



INAOE

Aumento de datos para tareas relacionadas al perfilado de autor

por

Victor Jimenez Villar

Tesis sometida como requisito parcial para obtener el grado de:
Maestro en Ciencias en el Área de Ciencias Computacionales
En el:

Instituto Nacional de Astrofísica, Óptica y Electrónica

Diciembre 2020. Tonanzintla, Puebla.

Supervisada por:

Dr. Luis Villaseñor Pineda

© INAOE 2020

El autor otorga al INAOE el permiso de reproducir y distribuir copias
en su totalidad o en partes de esta tesis



Aumento de datos para tareas relacionadas al perfilado de autor

Tesis de Maestría

POR:

Víctor Jiménez Villar

ASESOR:

Dr. Luis Villaseñor Pineda

Instituto Nacional de Astrofísica Óptica y Electrónica
Coordinación de Ciencias Computacionales

Agradecimientos

Esta investigación fue realizada gracias al apoyo otorgado por el Consejo Nacional de Ciencia y Tecnología (CONACYT), a través de la beca No. 718947.

Al INAOE, por brindarme la oportunidad de continuar con mi formación profesional. Gracias a todos los investigadores de la coordinación de Ciencias Computacionales que con su amabilidad y paciencia logre comprender los fundamentos teóricos para realizar este trabajo.

A mi asesor, Luis Villaseñor Pineda, por dirigir esta investigación de la mejor forma posible, siempre dándome sugerencias sobre cómo mejorar mi trabajo.

Al doctor Manuel Montes y Gómez el cual sin ser mi asesor siempre se mantuvo al pendiente de mis avances.

Al doctor Francisco Martínez Trinidad, por enseñarme los fundamentos teóricos en aprendizaje computacional, manteniendo una crítica objetiva sobre mi trabajo.

Al doctor Aurelio López López, por sus clases en procesamiento de lenguaje natural y sus aportes para corregir la claridad de este documento.

A Luz Maria Romero Cirne, por ayudarme a corregir los errores ortográficos en este documento.

A mis familiares y amigos por apoyarme en esta aventura.

Dedicatoria

*Para Luz,
por brindarme siempre su apoyo cuando más lo necesitaba y siempre creer en mí.*

Resumen

Para resolver las tareas de perfilado de autor, la mayoría de los trabajos existentes se han enfocado en utilizar algoritmos de aprendizaje computacional en combinación con diferentes técnicas para extraer características. La obtención de dichas características requiere un análisis riguroso y en muchos casos es necesaria la intervención de expertos en el tema. Sin embargo, existen técnicas de aprendizaje computacional más complejas como las redes neuronales en donde la extracción de características se realiza de forma automática mediante una serie de abstracciones.

La principal motivación para el uso de redes neuronales en perfilado de autor, es debido al increíble éxito del aprendizaje profundo en tareas complejas de procesamiento de lenguaje natural. De acuerdo al estado del arte, en la última conferencia del PAN@CLEF los equipos con mejores resultados utilizaron técnicas tradicionales de aprendizaje. Así también, en las tareas del eRisk el mejor sistema se construyó extrayendo características en combinación con un ensamble de bolsas de palabras y diferentes clasificadores. Lo que se ha podido observar en los diferentes reportes de estas conferencias es que los modelos de aprendizaje basados en redes neuronales no han tenido el éxito esperado.

Uno de los principales problemas en perfilado de autor es la cantidad de datos etiquetados con que se cuenta y se hace más notable cuando se utilizan modelos de aprendizaje profundo. En el caso de perfilado de autor la obtención de estos datos etiquetados manualmente consume mucho tiempo, son costosos, además se podría comprometer a problemas legales debido al uso de datos personales.

Dada esta problemática este trabajo presenta un estudio sobre el efecto de agregar documentos nuevos, generados artificialmente, mediante aumento de datos a nivel estructural, al conjunto de entrenamiento original y el efecto que tiene en los algoritmos de redes neuronales aplicados en tareas relacionadas al perfilado de autor. Para ello, en esta tesis se propone un esquema general para el aumento de datos con diferen-

tes estrategias de selección y reemplazo de palabras, principalmente enfocándose a las relaciones de similitud de las palabras. Gracias a los experimentos realizados fue posible concluir que el aumento de datos propuesto puede mejorar la predicción en tareas relacionadas al perfilado de autor, en comparación con no realizar aumento de datos y algoritmos existentes para el aumento de datos.

