

# Análisis de los comentarios en español de usuarios de Facebook para la clasificación de publicaciones utilizando técnicas inteligentes

Tesina de Licenciatura en Informática

Alumnos: Gianetto, Emiliano Ariel

Saporiti, Lucía

Director: Dr. Hasperué, Waldo

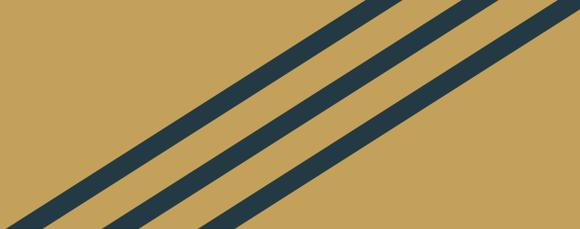
- 
- 1. Introducción**
  2. Redes Sociales
  3. Procesamiento de Lenguaje Natural
  4. Análisis de Sentimientos
  5. Desarrollo propuesto
  6. Estudio realizado
  7. Conclusiones y trabajos futuros
- 

# Motivación

- **Redes sociales** son cada vez más utilizadas
- Poseen **millones** de usuarios día a día
- La interacción se traduce en **contenido**
- Mediante **técnicas** de Procesamiento de Lenguaje Natural y Minería de Datos se realiza el **Análisis de Sentimientos**
- Se analiza y obtiene **información** de interés
- **Actualmente** se investiga Análisis de Sentimientos
- La mayoría de los estudios son aplicados sobre textos en **inglés**
- Decidimos investigar y aplicar sobre textos en **español**

# Objetivos

- Estudiar y aplicar **técnicas** de procesamiento de **lenguaje natural** para transformar los comentarios de una red social y luego analizarlos.
- Estudiar y evaluar la **performance** de las técnicas de clasificación estudiadas, planteando diversos escenarios de prueba.
- Implementar un **prototipo de aplicación** que, a partir de la opinión del usuario sobre comentarios, permita realizar un filtrado automático y muestre solo aquellos que puedan resultar de su interés.



1. Introducción

## **2. Redes Sociales**

3. Procesamiento de Lenguaje Natural

4. Análisis de Sentimientos

5. Desarrollo propuesto

6. Estudio realizado

7. Conclusiones y trabajos futuros



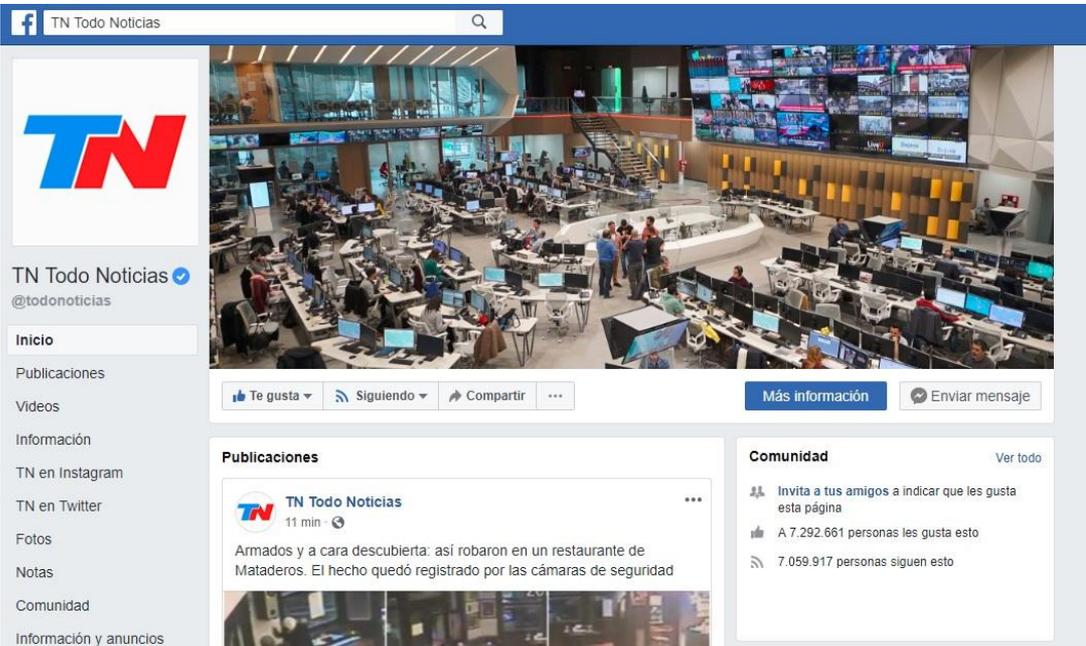
# ¿Qué son las redes sociales?

- Conjunto de **grupos vinculados** unos a otros a través de relaciones sociales, y que tienen como fin la **interacción** de dos o más **actores**.
- En las **plataformas de Internet**, las personas interactúan a través de **perfiles** creados por ellos mismo, donde:
  - **comparten** sus fotos, videos, historias, eventos o pensamientos,
  - se **reúnen** para hablar, compartir ideas, hacer nuevos amigos y **socializar**,
  - **establecen** alguna relación y que mantienen **intereses** y **actividades** en común o se encuentran interesados en **explorar** los intereses y las actividades de otros usuarios.

# Facebook

- Lanzado el 4 de febrero de **2004**. En español desde febrero de **2008**.
- Marzo de **2018**, contaba con más de **2200 millones de usuarios activos**.
- Inicialmente, para **estudiantes de Harvard**. Desde 2006, para cualquier persona mayor de **13 años**.
- **Nombre**: directorios de fotos personales que se entregan a estudiantes universitarios estadounidenses.
- **Acceder** desde una amplia gama de **dispositivos**.
- **Crear** un perfil personalizado: nombre, ocupación, escuelas, etcétera.
- **Utilizar** para asociar cuentas en otras redes sociales.

