiGRU + Attention	0.14



Sin embargo, el modelo SaBERT evidencia un comportamiento bueno y consistente. La combinación con la arquitectura BiLSTM + BiGRU + Attention alcanza un F1-macro de 0.41, y al ampliar la red a una arquitectura híbrida con cuatro componentes recurrentes, el rendimiento asciende hasta 0.49, el más alto entre todas las configuraciones evaluadas. Esto demuestra que los embeddings generados por SaBERT se integran eficazmente con modelos neuronales profundos, especialmente aquellos que emplean mecanismos de atención. La estabilidad y rendimiento superior demuestran que SaBERT como la mejor alternativa para tareas de clasificación de emociones en español utilizando modelos híbridos avanzados.

Tabla 8 — Resultados de F1-macro con modelos híbridos y SaBERT.

Modelo embedding	Modelo híbrido	F1-macro
SaBERT	BiLSTM + BiGRU + Attention	0.41
SaBERT	LSTM + BiLSTM + GRU + BiGRU + Attention (propuesta)	0.49

5.2.4. Comparación de predicción de emociones de comentarios de Apurímac en Facebook

En esta sección se realiza la explicación de los resultados obtenidos luego de emplear diferentes modelos pre-entrenados en idioma español. Estos modelos fueron empleados en el conjunto de datos de comentarios extraídos de Facebook con relación a la región de Apurímac en Perú.

La propuesta del modelo híbrido (SaBERT + LSTM + BiLSTM + GRU + BiGRU + Attention) logró una distribución más equilibrada en la clasificación de emociones. Predice emociones menos frecuentes como anger (133), disgust (2), fear (4), y surprise (23), lo cual demuestra su capacidad para detectar clases de baja ocurrencia, aunque con limitaciones en disgust y fear. Asimismo, presenta una predicción significativa de sadness (336) y joy (1150), mientras que la clase others concentra el mayor número de clases (2436), lo cual es común en este tipo de tareas donde las emociones son ambiguas o poco representadas.



La capacidad de detectar múltiples clases sugiere que el modelo captura relaciones emocionales complejas gracias a su arquitectura profunda.




Figura 9 — Predicción de cantidad de emociones mediante la propuesta híbrida. Por otro lado, el modelo basado en TweetNLP muestra una buena predicción de las emociones obteniendo los resultados de joy (1831) y sadness (1121), superando a todos los demás modelos en estas dos categorías. También predice cantidades no despreciables en disgust (182) y algunas ocurrencias en anger (19) y fear (8), aunque no clasifica ninguna emoción como surprise. La clase others aparece con 923 clases predichas, siendo significativamente menor que en los otros modelos. Este comportamiento sugiere que TweetNLP es más efectivo en distinguir emociones explícitas como alegría y tristeza, y menos propenso a agrupar ejemplos en la categoría ambigua como Others.




Figura 10 — Predicción de cantidad de emociones con modelo TweetNLP.

Así mismo, el modelo PySentimiento tiene una distribución limitada en la predicción de emociones, concentrándose fuertemente en joy (1555) y Others (2441). Las clases predichas como anger (42), sadness (40) y surprise (6) aparecen en cantidades mínimas, y no se detectan ejemplos en disgust ni fear. Esto indica una tendencia del modelo a reducir la tarea a pocas clases dominantes, lo cual podría deberse a una sensibilidad reducida para distinguir emociones de menor frecuencia o más sutiles. La mayor cantidad de clases predichas en Others evidencia una dificultad en la clasificación de emociones.