Abstract

The principal motivation for the use of neural networks in author profiling is due to the incredible success of deep learning in complex tasks of natural language processing. According to the state of the art in the last PAN@CLEF conference, the teams with the best results used traditional learning techniques. In the eRisk tasks, the best performing system was built by extracting features in combination with an assemble of “bags of words” and different classifiers. What has been observed in these conferences is that models based on neural networks had not the expected success.

One of the main problems in Machine Learning is the amount of labeled data that is available in the training phase, and it becomes more noticeable when using deep learning models. In the case of author profiling, obtaining this manually labeled data is time-consuming, expensive, and could also lead to legal problems due to the use of personal information.

Given this problem, this work presents a study on the effect of data augmentation by increasing data at the structural level to the original training set and the effect it has on neural network algorithms in the detection of depression and anorexia. This thesis proposes a general scheme for increasing data with different strategies for selecting and replacing words, mainly focusing on the similarity relationships of words.

Tabla de Contenido

Agradecimientos	I
Dedicatoria	III
Resumen	V
Abstract	VII
Lista de Figuras	XIII
Lista de Tablas	XV
1. Introducción	1
1.1. Planteamiento del problema	2
1.2. Objetivo general	4
1.3. Objetivos específicos	4
1.4. Organización de la tesis	4
2. Marco Teórico	7
2.1. Clasificación de textos	7
2.2. Extracción de características	8
2.2.1. Preprocesamiento	8
2.2.2. N-Gramas	10
2.2.3. Bolsa de palabras BoW	10
2.2.4. Representaciones distribucionales	11
2.2.5. Representaciones contextuales	12
2.3. Selección de características	13

2.4.	Algoritmos de clasificación	14
2.4.1.	Máquinas de Soporte Vectorial (SVM)	14
2.4.2.	Redes neuronales profundas	16
2.5.	Medidas de Evaluación	20
3.	Trabajo Relacionado	23
3.1.	Perfilado de autor	23
3.1.1.	Detección de trastornos mentales en redes sociales	25
3.2.	Aumento de datos	28
3.2.1.	Aumento de datos supervisado	29
3.2.2.	Aumento de datos semi-supervisado	29
3.2.3.	Aumento de datos en clasificación de textos	30
3.2.4.	Discusión del trabajo relacionado	32
4.	Método propuesto	35
4.1.	Selección de palabras a reemplazar	36
4.1.1.	Etiquetado de partes de la oración	37
4.1.2.	Exclusión de palabras importantes	38
4.2.	Reemplazo de palabras seleccionadas	39
4.2.1.	Similitud relacional	39
5.	Configuración experimental y resultados	49
5.1.	Configuración experimental	49
5.1.1.	Conjunto de datos	50
5.1.2.	Preprocesamiento	52
5.1.3.	Configuración de los métodos propuestos	54
5.1.4.	Configuración de los modelos de aprendizaje	57
5.2.	Resultados	62
5.3.	Análisis y discusión de los resultados	63
5.3.1.	Comparación con el estado del arte en detección de depresión y anorexia	66
5.3.2.	Análisis del aumento de datos	67
6.	Conclusiones y Trabajo Futuro	71
6.1.	Conclusiones	71