# Servicios de Facebook

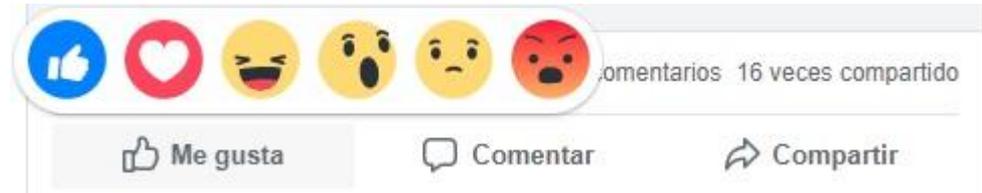


The screenshot shows the Facebook profile of 'TN Todo Noticias'. The profile picture is a large image of a newsroom with many people working at desks with computers. The page header includes the Facebook logo, the name 'TN Todo Noticias', and a search icon. Below the header is a navigation menu with options like 'Inicio', 'Publicaciones', 'Videos', 'Información', 'TN en Instagram', 'TN en Twitter', 'Fotos', 'Notas', 'Comunidad', and 'Información y anuncios'. The main content area features a post from 'TN Todo Noticias' with a video thumbnail and text: 'Armados y a cara descubierta: así robaron en un restaurante de Mataderos. El hecho quedó registrado por las cámaras de seguridad'. To the right of the post is a 'Comunidad' section showing 'Invita a tus amigos a indicar que les gusta esta página' and 'A 7.292.661 personas les gusta esto'.

- **Grupos y páginas:** usuarios con **intereses comunes** o que puedan recurrir a ellos en **búsqueda** de algo puntual. Los **grupos** pueden ser públicos, cerrados o secretos y cualquier miembro puede añadir archivos. Las **páginas** son públicas y su administrador es el único que puede realizar publicaciones.

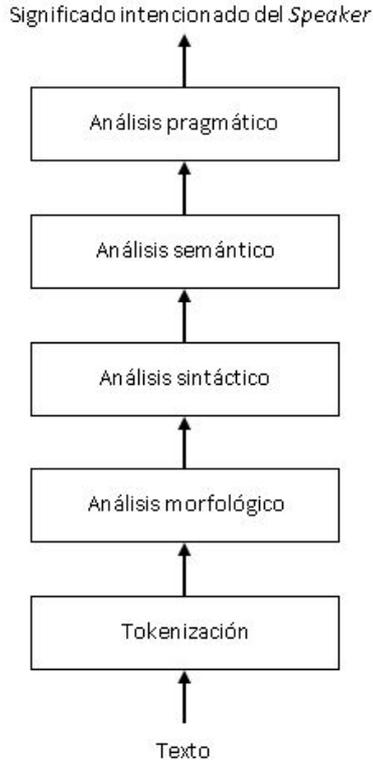
# Servicios de Facebook

- **Botón «Me gusta»:** parte inferior de cada publicación o comentario hechos por los usuarios, **valorando su contenido**. También hay “**reacciones**”, permitiendo al usuario elegir el **nivel de su agrado** agregando las opciones “Me encanta”, “Me divierte”, “Me asombra”, “Me entristece” y “Me enoja”.



- 
- 
1. Introducción
  2. Redes Sociales
  - 3. Procesamiento de Lenguaje Natural**
  4. Análisis de Sentimientos
  5. Desarrollo propuesto
  6. Estudio realizado
  7. Conclusiones y trabajos futuros

# Procesamiento de Lenguaje Natural



- Ayuda a las computadoras a **comprender, interpretar y manipular** el lenguaje humano.
- **Comprensión y procesamiento** asistido de información para determinadas tareas.
- **Descompone** el proceso del análisis en varias **etapas**.
  - Diferencias entre ***sintaxis, semántica y pragmática***.

# Preprocesamiento de texto

- Mejora las **condiciones** del texto y la **efectividad** de los procesos futuros.
- Existen imperfecciones, errores, abreviaturas, jerga, o simplemente **datos que no nos interesan**.
- **Convertir** un texto sin procesar, en una **secuencia** bien definida de elementos (caracteres, palabras y oraciones), que serán utilizadas en etapas posteriores.

# Tokenización

- **Convertir** una secuencia de caracteres en una secuencia de tokens.
- Métodos para identificarlos:
  - Expresiones regulares
  - Delimitadores (caracteres de separación)
  - Definición explícita por un diccionario

# Técnicas de transformación de datos

- **Bolsa de palabras (BoW - Bag of Words):** estructura de datos con las palabras y la cantidad de ocurrencias que tienen en un texto. Ignora la posición de la palabra en el documento.
- **Frecuencia de término - Frecuencia de documento inversa (TF-IDF - Term Frequency - Inverse Document Frequency):** producto de la frecuencia de un término dentro de un texto (local) y qué tan específica es la palabra, tomando en cuenta el total de los textos (global).
- **Negaciones (Negations):** analiza la presencia y alcance de la negación dentro de una frase, y evalúa cómo altera la opinión.
- **Reconocimiento de entidad con nombre (NER - Named Entity Recognition):** etiqueta los elementos atómicos de la oración asignando categorías como: persona, lugar, entre otros.

# Aplicaciones y ejemplos

- Descubrimiento de tópicos en colecciones de textos.
- Conversión de voz a texto, de texto a voz, y traducción automática.
- Resumen del documento.
- Correos electrónicos *spam*.
- **Análisis de sentimientos** (estado de ánimo, opinión).

- 
1. Introducción
  2. Redes Sociales
  3. Procesamiento de Lenguaje Natural
  - 4. Análisis de Sentimientos**
  5. Desarrollo propuesto
  6. Estudio realizado
  7. Conclusiones y trabajos futuros
- 