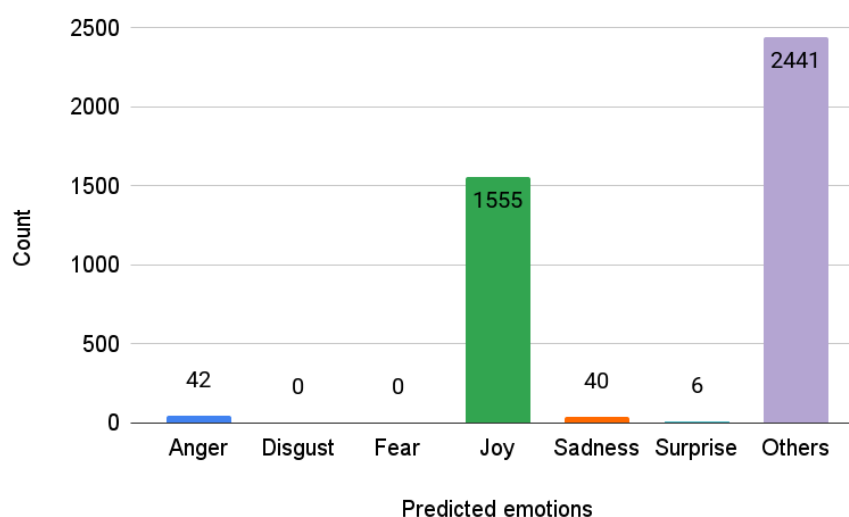


Figura 11 — Predicción de cantidad de emociones con modelo Pysentimiento.

Por último, los resultados de clasificación del modelo XML-RoBERTa muestra una mejora respecto a PySentimiento en cuanto a detección de clases de emociones. El modelo ha predicho a anger (97), sadness (116) y surprise (7), aunque sigue sin detectar disgust ni fear. La clase joy (1657) continúa siendo la más representada, seguida por una alta concentración en Others (2207). Este modelo tiene un comportamiento intermedio: logra predecir más emociones que PySentimiento, pero aún muestra debilidad para clasificar categorías emocionales menos comunes. Su rendimiento sugiere una mayor adaptabilidad semántica, pero limitada cobertura emocional.



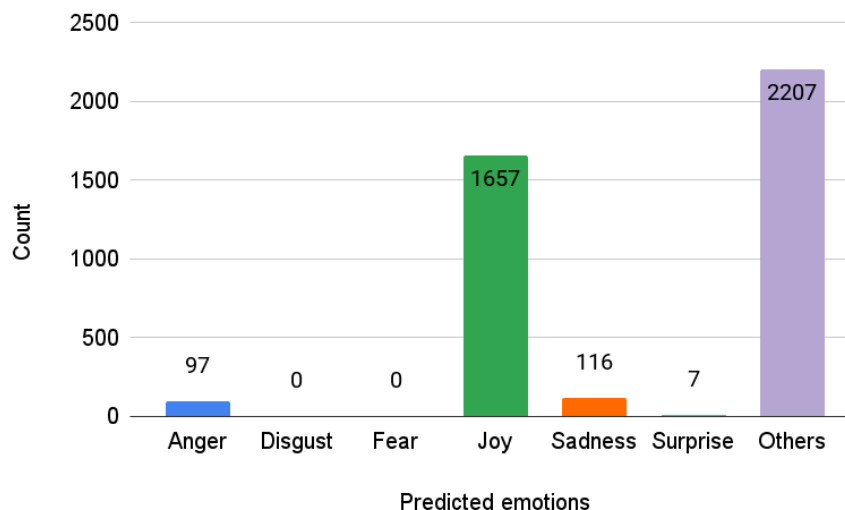


Figura 12 — Predicción de cantidad de emociones con modelo XML-Roberta.

5.2.5. Comparación de frecuencia y polaridad léxica de comentarios de Apurímac en Facebook

A continuación se muestran los resultados de las palabras frecuentes en los comentarios de Facebook de la región de Apurímac. Así mismo, se logró identificar las palabras frecuentes positivas y negativas.

La Figura de barras representa la frecuencia de aparición de las palabras más comunes en el conjunto de datos de comentarios de Facebook. Se observa que términos como "hermoso", "feliz", "fuerza", "vida", "tranquilo" y "agradezco" son los más frecuentes, con "hermoso" superando las 450 apariciones. La mayoría de estas palabras poseen una connotación positiva, lo que sugiere una tendencia del corpus hacia el uso de lenguaje afectivo favorable. También aparecen términos como "cruz", "pena", "dolor" y "protesta", que pueden tener carga emocional negativa, aunque en menor frecuencia relativa. Esta distribución refleja la variedad semántica y emocional del conjunto de datos, esto manifiesta una clave para tareas como análisis de sentimientos o clasificación de emociones.