TABLA DE CONTENIDO	XI
6.2. Trabajo futuro	72
Apéndices	74
Bibliografía	75

Lista de Figuras

2.1. Una celda de LSTM desdoblada sobre el tiempo. Obtenida de Wikimedia Commons y modificada bajo la licencia Creative Commons 4.0	19
2.2. Red Convolutiva para clasificación de textos, imagen tomada de Kim (2014)	20
4.1. Función de masa para la distribución geométrica con diferentes valores de probabilidad.	37
4.2. Ejemplo comparando las distancias entre las proyecciones de los vectores de palabras relacionadas a la palabra <i>depresión</i> en contraste a la palabra <i>feliz</i> .	40
4.3. Palabras que ocurren en contextos de uso similares tienen una similitud relacional alta, incluyendo el caso de antónimos, por ejemplo <i>llorar</i> vs <i>reír</i>	42
5.1. Diagrama general de la configuración experimental	50
5.2. Distribución del número de palabras en los historiales de usuarios estudiados	52
5.3. Arquitectura del modelo Bi-LSTM	60
5.4. Arquitectura del modelo CNN con múltiples tamaños de convolución	61
5.5. Relación entre el aumento del conjunto de datos <i>Depresión 2018</i> y la ganancia porcentual en F1.	65
5.6. Relación entre el aumento del conjunto de datos <i>Depresión 2019</i> y la ganancia porcentual en F1.	66
5.7. Relación entre el aumento del conjunto de datos <i>Anorexia</i> y la ganancia porcentual en F1.	66
5.8. Comparación con el estado del arte en detección de depresión y anorexia	67

5.9. Relación entre el aumento de datos y el vocabulario nuevo agregado. .	69
5.10. Palabras con mayor puntuación χ^2	70

Lista de Tablas

2.1. Matriz de confusión.	21
3.1. Comparación del método propuesto con el estado del arte en aumento de datos para clasificación de textos.	34
4.1. Ejemplo de etiquetado de partes de la oración.	38
4.2. Ejemplos del aumento de datos, para el método con restricción χ^2 y sustitución por similitud relacional.	41
4.3. Ejemplos del aumento de datos para el método basado en reemplazo por relaciones equivalentes.	45
4.4. Ejemplos del aumento de datos para el método basado en relaciones contrarias, las palabras en cursiva, son las que resultaron afectadas después de la transformación.	47
5.1. Número de usuarios en los conjuntos de datos y número de secuencias con 64 palabras. Los números resaltados en negritas representan el número de historiales.	51
5.2. Número de usuarios en los conjuntos de datos y número de secuencias con 64 palabras después del preprocesamiento y filtrado. Los números resaltados en negritas representan el número de historiales.	52
5.3. Etiquetas utilizadas en el proceso de aumento para los métodos de similitud relacional.	56
5.4. Ejemplos del aumento de datos, las palabras resaltadas en negritas son las que resultaron afectadas después de la transformación.	57
5.5. Parámetros utilizados para el entrenamiento de los modelos basados en redes neuronales.	62

5.6. Resultados en términos de la métrica F1, la variable n indica la magnitud del aumento en el conjunto original.	64
---	----

Capítulo 1

Introducción

Imagina que se te ha dado un texto de un autor anónimo, y deseas saber tanto como sea posible del autor (género, ocupación, personalidad etc.), sólo analizando el texto dado. Es sorprendente, pero el texto refleja parte de la personalidad del autor. Así que, observando el texto al determinar su estilo y contenido, se puede inferir información sobre el autor. Esta tarea se conoce como *perfilado de autor* y está fundada en estudios dentro de la comunidad sociolingüística, demostrando que las palabras utilizadas en la vida diaria pueden revelar importantes aspectos sociales y psicológicos. Gracias a los avances en computación, el análisis de textos permite obtener características de lo que las personas dicen y también de las particularidades en sus estilos lingüísticos (Pennebaker, Mehl, y Niederhoffer, 2002).

El interés en esta tarea ha crecido gracias al constante flujo de información compartida a través de redes sociales (por ejemplo, Twitter ¹, Facebook² y Reddit ³) y sus aplicaciones varían desde mercadotecnia hasta seguridad nacional. Existen numerosas razones del interés en conocer datos relevantes de los usuarios de redes sociales. Por ejemplo, a las empresas les interesaría conocer a qué tipo de usuarios les gusta un producto o servicio, con la intención de dirigir una mejor campaña de publicidad (Ikeda et al., 2013). Además, en un contexto de seguridad informática, a la policía cibernética le gustaría conocer el perfil de las personas que envían mensajes amenazantes o de acoso sexual (Bogdanova, Rosso, y Solorio, 2012).