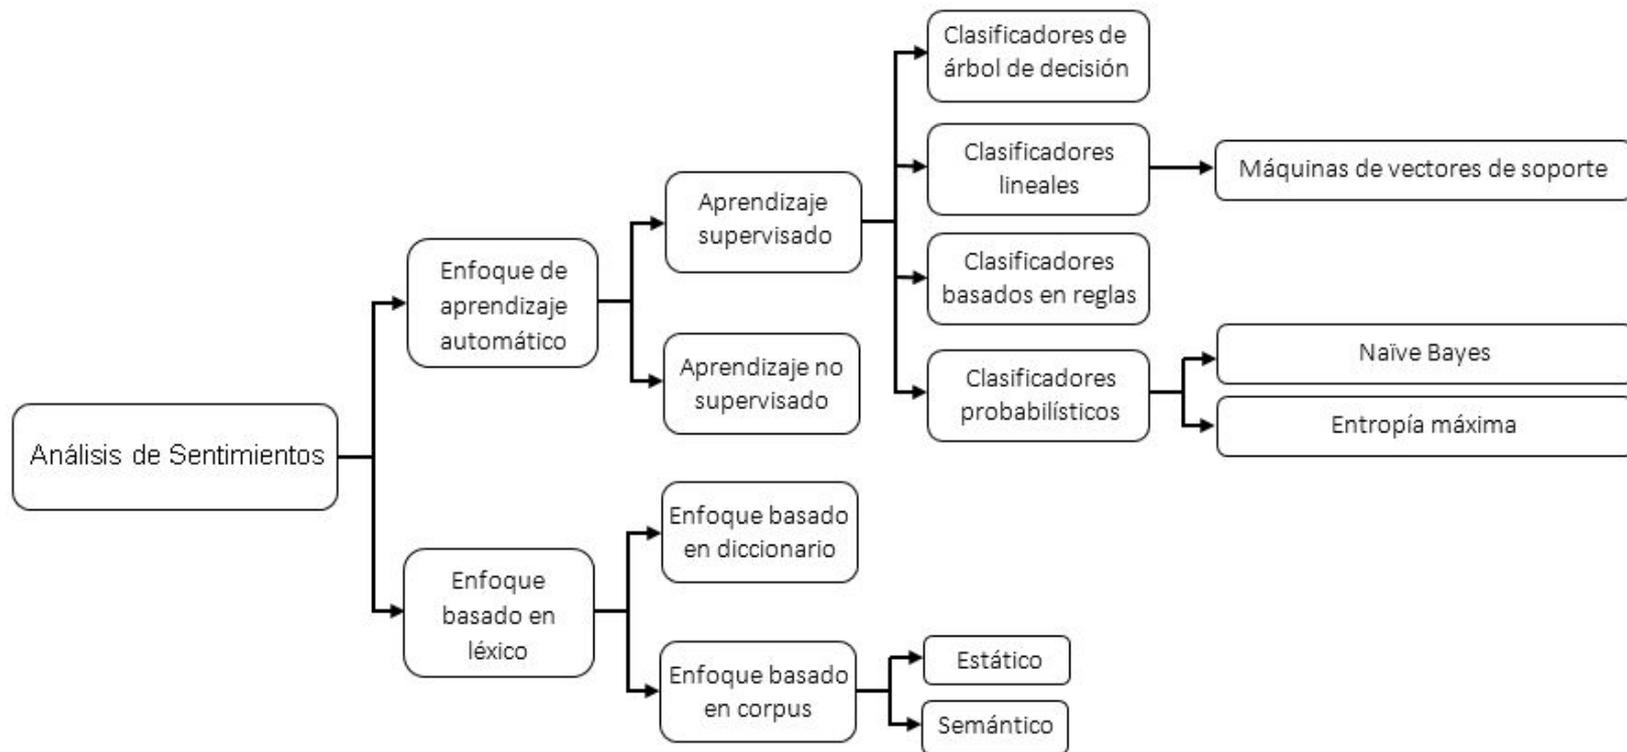
# Minería de datos

- Gran cantidad de datos, de rápido crecimiento, recopilada y almacenada en grandes y numerosos repositorios de datos → procedimiento **manual** es propenso a **errores, costoso y lento**.
- Necesidad de **obtener información útil** y conocimiento que pueda ser utilizado para la creación de diversas aplicaciones a partir del crecimiento exponencial que están sufriendo los datos.
- Resultado de la **evolución** natural de la tecnología de la información.

# Análisis de Sentimientos

- **Estudio computacional** de opiniones, sentimientos, emociones y subjetividad expresadas en textos hacia una **entidad**.
- Su objetivo es **determinar** opiniones, **identificar** los sentimientos que expresa un escritor mediante su texto, y luego clasificar su **polaridad**.
- **Rapidez y espontaneidad** en que se obtiene la información ya que se realiza en el mismo momento en que se minan las opiniones.
- Realizar un seguimiento del **impacto**, comparando las métricas de **antes** y **después** del acontecimiento de un evento o noticia.
- **Dominios posibles**: productos, servicios, atención médica, artículos de noticias, eventos sociales, elecciones políticas, etcétera.

# Técnicas para el Análisis de Sentimientos



# Aprendizaje supervisado

- Clasificadores **probabilísticos** o **generativos**

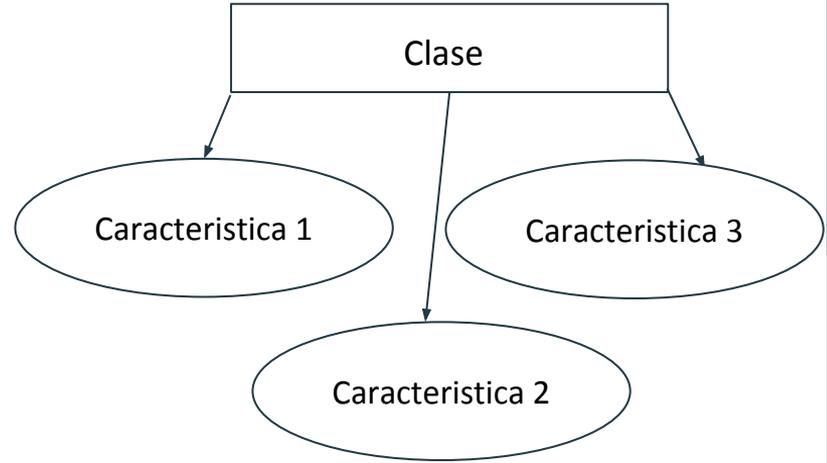
- Permiten la **descripción** del conjunto de observación a través de funciones de **probabilidad**.
- **Describen** cómo se generan los datos.
- Se pueden usar para imputar datos faltantes, comprimir el conjunto de datos o generar datos no vistos.

- Clasificadores **lineales** o **discriminativos**

- **Identificar** a qué clase pertenece un objeto por medio de **funciones discriminativas** que mapean directamente la observación al valor de una etiqueta de clase.
- **Superiores** en predicción, pero se obtiene **poco conocimiento** de los datos y cómo se generan

# Naïve Bayes

- Más simple, más utilizado, fácil de construir.
- Asume **independencia** entre características.
- Útil para **conjuntos** de datos muy **grandes**.
- Funciona bien en **múltiples clases**.
- Funciona mejor con variables de entrada nominales que con numéricas.
- Utiliza el **Teorema de Bayes** para predecir la probabilidad que un conjunto de características determinado pertenezca a una etiqueta en particular.