Figura 13 — Frecuencia de palabras más utilizadas en los comentarios de Apurímac.

Por otro lado, la Figura de nubes de palabras presenta una representación visual de términos con polaridad positiva (izquierda) y polaridad negativa (derecha). El tamaño de cada palabra refleja su frecuencia relativa dentro de cada grupo polar. En la nube de palabras positivas, destacan palabras como "favor", "fiesta", "natural", "original", "admirable", y "genial", que denotan alegría, aprecio y aprobación. Estas palabras son características del lenguaje emocional positivo utilizado en contextos de celebración, reconocimiento o gratitud. En la nube de palabras negativas, predominan términos como "lamentable", "horrible", "criminal", "error", "ruin" y "fatal", asociados a emociones como tristeza, miedo o enojo. Estas palabras reflejan descontento o crítica, y pueden estar presentes en mensajes de queja, denuncia o eventos negativos.




Figura 14 — Nube de palabras positivas y negativas más frecuentes de los comentarios de Apurímac.

5.3. Discusión

El modelo híbrido propuesto, basado en SaBERT combinado con LSTM, BiLSTM, GRU, BiGRU y una capa de Attention, demostró un rendimiento adecuado en la tarea de clasificación de emociones en comparación a modelos recurrentes independientes. Este modelo no solo logró el valor más alto de F1-macro (hasta 0.49), sino que además mostró una capacidad considerable para detectar clases de emociones de baja frecuencia como *anger*, *fear* o *surprise*. La arquitectura híbrida permitió una representación más ordenada del lenguaje de emociones, integrando memorias secuenciales unidireccionales y bidireccionales con atención contextual, lo que explica resolver ante ambigüedades semánticas de palabras. Su rendimiento contrasta favorablemente frente a modelos pre-entrenados tradicionales, lo que valida la hipótesis de que combinar múltiples estructuras recurrentes mejora la sensibilidad emocional del sistema.

En ese sentido, la propuesta híbrida, modelos como RoBERTuito, XLM-RoBERTa, TweetNLP y PySentimiento evidenciaron limitaciones importantes. Aunque modelos como TweetNLP mostraron un buen desempeño al identificar emociones dominantes como *joy* y *sadness*, su cobertura emocional fue reducida, omitiendo clases como *surprise* o *disgust*. PySentimiento, por su parte, presentó una alta concentración en la clase *others*, reflejando una escasa sensibilidad a emociones menos frecuentes. Estos resultados sugieren que, si bien los modelos pre-entrenados tienen ventajas en eficiencia y adaptabilidad, no todos son igualmente efectivos para tareas finas de análisis emocional multiclase, especialmente en contextos con desbalance de comentarios expresados en Facebook.

El análisis léxico complementario, basado en la frecuencia de términos y la visualización de nubes de palabras, respalda los resultados obtenidos en la clasificación emocional. Las palabras más frecuentes tienen, en su mayoría, connotación positiva (hermoso, feliz, agradezco, vida), lo que sugiere que el conjunto de datos de Apurímac contiene una inclinación hacia el lenguaje emocional favorable. Asimismo, las nubes de palabras muestran un contraste claro entre términos positivos y negativos, siendo los primeros más diversos y



frecuentes. Esta distribución afecta directamente al rendimiento de los modelos, ya que aquellos con menor cobertura emocional tienden a sobre ajustarse a las clases dominantes. Los resultados confirman la necesidad de incorporar estrategias de balance y atención contextual para evitar sesgos semánticos en los sistemas de clasificación.

En ese sentido, los resultados evidencian que el diseño de arquitecturas neuronales especializadas, como el modelo híbrido propuesto, ofrece ventajas claras sobre soluciones estándar. La integración de múltiples componentes secuenciales y una capa de atención permite capturar mejor el lenguaje emocional en español. Asimismo, se identifican oportunidades de mejora, como el tratamiento del desbalance de clases, el ajuste fino de modelos pre-entrenados con datos emocionales específicos, y la expansión del vocabulario emocional mediante recursos externos como WordNet o ConceptNet. Además, los análisis léxicos y de desempeño multiclase son útiles para futuras optimizaciones dirigidas a aumentar la equidad, cobertura y precisión en tareas de clasificación emocional.