Claro está que la tarea no es simple y debido al lenguaje informal de redes sociales y poco estandarizado hace que esta tarea sea incluso más desafiante, por ejemplo: errores gramaticales, abreviaturas, anglicismos, emoticonos o incluso texto generado

¹www.twitter.com

²www.facebook.com

³www.reddit.com

por cuentas automáticas. Una de las conferencias más destacadas en perfilado de autor ha sido el PAN@CLEF⁴ (una serie de eventos científicos y tareas compartidas en el análisis forense digital y estilométrico); desde el año 2013 al actual se han estudiado diversos enfoques del perfilado de autor desde una perspectiva multi-idioma (inglés y español principalmente) entre las cuales destacan: identificación de edad y género (Rangel et al., 2013), identificación de personalidad, variación de lenguaje y dimensión de género (Stammatatos et al., 2015).

Un tema importante es el perfilado de características de comportamiento (Kumar et al., 2018) y condiciones médicas (De Choudhury et al., 2013); estas tareas se han desarrollado en subcampos y con sus propias conferencias. Por ejemplo, la conferencia eRisk (Losada, Crestani, y Parapar, 2018), está orientada al perfilado del autor en búsqueda de evidencia de trastornos como la depresión o la anorexia. El perfilado automático de depresión y anorexia consiste en recopilar una serie de textos de diferentes autores, con el objetivo de extraer información útil para construir modelos estadísticos que permiten detectar o incluso predecir signos de depresión y anorexia, en una forma fina, incluyendo maneras de complementar y extender enfoques tradicionales de diagnóstico. La hipótesis inicial es que los cambios en el lenguaje de un autor, empleado para interactuar y expresarse diariamente, contiene patrones que pueden indicar este tipo de desórdenes mentales De Choudhury et al. (2013).

1.1. Planteamiento del problema

Para resolver las tareas de perfilado de autor, la mayoría de los trabajos existentes se han enfocado en utilizar algoritmos de aprendizaje computacional, en combinación con diferentes técnicas para extraer características: conteo de palabras (Laserna, Seih, y Pennebaker, 2014), identificación de frases personales (Ortega-Mendoza et al., 2018a), análisis de emociones (Aragón et al., 2019) entre otras técnicas. La obtención de estas características requiere un análisis riguroso y en muchos casos es necesaria la intervención de expertos en el tema. No obstante, existen técnicas de aprendizaje computacional más complejas como las redes neuronales, donde la extracción de características se realiza de forma automática mediante una serie de abstracciones.

La principal motivación para el uso de redes neuronales en perfilado de autor, es debido al increíble éxito del aprendizaje profundo en tareas complejas para el en-

⁴www.pan.webis.de

tendimiento del lenguaje: parafraseo, traducción automática, analogía, implicación textual, similitud semántica, etc. En el conjunto de datos GLUE (Wang et al., 2018), los modelos de aprendizaje profundo han superado la puntuación humana, Christopher D. Manning (director del laboratorio de inteligencia artificial de la universidad de Stanford), menciona que desde el año 2015 se produjo un tsunami del aprendizaje profundo en el área de procesamiento de lenguaje natural, debido a la gran cantidad de artículos en conferencias de PLN (Procesamiento de Lenguaje Natural) utilizando aprendizaje profundo (Manning, 2015).

De acuerdo con el estado del arte, en la última conferencia del PAN@CLEF los equipos con mejores resultados utilizaron técnicas tradicionales de aprendizaje como lo son máquinas de soporte vectorial SVM, en combinación con n-gramas de caracteres. Así también, en las tareas del eRisk el mejor sistema se construyó extrayendo características en combinación con un ensamble de bolsas de palabras (BOW por sus siglas en inglés) y diferentes clasificadores. Lo que se ha podido observar en los diferentes reportes de estas conferencias es que los modelos de aprendizaje basados en redes neuronales no han tenido el éxito esperado.