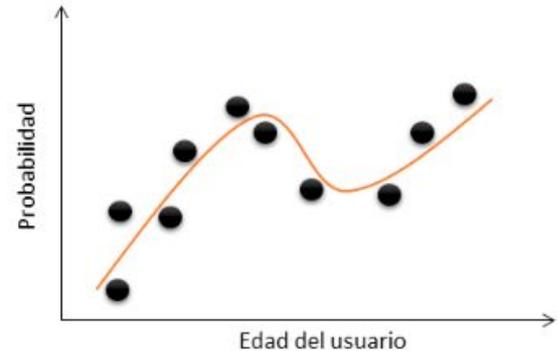
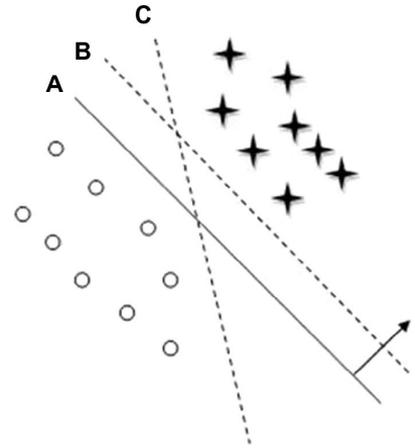


# Entropía Máxima

- Pertenece a la clase de modelos exponenciales.
- No supone que las **características** sean condicionalmente independientes entre sí, toma en cuenta la **correlación** de las mismas.
- Predecir resultados posibles de una variable **distribuida categóricamente**.
- Estima las distribuciones de probabilidad de acierto a partir de datos usando **optimización iterativa**.
  - Comienza con **ponderaciones** previas **mínimas** y se optimiza para encontrar pesos que **maximicen** la probabilidad de los datos de entrenamiento.
- Aprendizaje es más lento que Naïve Bayes, y por lo tanto puede no ser apropiado dada una gran cantidad de clases para aprender.

# Máquinas de Vectores de Soporte

- Representa los puntos de muestra en el espacio.
- Separa de forma óptima las clases mediante un hiperplano de separación al que se llama **vector soporte**.
- Los datos de texto son ideales, ya que pocas características son irrelevantes, pero tienden a correlacionarse entre sí.
- **Funciones Kernel**. Resuelven el problema de clasificación trasladando los datos a un espacio donde el hiperplano de solución es lineal. La técnica se entrena con una serie de datos de prueba.



# Enfoque basado en léxico

Se basa en una una colección de términos de sentimiento conocidos y precompilados. Existen palabras que expresan una opinión **comparativa** sobre más de una entidad. Además hay expresiones o modismos, que forman un **léxico de opinión**.

- **Basado en el diccionario:** fácil y rápido para encontrar una gran cantidad de palabras de opinión y luego sus sinónimos y antónimos. Incapaz de encontrar palabras con el dominio específico del contexto.
- **Basado en corpus:** ayuda a resolver el problema de encontrar palabras de opinión específicas del contexto. Sus métodos dependen de patrones sintácticos o que ocurren junto con una lista de palabras de opinión.

# Herramientas actuales

- **Text Analytics** (Microsoft): procesamiento de lenguaje natural avanzado sobre texto sin formato.
- **Google Cloud Platform** (Google) (Beta): servicios de aprendizaje automático con modelos ya preparados y está basado en redes neuronales.
- **Watson** (IBM): procesamiento del lenguaje natural, recuperación de información, representación del conocimiento, aprendizaje automático.
- Productos de caja negra, reciben datos y devuelven resultados.
- No es posible hacer uso del contexto.
- Google y Microsoft, no son gratuitos.
- Su uso no es amigable e intuitivo para el usuario final.

- 
1. Introducción
  2. Redes Sociales
  3. Procesamiento de Lenguaje Natural
  4. Análisis de Sentimientos
  - 5. Desarrollo propuesto**
  6. Estudio realizado
  7. Conclusiones y trabajos futuros
- 

# Desarrollo propuesto

- **Recolectar comentarios** conectándose con la API de Facebook y almacenarlos en una base de datos.
- **Etiquetar** un conjunto de comentarios de manera personal.
- **Analizar** el corpus, implementando un preprocesamiento del mismo.
- **Entrenar y aplicar modelos** basados en las técnicas de clasificación.
- **Evaluar y comparar el rendimiento** de los diversos modelos.

# Arquitectura de la aplicación



**Interfaz gráfica.** Nivel más alto de la aplicación. Captura la interacción del usuario y muestra la información.

**Funcionalidad.** Procesa las peticiones de la capa superior y obtiene la información de la capa inferior.

**Información.** Almacena y recupera información de la base de datos.

# Descripción y funcionamiento - Recolección

The screenshot shows a web application interface with a sidebar on the left and a main content area. The sidebar has three items: 'Recoleccion' with a list icon, 'Etiquetado' with a tag icon, and 'Resultados' with a home icon. The main content area is titled 'Recolección' and displays the following statistics:

- Total de publicaciones: 569
- Total de comentarios: 270279
- Cantidad de comentarios etiquetados: 3000

Below the statistics, there is a form for data collection. It includes a dropdown menu for 'Tipo de recolección:' set to 'Por comentarios'. There are two input fields: one containing 'todonoticias' and another containing '5000'. A blue button labeled 'Recolectar' is positioned below the input fields.

- Se comunica con API
- Recolecta datos
- Posee corte de control
- Almacena todo en la base de datos

# Descripción y funcionamiento - Etiquetado

Recoleccion 

Etiquetado 

Resultados 

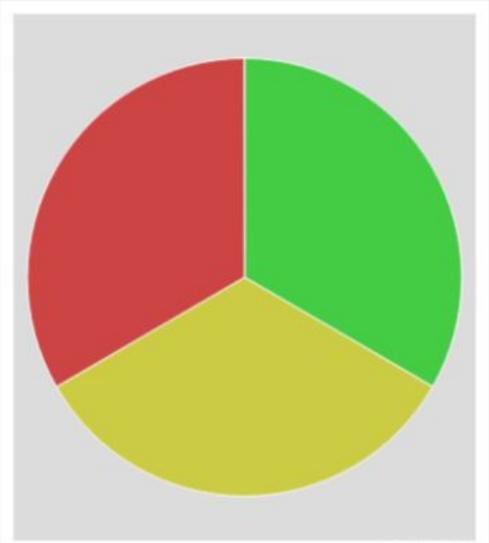
## Etiquetado

VIVO - Tensión en el Congreso a minutos de la sesión clave por la reforma previsional - #TNLive

Minitra Usá la infantería para llevarles a estos revoltosos y delincuentes y que limpien las calles



**Total de comentarios: 270279**  
**Cantidad de comentarios etiquetados: 3000**



Highcharts.com

# Cambio de rumbo

- Utilizar **reacciones** de usuarios sobre las publicaciones para **complementar** el análisis del texto de su **comentario**.
- **Cambios** en la política de **permisos** de la API de Facebook.
- Imposible obtener la información del **usuario** que generó cada **reacción**.
- Imposible obtener **reacciones** a los **comentarios**.
- Conjunto de comentarios etiquetados **manualmente**.
- Resultados **dependen** de la opinión propia de los tesisistas.
- Aplicación **personalizable**.