CAPÍTULO VI CONCLUSIONES Y RECOMENDACIONES

6.1. Conclusiones

Se logró desarrollar con éxito un modelo de redes neuronales recurrentes para el análisis de sentimientos en comentarios de Facebook relacionados con la región de Apurímac. El modelo híbrido, basado en arquitecturas avanzadas como LSTM, BiLSTM, GRU, BiGRU y capas de atención, empleó representaciones vectoriales generadas con embeddings entrenados en español (SaBERT y BETO), logrando una comprensión del lenguaje y una clasificación de sentimientos, validada por métricas superiores a modelos tradicionales.

El modelo propuesto permitió clasificar de manera eficaz los sentimientos afectivos de los comentarios, asignando emociones específicas como alegría, tristeza, enojo, miedo, disgusto y sorpresa, que luego fueron agrupadas en categorías de sentimiento positivo o negativo. Las métricas obtenidas particularmente el F1-macro evidencian una alta capacidad predictiva, lo que confirma la utilidad del sistema para tareas de monitoreo de sentimientos aplicado a contenidos de comentarios sobre Apurímac.

Mediante un análisis léxico detallado del conjunto de datos de comentarios recolectado desde Facebook, se identificaron las palabras más frecuentes utilizadas por los usuarios en relación con Apurímac, siendo las más destacadas Hermoso, Saludo, Felicitación, Lindo, Tierra y Apurímac (ver Figura 13). Este hallazgo permitió reconocer temas recurrentes, intereses colectivos y áreas de preocupación social en los comentarios de la región de Apurímac, facilitando así una información cuantitativa de información pública de la región.

Se logró construir una clasificación efectiva de términos con polaridad de sentimientos positiva (fiesta, favor, admirable, original, natural, etc.) y negativa



(error, lamentable, horrible, etc.) mediante una combinación de análisis léxico, puntuaciones de polaridad con VADER y validación contextual a través de embeddings. La visualización de estos resultados en forma de nubes de palabras (ver Figura 14) proporcionó una representación clara de los sentimientos predominantes en los comentarios relacionados a Apurímac, ofreciendo una herramienta semántica valiosa para el análisis de percepción social, opinión pública y estudios de sentimientos en entornos de la región de Apurímac.

6.2. Recomendaciones

Se recomienda continuar con nuevos experimentos que permitan mejorar las métricas de evaluación del modelo propuesto, tales como precisión, recall y F1-macro, explorando ajustes en la arquitectura neuronal, el número de épocas de entrenamiento, técnicas de regularización y estrategias de atención híbridas. Asimismo, es fundamental ampliar la base de datos de entrenamiento mediante la búsqueda y creación de nuevos conjuntos de datos etiquetados en idioma español, que incluya variedad temática, expresiones emocionales y diversidad de comentarios relacionados a la región de Apurímac. Esto permitirá incrementar la robustez del modelo, mejorar su capacidad de generalización y adaptarlo a distintos contextos lingüísticos del idioma español.