Uno de los principales problemas dentro del campo de aprendizaje automático es que el éxito de éste depende de la cantidad de datos etiquetados con que se cuente y se hace más notable cuando se utilizan modelos de aprendizaje profundo, el etiquetado manual de datos consume mucho tiempo y es costoso, además se podría incurrir en problemas legales debido al uso de datos personales, como es el caso en las tareas de perfilado de autor. Los estudios actuales tratan con un número pequeño de autores conocidos, donde el etiquetado manual puede ser aplicado, pero considerando las dimensiones de los datos en redes sociales se convierte en una tarea costosa y difícil.

Uno de los problemas conocidos en la clasificación de textos es el sobreajuste de los modelos de aprendizaje, el cual se genera en la etapa de entrenamiento debido a que el modelo memoriza los pocos documentos de entrenamiento. Por lo tanto, ante esta situación es deseable tener una amplia diversidad en los textos, es decir tener frases que signifiquen lo mismo pero escritas de forma diferente; para esto se han propuesto diferentes técnicas como el aumento de datos o agregar ruido aleatorio a los ejemplos originales.

Observando las limitantes anteriores este trabajo presenta un estudio incrementando el conjunto de datos de entrenamiento, observando el efecto al agregar documentos nuevos. Para ello, se crean nuevos documentos respetando su estructura, y se agregan

al conjunto de entrenamiento original. Este estudio analiza el efecto que tiene este incremento en los algoritmos de redes neuronales tradicionales en tareas relacionadas al perfilado de autor.

Algunas de las principales preguntas a contestar en esta investigación son:

- 1.- ¿Cómo conservar el estilo y contenido para el aumento de datos en perfilado de autor?
- 2.- ¿En qué tipo de arquitecturas basadas en redes neuronales tiene mayor impacto el aumento de datos?
- 3.- ¿Se puede mejorar el perfilado de usuarios que sufren depresión y anorexia mediante el aumento de datos?

1.2. Objetivo general

Proponer un método de aumento de datos, considerando estilo y contenido del texto, para mejorar la predicción de los modelos de aprendizaje profundo en las tareas de perfilado de autor.

1.3. Objetivos específicos

- 1.- Diseñar diferentes estrategias de aumento de datos bajo condiciones supervisadas las cuales permitan conservar el estilo y contenido del documento original y a la vez aumentar el vocabulario.
- 2.- Demostrar el efecto del aumento de datos, tanto en modelos de redes neuronales como en modelos de aprendizaje supervisado tradicionales.
- 3.- Evaluar y analizar los métodos propuestos para abordar el perfilado de depresión y anorexia en redes sociales.

1.4. Organización de la tesis

Esta tesis está organizada de la siguiente forma:

- **Capítulo 2: Marco teórico.** Presenta una introducción a la clasificación de textos con aprendizaje automático, además de mencionar las principales métricas de evaluación utilizadas en este trabajo. Los conceptos descritos son fundamentales para comprender la solución propuesta.
- **Capítulo 3: Trabajo relacionado.** Describe el estado del arte en perfilado de autor y aumento de datos para clasificación de textos, su principal objetivo es conocer como se ha abordado el problema y analizar las ventajas y desventajas de los métodos existentes.
- **Capítulo 4: Método propuesto:** En este capítulo se describen a detalle los métodos propuestos, su justificación y algunos ejemplos de aumento de datos.
- **Capítulo 5: Configuración experimental y resultados:** En este capítulo se describen los conjuntos de datos estudiados y la configuración para los distintos clasificadores empleados, así como los métodos propuestos y los métodos de referencia o de comparación. Se realiza una comparación de los resultados obtenidos con el estado del arte para la detección de depresión y anorexia.
- **Capítulo 6: Conclusiones y trabajo futuro:** Por último, se exponen las principales contribuciones de este trabajo y formas en que se puede mejorar.

Capítulo 2

Marco Teórico

En este capítulo se describen conceptos relacionados con la tarea de perfilado de autor mediante algoritmos de aprendizaje automático. Se describen las principales representaciones de un texto dado, las características generales de los clasificadores empleados, así como las medidas de evaluación empleadas para medir los resultados de los diferentes modelos. Además, se presenta una introducción de las tareas de procesamiento de lenguaje natural utilizadas en el método propuesto: etiquetado de partes de la oración, esquemas de pesado y representaciones distribucionales de palabras.