# Descripción y funcionamiento - Análisis

## 1. Decodificación de formato utf-8 a latin-1

“MaÑ±ana se levantarÃ; la sesiÃ³n? JaJaJa” -> “Mañana se levantará la sesión? JaJaJa”

## 2. Pasaje a minúsculas

“Mañana se levantará la sesión? JaJaJa” -> “mañana se levantará la sesión? jajaja”

## 3. Separación de palabras

“mañana se levantará la sesión? Jajaja” -> [“mañana”, “se”, “levantará”, “la”, “sesión”, “jajaja”]

## 4. Normalización de risas

“jajaja” -> “inter-risa”

## 5. Eliminación de stopwords (singular y plural)

[“mañana”, “se”, “levantará”, “la”, sesión”, “jajaja”] ->

[“mañana”, “levantará”, “sesión”, “inter-risa”]

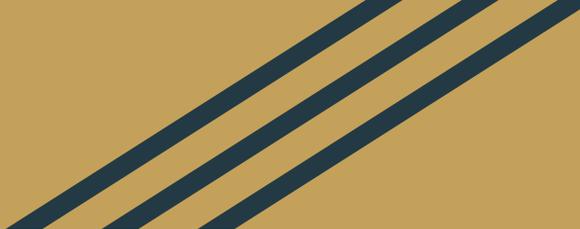
# Descripción y funcionamiento - Entrenamiento

## Lexicon:

- 12000(inicial) + 500 palabras
- Polaridad = promedio de valores

## Machine Learning:

- Naïve Bayes, ME y SVM
- Validación cruzada de K iteraciones
- Bag of Words

- 
1. Introducción
  2. Redes Sociales
  3. Procesamiento de Lenguaje Natural
  4. Análisis de Sentimientos
  5. Desarrollo propuesto
  - 6. Estudio realizado**
  7. Conclusiones y trabajos futuros
- 

# Caso de estudio

- **Red social:** Facebook
- **Portal:** Todo Noticias
- **Publicaciones:** 569
- **Comentarios:** 270279
- **Etiquetados:** 3000
- **Parámetros modificados:**
  - Cantidad mínima de tokens
  - Número de iteraciones
  - Tamaño del BoW.

# Etapa de entrenamiento

## Lexicon:

- Intervalo  $[-1, 1]$  y límites L1 y L2.
- $-1 < L1 < L2 < 1$
- Límites iniciales: L1=-0.3 y L2=0.3
- Límites finales: L1=-0.009 y L2=0.05

## Machine Learning:

- Mínimo de 1 (todos) y 2 tokens
- Validación cruzada de 3, 5 y 10 iter.
- Tamaño del BoW de 73 y 108 tokens

| Tokens   | Pos  | Neu  | Neg  |
|----------|------|------|------|
| $\geq 1$ | 1000 | 1000 | 1000 |
| $\geq 2$ | 884  | 865  | 889  |
| $\geq 3$ | 721  | 661  | 768  |
| $\geq 4$ | 604  | 420  | 652  |

# Evaluación de técnicas

## Lexicon:

- **Ensayo 1:** Sin filtrar stopwords. Límites: -0.3, 0.3.
- **Ensayo 2:** Sin filtrar stopwords. Límites. -0.009, 0.05.
- **Ensayo 3:** Filtrando stopwords. Límites: -0.3, 0.3.
- **Ensayo 4:** Filtrando stopwords. Límites: -0.009, 0.05.

# Evaluación de técnicas

## Machine Learning:

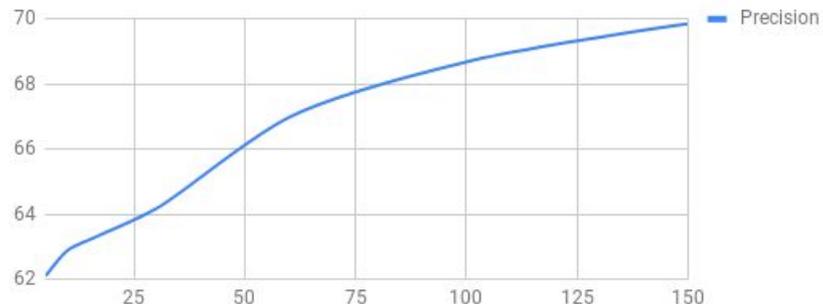
| Ensayo | Tokens   | Folds | Tamaño BoW |
|--------|----------|-------|------------|
| 1      | $\geq 2$ | 3     | 108        |
| 2      | $\geq 2$ | 5     | 108        |
| 3      | $\geq 2$ | 10    | 108        |
| 4      | $\geq 2$ | 3     | 73         |
| 5      | $\geq 2$ | 5     | 73         |
| 6      | $\geq 2$ | 10    | 73         |

| Ensayo | Tokens   | Folds | Tamaño BoW |
|--------|----------|-------|------------|
| 7      | $\geq 1$ | 3     | 108        |
| 8      | $\geq 1$ | 5     | 108        |
| 9      | $\geq 1$ | 10    | 108        |
| 10     | $\geq 1$ | 3     | 73         |
| 11     | $\geq 1$ | 5     | 73         |
| 12     | $\geq 1$ | 10    | 73         |

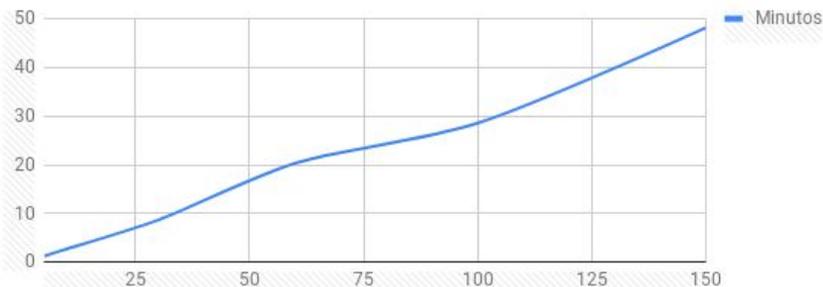
# Evaluación de técnicas - ME

| Iters | Minutos | Precisión | Prec. extra | Min para +1% |
|-------|---------|-----------|-------------|--------------|
| 5     | 1.28    | 62.10%    | -           | -            |
| 10    | 2.77    | 62.90%    | +0.80%      | 1.86         |
| 30    | 8.70    | 64.17%    | +2.07%      | 3.58         |
| 60    | 20.35   | 66.98%    | +4.88%      | 3.91         |
| 100   | 28.58   | 68.68%    | +6.58%      | 4.15         |
| 150   | 48.18   | 69.85%    | +7.75%      | 6.05         |

