


L U M B R E



Clasificación de texto

Grado: 7

Materia: Procesamiento de Lenguaje Natural · Inteligencia Artificial

11/10/2026

Antes de empezar

Asignar una etiqueta a un texto —positivo o negativo, deporte o política— es la tarea más extendida del procesamiento del lenguaje. Va del vector de características al modelo, con una evaluación honesta que no confunda exactitud con utilidad.

QUÉ APRENDERÁS

- Construir clasificadores de sentimiento y tópicos a partir de datos etiquetados, evaluando su rendimiento con métricas adecuadas.

Clasificación de texto

De palabras a etiquetas

Clasificar texto es decidir una etiqueta a partir de palabras. La receta —representar, aprender, evaluar— es estable; lo que cambia son las trampas del dato: desbalance, contexto y expresión figurada.

VIDEO

Análisis de sentimientos con BERT en Python

Vídeo en español que afina un modelo de lenguaje preentrenado para clasificar la polaridad de textos.



Escanea para verlo en Lumbre


<https://www.youtube.com/watch?v=mvh7DV84mr4>

El flujo de trabajo

- Recolectar textos con sus etiquetas y dividir en entrenamiento y prueba.
- Representar el texto: bolsa, TF-IDF o embeddings.
- Entrenar un modelo y medirlo sobre datos no vistos.

Representar el texto

Se puede partir de TF-IDF, rápido e interpretable, o de embeddings que captan semejanza. La elección condiciona el modelo: los dispersos casan bien con lineales; los densos, con redes.



Un clasificador convierte texto crudo en una decisión: positivo, negativo o de un tópico dado.

Modelos clásicos

Regresión logística, máquinas de vectores soporte o ingenuos bayesianos resuelven mucho con pocos datos y gran velocidad. Suelen ser un buen referente antes de tirar de profundidad.

Enfoques profundos

CNN y RNN sobre embeddings aprenden patrones que los modelos lineales pierden, sobre todo en textos largos o con estructura. Cuestan más datos y cómputo, y no siempre ganan.

Transformers y ajuste fino

Hoy se parte de un modelo de lenguaje preentrenado y se afina para la tarea: suele batir a lo demás con pocas muestras. El coste es memoria y latencia en inferencia.

Sentimiento y su trampa

Detectar polaridad choca con la ironía, los dobles sentidos y el contexto. «Qué bien, otra vez lloviendo» engaña a un modelo que solo mira palabras sueltas.

Datos desbalanceados

Si el 95 % de las reseñas son positivas, predecir siempre positivo da alta exactitud inútil. Conviene re-muestrear, ponderar la pérdida o mirar precisión por clase.

Evaluar con criterio

Además de la exactitud, importan precisión y exhaustividad por clase y la matriz de confusión. En multi-clase, el F1 macro trata a todas las clases con igualdad.

Errores que enseñan

Revisar los textos mal clasificados revela si falta dato, si la etiqueta es dudosa o si el modelo ignora palabras clave. La mejora suele salir de ahí, no de tocar hiperparámetros.

Errores frecuentes

- Celebrar una exactitud del 95 % en un conjunto donde la clase minoritaria —la que interesa— casi nunca se acierta.
- Mezclar entrenamiento y prueba al ajustar el preprocesado sobre todos los datos: métrica inflada que luego no se repite.
- Ignorar negaciones e ironía y dejar frases como «nada bien» a merced de las palabras sueltas.

Ejemplo resuelto: clasificar reseñas de cine

Dispones de 10 000 reseñas etiquetadas como positivas o negativas y quieres un detector de sentimiento fiable:

1. Divides en entrenamiento y prueba y compruebas el balance de las clases.
2. Transformas el texto con TF-IDF como base rápida e interpretable.
3. Entrenas una regresión logística y miras precisión, exhaustividad y F1 por clase.
4. Ajustas un modelo preentrenado y lo comparas con la base usando el mismo F1 macro.
5. Revisas los falsos positivos: si abunda la ironía, añades ejemplos de ese estilo y repites.

¿Para qué sirve en la realidad?

Las marcas vigilan su reputación en redes, las tiendas de aplicaciones priorizan reseñas negativas y las encuestas clasifican miles de respuestas abiertas: todo eso es clasificación de texto desplegada.

1. En un clasificador de sentimiento con clases muy desbalanceadas, la exactitud global engaña porque:

- ☐ mide solo el tamaño del vocabulario
- ☐ predecir siempre la clase mayoritaria la dispara sin resolver la tarea
- ☐ depende del número de épocas
- ☐ no usa embeddings

2. Ajustar fino un modelo de lenguaje preentrenado suele funcionar mejor con pocas muestras etiquetadas que entrenar una red desde cero.

- ☐ Verdadero
- ☐ Falso

ACTIVIDAD INTERACTIVA DISPONIBLE EN LUMBRE

3. Clasificación texto



4. Ordena las etapas de un proyecto de clasificación de texto:

Elementos:

- reunir textos con sus etiquetas y dividir
- convertir el texto en TF-IDF o embeddings
- ajustar el modelo sobre entrenamiento
- medir con F1 y matriz sobre prueba

Etiquetar	. . .
Representar	. . .
Entrenar	. . .
Evaluar	. . .

Análisis de sentimiento https://en.wikipedia.org/wiki/Sentiment_analysis Clasificación de la polaridad de textos.

5. Une cada concepto de clasificación de texto con su descripción.

5.	representación dispersa que penaliza las palabras frecuentes	-----
5.	representación densa que capta semejanza semántica	-----
5.	métrica que pondera todas las clases con igual peso	-----
5.	tabla que revela qué clases se confunden entre sí	-----

Opciones: tf-idf · embeddings · f1 macro · matriz de confusion

De palabras a etiquetas

Clasificación de texto

Flujo

etiquetar datos

entrenar y medir

Representación

tf-idf disperso

embeddings densos

Modelos

lineales de referencia

transformers afinados

Evaluación

precision por clase

matriz de confusion

El mapa mental interactivo es interactivo en la versión online.



Clasificación de documentos https://en.wikipedia.org/wiki/Document_classification

Panorama de la tarea y sus variantes: sentimiento, tópicos, intención.

6. Tu clasificador de reseñas ignora la ironía y falla en frases como «menuda maravilla de vuelo». ¿Qué cambiarías: datos, representación o modelo? Justifica.

Referencia curricular

Grado:	7
Materia:	Procesamiento de Lenguaje Natural · Inteligencia Artificial

Versión interactiva completa (con actividades, videos y autoevaluación):



<https://univ.lumbre.lat/object/cdia-nlp-004-clasificacion-de-texto>

Material educativo generado desde Lumbre · lumbre.lat