2.1. Clasificación de textos

En años recientes, ha habido un crecimiento exponencial en el número de textos disponibles en Internet, a tal grado que es imposible procesarlos manualmente, de ahí la importancia de su procesamiento automático. Los problemas de clasificación automática de textos han sido ampliamente estudiados en las últimas décadas, especialmente con los avances en procesamiento de lenguaje natural, muchos investigadores están interesados en desarrollar aplicaciones que mejoren los métodos de clasificación de textos. Las tareas exploradas en este trabajo se circunscriben a las tareas de perfilado de autor, donde se desea conocer la categoría (clase o tipo de autores) a la que pertenece un documento dado (historial del usuario).

Definición

La clasificación de textos puede ser definida como la tarea de categorizar un grupo de documentos en una o más clases predefinidas de acuerdo con sus temas (Kadhim,

2019). Retomando la definición de (Kadhim, 2019), se parte con un grupo específico de documentos $D = \{d_1, \dots, d_n\}$, con clases predefinidas $C = \{c_1, \dots, c_m\}$ y un nuevo documento q el cual es generalmente indicado como una consulta, con el objetivo de predecir la clase del documento consultado, la cual puede ser una o más clases pertenecientes a C .

De acuerdo con (Kowsari et al., 2019), la clasificación de textos puede describirse en cuatro pasos: extracción de características, reducción de dimensionalidad o selección de características, construcción del modelo de clasificación y evaluación. A continuación, se describen en forma resumida algunos de los puntos más importantes para este trabajo, tomados del análisis de (Kowsari et al., 2019).

2.2. Extracción de características

El preprocesamiento y la extracción de características, son pasos muy importantes en la clasificación de textos, en las siguientes secciones se presentan algunas de las técnicas más empleadas y se mencionan dos métodos de representación de características: la bolsa de palabras y las representaciones distribucionales.

2.2.1. Preprocesamiento

Dependiendo de la tarea de clasificación, algunos elementos pueden desecharse para enfocar nuestra atención en los elementos más informativos. Algunos de estos elementos son: *palabras de paro*, errores gramaticales, signos de puntuación, etc. Además de esto, el texto extraído de redes sociales contiene enlaces del Internet, menciones de usuario, etiquetas (conocidos como hashtags), emoticonos y un vocabulario muy informal (p.e. abreviaturas no convencionales). A continuación, se explican brevemente algunas técnicas empleadas para el limpiado y preprocesamiento de textos.

- 1.- **Tokenización:** Es un método de preprocesamiento en el cual se divide una cadena de caracteres en palabras, frases, símbolos y otros elementos dentro del texto, llamados *tokens* (Kowsari et al., 2019). Se pueden utilizar diferentes algoritmos, para este proceso, lo más simple es separar el texto mediante un espacio o carácter común, por ejemplo:

Texto original: “*Los días de verano son calurosos*”.

Los tokens del texto anterior son los siguientes: {“Los”, “días”, “de”, “verano”, “son”, “calurosos”}

- 2.- **Palabras de paro:** Son palabras con mayor frecuencia en los documentos, y por lo tanto poco útiles para la discriminación entre documentos de diferentes clases. Ejemplos de ellas son: {“a” “the”, “they”, “he” , “she”, ...} (para el idioma inglés). En algunas tareas de clasificación de textos, las palabras de paro no son de importancia y lo más común es removerlas de los documentos. Nothman (Nothman, Qin, y Yurchak, 2018) presenta un análisis de las palabras de paro y su impacto en la clasificación de textos.
- 3.- **Capitalización:** Los textos contienen diversas formas de capitalización de palabras para formar una oración. Dado que los documentos consisten en muchas oraciones, una capitalización diversa puede ser muy problemática en la clasificación de textos largos. La técnica más común para tratar la capitalización inconsistente es reducir cada palabra a minúsculas (Kowsari et al., 2019).
- 4.- **Reducción de ruido:** La mayoría de los textos contienen caracteres innecesarios para la clasificación de documentos, como signos de puntuación o caracteres especiales. En tareas como detección de autoría pueden ser útiles, pero en general agregan ruido a los modelos de clasificación de textos.
- 5.- **Lematización:** Es el proceso de convertir palabras a su forma base o raíz (e.g., morfema base del significado) (Kamath, Liu, y Whitaker, 2019). La desventaja es que este método requiere un diccionario y tablas de búsqueda (Kamath, Liu, y Whitaker, 2019). Uno de los algoritmos más populares es el algoritmo de Porter (Porter, 2001), el cual hace una lematización por fuerza bruta mediante el truncamiento de las palabras.
- 6.- **Otras técnicas:** Adicionalmente a las técnicas descritas, también es posible preprocesar los textos para intentar normalizarlos, con la intención de facilitar al clasificador la identificación de patrones. Algunas de ellas son: la corrección de errores ortográficos, enmascaramiento de textos, etiquetado de partes de la oración, etc.