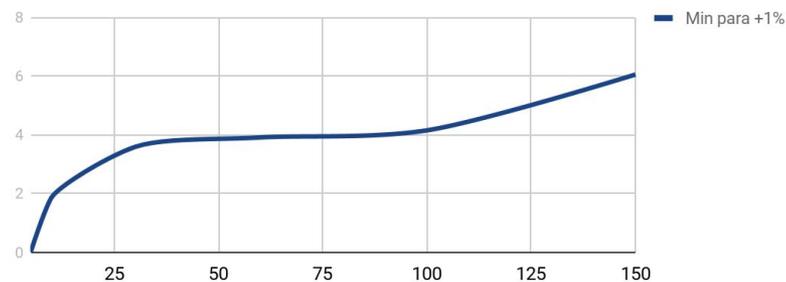
Precisión / Iteraciones



Tiempo / Iteraciones



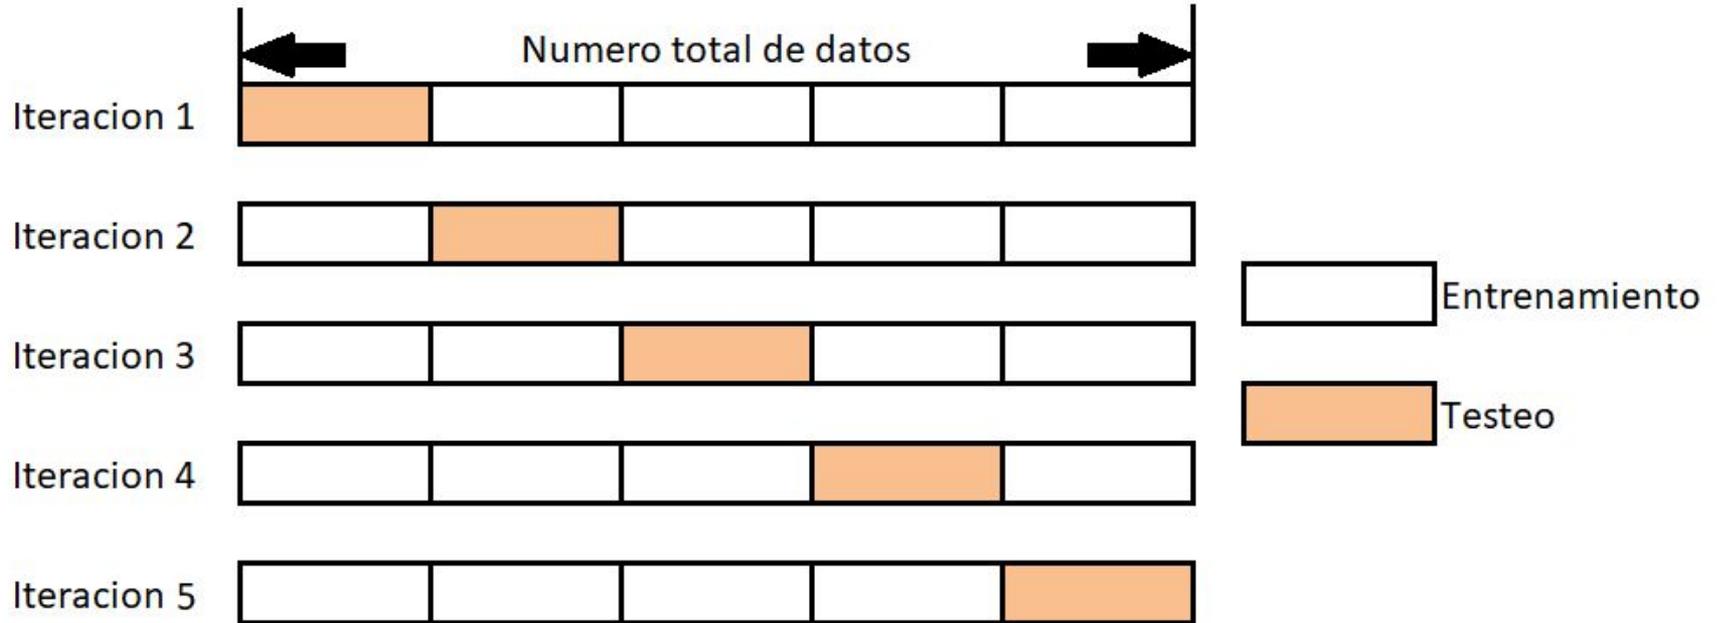
Tiempo (min) para +1% precision / Iteraciones



# Performance

- **Análisis de desempeño** o *performance* del modelo, para saber qué tan exitoso resultó el entrenamiento.
- Existen diferentes **métricas** utilizadas para evaluar los algoritmos de aprendizaje automático.
- Obtuvimos solo aquellas utilizadas para los problemas de clasificación.