REFERENCIAS BIBLIOGRÁFICAS

- AGUILAR SANCHEZ, A. y FLORES MORAN, G., 2018. *INSTITUTO NACIONAL DE ESTADÍSTICA E INFORMÁTICA FRANCISCO COSTA APONTE* [en línea]. 10 enero 2018. S.l.: s.n. [consulta: 10 agosto 2025]. Disponible en: https://www.inei.gob.pe/media/MenuRecursivo/publicaciones_digitales/Est/Lib1557/03TOMO_01.pdf.
- ASOCIADOS, C., 2022. *¿Qué es la rueda de las emociones?* [en línea]. 2022. S.l.: s.n. Disponible en: <https://www.cuniasociados.com/que-es-la-rueda-de-las-emociones/>.
- CAMBRIA, E., SCHULLER, B., XIA, Y. y HAVASI, C., 2013. New Avenues in Opinion Mining and Sentiment Analysis. *IEEE Intelligent Systems*, vol. 28, no. 2, pp. 15-21. DOI 10.1109/MIS.2013.30.
- CHUNG, J., GULCEHRE, C., CHO, K. y BENGIO, Y., 2014. Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. *arXiv preprint arXiv:1412.3555* [en línea], Disponible en: <https://arxiv.org/abs/1412.3555>.
- CPI, 2024. Perú: Población 2024. [en línea]. S.l.: CPI Research. 5. Disponible en: <https://cpi.pe/images/upload/paginaweb/archivo/23/PER%C3%A9%20POBLACI%C3%93N%202024.pdf>.
- GUTIÉRREZ, C. y ANDRÉS, O., 2019. *Desarrollo de una aplicación web para la identificación de oportunidades de emprendimiento e inversión utilizando análisis de sentimientos de Tweets* [en línea]. 2019. S.l.: s.n. Disponible en: <http://repository.unipiloto.edu.co/handle/20.500.12277/7778>.
- HELTHON, 2023. Redes Sociales más Usadas Perú (agosto 2024). *Data Trust Perú* [en línea]. [consulta: 10 agosto 2025]. Disponible en: <https://www.datatrust.pe/social-media/ reporte-redes-sociales-peru/>.
- HERNÁNDEZ-SAMPIERI, R. y MENDOZA-TORRES, C.P., 2018. *Metodología de la investigación. Las rutas cuantitativa, cualitativa y mixta*. México: Editorial Mc Graw Hill Education. ISBN 78-1-4562-6096-5.
- IBÁÑEZ, N. y DAMMAN, G., 2010. Indicadores de desertificación en Apurímac: relaciones espaciales entre degradación de suelos y presiones antrópicas. *Zonas Áridas*, pp. 214-229.
- IBM, [sin fecha]. *¿Qué son las redes neuronales recurrentes?* [en línea]. S.l.: s.n. Disponible en: <https://www.ibm.com/es-es/topics/recurrent-neural-networks>.
- KASTRATI, Z., DALIPI, F., IMRAN, A.S., PIREVA NUCI, K. y WANI, M.A., 2021. Sentiment Analysis of Students' Feedback with NLP and Deep Learning: A Systematic Mapping Study. *Applied Sciences*, vol. 11, no. 9, pp. 3986. DOI 10.3390/app11093986.
- LIU, B., 2015. *Sentiment Analysis* [en línea]. S.l.: Cambridge University Press. Disponible en: <https://www.cambridge.org/core/books/sentiment-analysis/3F0F24BE12E66764ACE8F179BCDA42E9>.
- LIU, B., 2020. *Sentiment Analysis: Mining Opinions, Sentiments, and Emotions*. S.l.:



Cambridge University Press. Studies in Natural Language Processing, ISBN 978-1-108-48637-8.