2.2.2. N-Gramas

Es una técnica para extraer características para representar un texto, los n-gramas son un conjunto de palabras o caracteres que respetan el orden de aparición en el texto; el número n indica la longitud de la secuencia a considerar, lo más común es utilizar valores de n pequeños (uni-gramas, bi-gramas, tri-gramas) (Kowsari et al., 2019).

Ejemplo de bi-gramas:

Texto Original: “*Con el tiempo todo pasa*”

Bi-gramas: {“con el”, “el tiempo”, “tiempo todo”, “todo pasa”}

2.2.3. Bolsa de palabras BoW

El modelo de bolsa de palabras o BoW (por sus siglas en inglés “Bag of Words”) es una representación simplificada de un texto. Normalmente, se utiliza un criterio o pesado específico, como lo puede ser la frecuencia de cada palabra, para representar cada texto. Es decir, en el modelo BoW, el conjunto de documentos es representado mediante una matriz de pesos, siendo las columnas palabras únicas del conjunto de datos y las filas representan un documento. Este modelo es muy simple, donde no es posible capturar el orden secuencial de las palabras -como en una oración o un documento-, con lo que las relaciones semánticas entre las palabras se pierden. Sin embargo, en este modelo las palabras capturan el contenido de un documento y esta representación puede ser utilizada para determinar el tema principal del documento (Kowsari et al., 2019).

Pesado de palabras

La forma más básica de pesado de características es mediante el pesado TF (*term frequency* por sus siglas en inglés), el cual consiste en contar el número de ocurrencias de cada término t en el documento d . Los métodos basados en TF generalmente consisten en representar la frecuencia de palabras como un peso escalado o normalizado, aunque es fácil de implementar y muy intuitivo, este método es limitado porque las palabras más comunes pueden dominar la representación.

TF-IDF Term Frequency-Inverse Document Frequency

Esta técnica de pesado fue propuesta por (Jones, 1972), con el objetivo de mitigar el efecto de las palabras más comunes del corpus. *IDF* asigna menos peso a aquellas palabras presentes en la mayoría de los documentos en la colección y, por lo tanto, estas palabras no se consideran útiles para identificar patrones discriminatorios. La representación matemática del peso de un término en un documento por *TF-IDF* está dada en la ecuación 2.2.1

$$W(d, t) = TF(d, t) * \log(N/df(t)) \quad (2.2.1)$$

Donde N es el número total de documentos en la colección y $df(t)$ es el número de documentos que contienen el término t , el primer término $TF(d, t)$ es la frecuencia del término t en el documento d . Aunque *TF-IDF* trata de solucionar el problema de términos comunes en el documento, sigue sufriendo de otras limitaciones. Un problema común es que *TF-IDF* no se puede utilizar para medir la similitud entre palabras en el documento, debido a que las representaciones son generadas a nivel documento.

2.2.4. Representaciones distribucionales

Su objetivo principal es capturar el significado semántico de las palabras, donde cada palabra del vocabulario es representada mediante un vector n-dimensional de números reales. Recientemente (Mikolov et al., 2013) presentó el modelo Word2Vec, para generar vectores de palabras, el cual tiene dos algoritmos: el modelo CBOW y el modelo Skip-gram. CBOW predice la palabra central del contexto que la rodea, mientras que Skip-gram hace lo contrario y predice la distribución (probabilidad) de las palabras de contexto de una palabra central. Word2Vec proporciona una herramienta muy poderosa para descubrir relaciones entre los textos de un corpus, así como la similitud entre palabras.