# Validación cruzada de K iteraciones



# Matriz de confusión

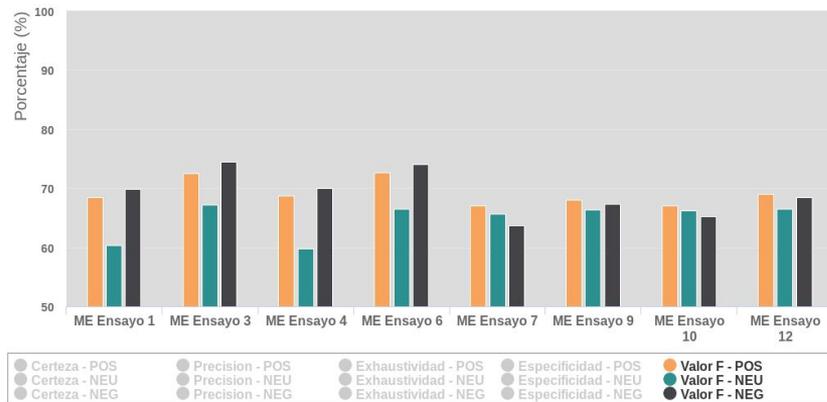
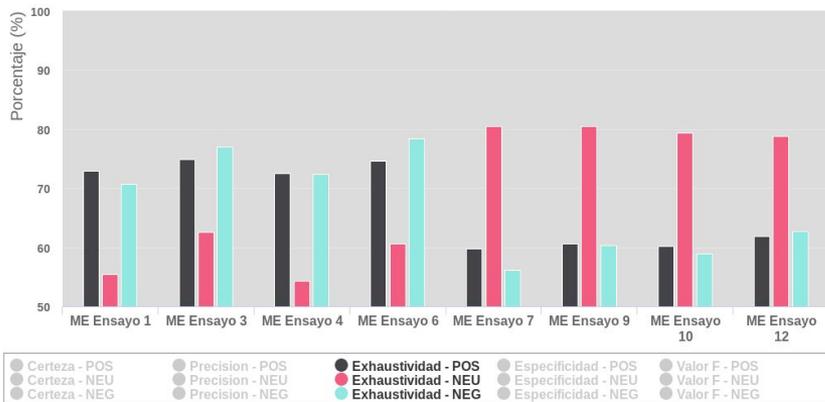
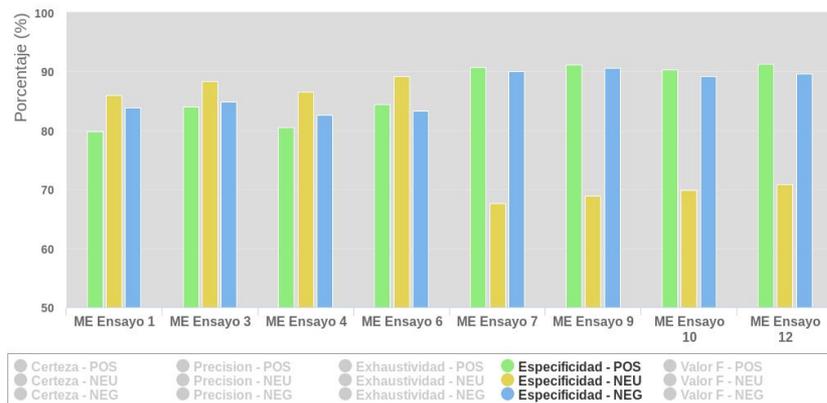
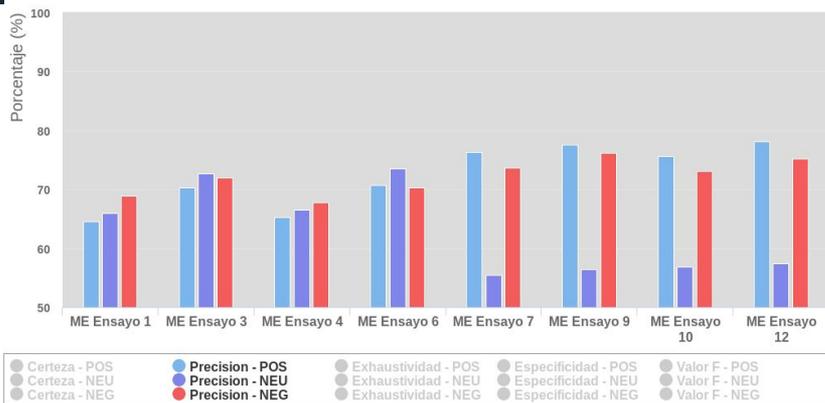
|            |     | Real      |           |       |
|------------|-----|-----------|-----------|-------|
|            |     | Pos       | Neg       | Total |
| Predicción | Pos | <b>40</b> | <b>20</b> | 60    |
|            | Neg | <b>30</b> | <b>10</b> | 40    |
| Total      |     | 70        | 30        |       |

# Métricas

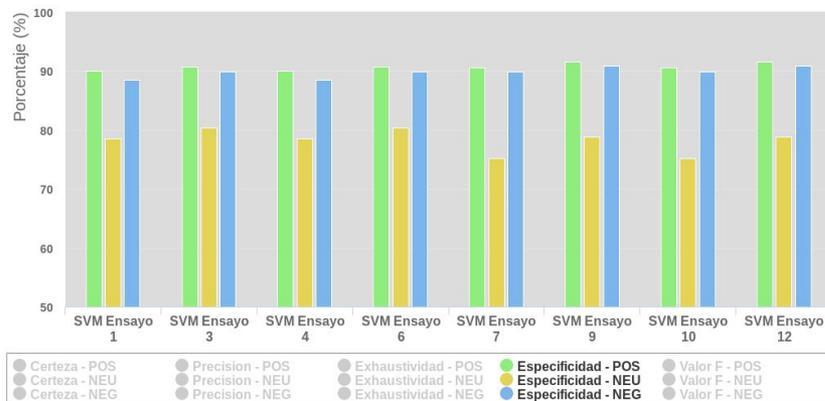
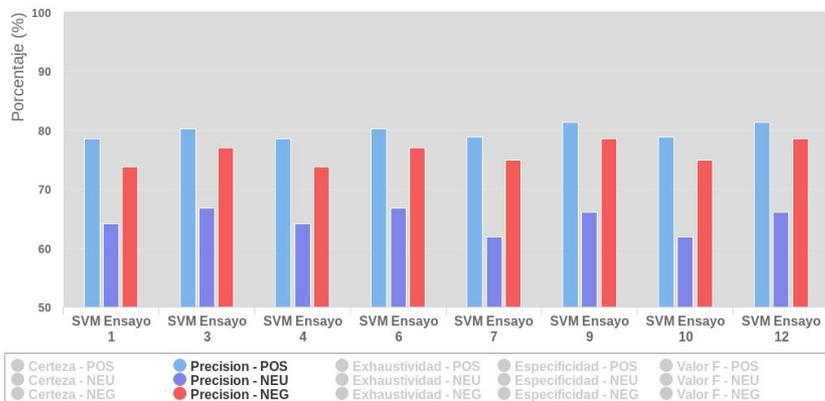
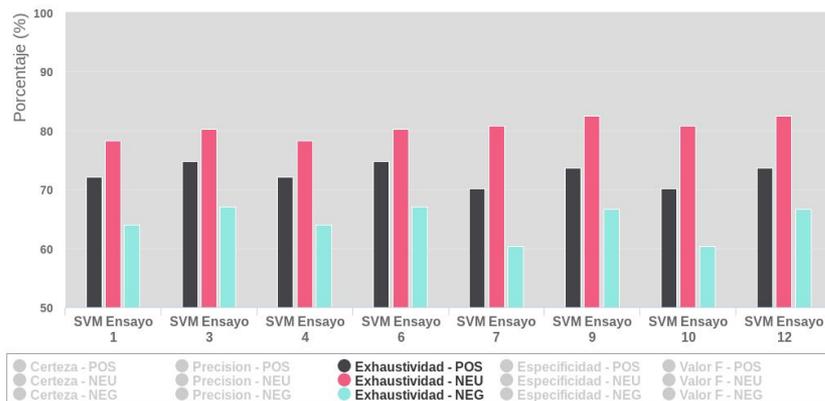
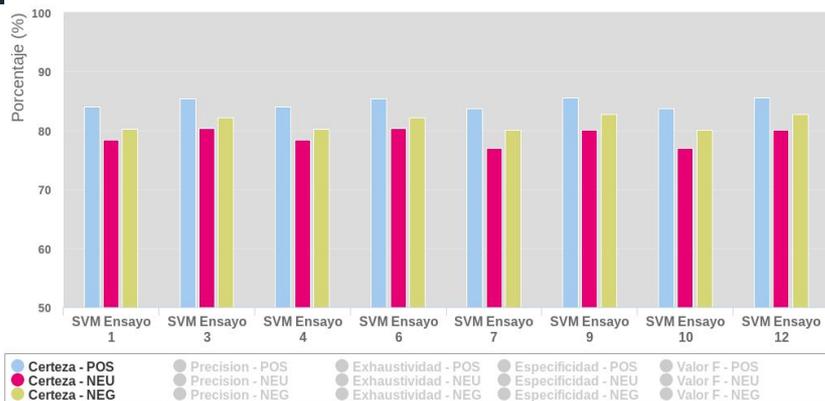
- **Certeza (accuracy):** predicciones correctas respecto del total de predicciones.
- **Precisión (precision):** predicciones correctas respecto de las predicciones para una clase.
- **Exhaustividad (recall):** casos positivos cuya predicción fue acertada.
- **Especificidad (specificity):** casos que no pertenecen a la clase X, y fueron correctamente predichos como otra clase.
- **Valor-F:** promedio armónico entre Precisión y Exhaustividad.