- MAMANI-COAQUIRA, Y., IBARRA, M.J., VILCA, E.M., RAMOS, E.O. y CRUZ, M.A., 2021. Identificar Sentimientos en Cuarentena por la Covid-19 mediante Clasificador Léxico y Aprendizaje Supervisado. *Proceedings*. S.l.: s.n., pp. 618-631.
- MATHWORKS, [sin fecha]. *Redes neuronales convolucionales* [en línea]. S.l.: s.n. Disponible en:
<https://es.mathworks.com/discovery/convolutional-neural-network-matlab.html>.
- MINAEE, S., KALCHBRENNER, N., CAMBRIA, E., NIKZAD, N., CHENAGHLOU, M. y GAO, J., 2021. Deep Learning–based Text Classification: A Comprehensive Review. *ACM Computing Surveys*, vol. 54, no. 3, pp. 62:1-62:40. DOI 10.1145/3439726.
- NASUKAWA, T. y YI, J., 2003. Sentiment analysis: capturing favorability using natural language processing. *Proceedings of the 2nd international conference on Knowledge capture*. S.l.: ACM, pp. 70-77. DOI 10.1145/945645.945658.
- NAVARRO, L.F.S., 2022. Aprobación del presidente de Perú basado en análisis de sentimientos en Twitter. *TECHNO REVIEW. International Technology, Science and Society Review*, vol. 12, no. 1, pp. 1-13. DOI 10.37467/revtechno.v11.4396.
- ORÉ ARROYO, C., 2025. Día de las redes sociales: ¿Cuántos peruanos las utilizan y cuál lidera sus preferencias? *infobae* [en línea]. [consulta: 10 agosto 2025]. Disponible en:
<https://www.infobae.com/peru/2025/06/30/dia-de-las-redes-sociales-cuantos-peruanos-las-utilizan-y-cual-lidera-sus-preferencias/>.
- RAMOS-GALARZA, C., 2021. Editorial: Diseños de investigación experimental. *CienciAmérica*, vol. 10, no. 1, pp. 1-7. ISSN 1390-9592. DOI 10.33210/ca.v10i1.356.
- REYES-OLIVO, M. y SOTO, R.M., 2020. Potencialidades productivas del sector Agronegocios en la región Apurímac, Perú. Oportunidades para el Comercio Internacional. *Ciencia Latina Revista Científica Multidisciplinar*, vol. 4, no. 2, pp. 1288-1301. ISSN 2707-2215. DOI 10.37811/cl_rcm.v4i2.155.
- ROMERO, J., DAFONTE, C., GÓMEZ, Á. y PENOUSAL, F., 2007. *INTELIGENCIA ARTIFICIAL Y COMPUTACIÓN AVANZADA*. S.l.: Consejo Editorial de la Fundación Alfredo Brañas.
- ROUHIAINEN, L., 2018. *Inteligencia Artificial: 101 cosas que debes saber hoy sobre nuestro futuro*. S.l.: Editorial Planeta. ISBN 978-84-17568-08-5.
- SÁNCHEZ DEL HOYO, R., 2019. *Análisis de sentimientos con Twitter: turismo y política electoral* [en línea]. 2019. S.l.: s.n. Disponible en:
<https://idus.us.es/handle/11441/90023>.
- WANG, Y., SONG, W., TAO, W., LIOTTA, A., YANG, D., LI, X., GAO, S., SUN, Y., GE, W., ZHANG, Wei y ZHANG, Wenqiang, 2022. A systematic review on affective computing: emotion models, databases, and recent advances. *Information Fusion*, vol. 83–84, pp. 19-52. DOI 10.1016/j.inffus.2022.03.009.



- WAYNET, 2025. Estadísticas De Redes Sociales Perú 2025 - Marketing Digital. [en línea]. [consulta: 10 agosto 2025]. Disponible en: <https://www.way2net.com/2025/07/estadisticas-redes-sociales-peru-2025/>.
- WIKIPEDIA, 2022. *Recurrent neural network* [en línea]. 2022. S.l.: s.n. Disponible en: https://it.wikipedia.org/w/index.php?title=Rete_neurale_ricorrente&oldid=128372704.
- YADAV, A. y VISHWAKARMA, D.K., 2020. Sentiment analysis using deep learning architectures: a review. *Artificial Intelligence Review*, vol. 53, no. 6, pp. 4335-4385. DOI 10.1007/s10462-019-09794-5.
- YADOLLAHI, A., SHAHRAKI, A.G. y ZAIANE, O.R., 2017. Current State of Text Sentiment Analysis from Opinion to Emotion Mining. *ACM Computing Surveys*, vol. 50, no. 2, pp. 25:1-25:33. DOI 10.1145/3057270.
- ZÁRATE CALDERÓN, G.H., 2022. *Análisis de sentimiento en información de medios periodísticos y redes sociales mediante redes neuronales recurrentes* [en línea]. PhD Thesis. S.l.: Pontificia Universidad Católica del Perú. Disponible en: <https://tesis.pucp.edu.pe/repositorio/handle/20.500.12404/21525>.
- ZAVALA, A.A., 2023. Impacto de la exportación minera y de la producción en el crecimiento económico de la región Apurímac durante el periodo 2004-2016. *Industrial Data*, vol. 26, no. 1, pp. 153-177. ISSN 1810-9993. DOI 10.15381/idata.v26i1.19666.
- ZHANG, L., WANG, S. y LIU, B., 2018. Deep learning for sentiment analysis: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, vol. 8, no. 4, pp. e1253.