|            |     | Real |     |
|------------|-----|------|-----|
|            |     | Pos  | Neg |
| Predicción | Pos | 40   | 20  |
|            | Neg | 30   | 10  |

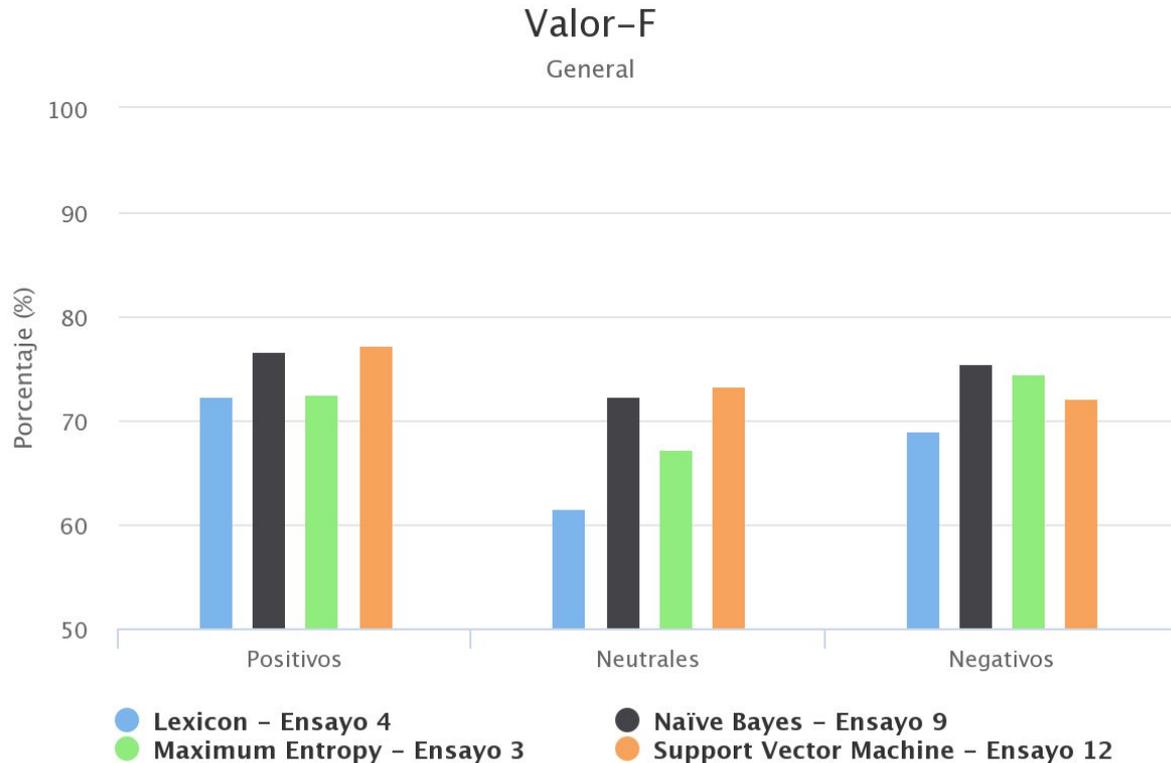
# Comparación de métricas para las técnicas (ME)



# Comparación de métricas para las técnicas (SVM)



# Comparación de métricas para las técnicas



- 
1. Introducción
  2. Redes Sociales
  3. Procesamiento de Lenguaje Natural
  4. Análisis de Sentimientos
  5. Desarrollo propuesto
  6. Estudio realizado
  - 7. Conclusiones y trabajos futuros**
- 

# Conclusiones

- Los **límites** del **Lexicon** tienen gran repercusión en la performance.
  - Filtrar las **stopwords** mejora el desempeño.
- **Incrementar** el número de **folds** mejora los resultados en las técnicas de aprendizaje automático.
  - **NB** mejora al utilizar un **mayor** tamaño de **BoW**.
  - **MaxEnt** posee **dificultades** para identificar la clase neutral.
  - **SVM** mejora levemente al utilizar comentarios más **extensos** y **menor** tamaño de BoW.
- Los **mejores** resultados fueron obtenidos por **NB** y **SVM**.

# Trabajos futuros

- **Influencia** entre **usuarios** dentro de un hilo de discusión. **Variación** de **opinión**.
- **Agrupar usuarios** en base a la **similitud** de su **valoración** sobre los noticias/publicaciones.
- Extraer **información** sobre el **usuario**. **Ranking** de noticias/publicaciones más aceptadas o rechazadas para **grupos** con ciertas **características similares**.
- Permitir que el **usuario** pueda **reaccionar**, de forma similar a Facebook, sobre los comentarios en **tiempo real**.
- **Recolectar** publicaciones y comentarios según lo **aprendido** por el **modelo**.
- Posibilitar la **descarga** de una base o “**perfil de opinión**” de otra persona, para **evitar** la necesidad de **etiquetar** comentarios antes de poder utilizar la aplicación.



**¿Preguntas?**