Glove es un modelo similar a Word2Vec, fue propuesto por (Pennington, Socher, y Manning, 2014) y su objetivo principal de capturar contextos globales combinando factorización de matrices y ocurrencias locales. Este modelo demostró ser más rápido en entrenamiento y mejora en tareas como analogía (en comparación con Word2Vec). Los autores generaron diferentes modelos preentrenados para su libre acceso, estos

modelos fueron entrenados con grandes conjuntos de datos como CRAWL¹ y Wikipedia².

Otro modelo distribucional es FastText, este modelo fue desarrollado por el laboratorio de inteligencia artificial de Facebook (Mikolov et al., 2017). A diferencia de los modelos anteriores este modelo considera la morfología de las palabras, cada vector es enriquecido con una bolsa de vectores de caracteres de n-gramas que es derivada de una matriz de coocurrencia. La principal ventaja de este modelo es su habilidad de obtener vectores para palabras fuera del vocabulario. Los vectores preentrenados están disponibles en la página oficial de FastText³ y la última liberación fue un modelo entrenado en 157 idiomas (Grave et al., 2018).

Para un mayor detalle de la teoría y el cálculo de este tipo de representaciones consultar el capítulo 5 del libro de (Kamath, Liu, y Whitaker, 2019).

2.2.5. Representaciones contextuales

Este tipo de representación difiere de las representaciones distribucionales, en que a cada token le es asignado a una representación que es una función de la secuencia completa de entrada, por lo tanto, cada token tendrá un vector de características diferentes de acuerdo con la secuencia de entrada. A continuación, se describen los trabajos más relevantes bajo este paradigma. ELMo fue presentado por (Peters et al., 2018), la idea original es que los vectores resultantes sean aprendidos por una red bidireccional LSTM (ver sección 2.4.2). El objetivo principal de este modelo, es representar el uso complejo de las palabras (e.g., sinonimia y semántica) y como varían estos usos en diferentes contextos lingüísticos (i.e., polisemia). Los autores demostraron que estas representaciones pueden ser añadidas a modelos existentes y mejorar significativamente el estado del arte en tareas como: respuesta de preguntas, implicación textual y análisis de sentimientos.

BERT es un modelo de representación de lenguaje Devlin et al. (2018), fue diseñado para preentrenar representaciones bidireccionales profundas condicionando y uniendo el contexto de la secuencia de entrada de derecha a izquierda en todas las capas. Como resultado, el modelo preentrenado puede ser ajustado a la tarea deseada agregando una capa de salida adicional. Este modelo obtuvo nuevos resultados del

¹www.commoncrawl.org

²www.wikipedia.org

³www.fasttext.cc

estado del arte en once tareas de procesamiento de lenguaje natural, incluyendo el conjunto de tareas GLUE Wang et al. (2018).

2.3. Selección de características

Un problema común en la clasificación de textos, es el manejo de grandes espacios vectoriales (cientos de miles dependiendo de la extracción utilizada) y como consecuencia se necesitan grandes cantidades de memoria y tiempo de computación para poder procesar los algoritmos de aprendizaje. Una solución efectiva consiste en seleccionar las características que mejor discriminan a las clases.

Existen diversos métodos para seleccionar características, entre los más utilizados se encuentran:

- 1.- Umbral de Frecuencia: Se mide para cada palabra w del vocabulario, el número de documentos en que w aparece. Aquellas palabras con una frecuencia baja, es decir, con pocos contextos de uso, se eliminan. Se espera que las palabras más frecuentes también aparezcan en documentos no vistos (Yang and Pedersen, 1997).
- 2.- Ganancia de información: Se establecen como relevantes todas aquellas palabras con una ganancia mayor a cero. Esta técnica tiene un sesgo muy importante respecto al conjunto de entrenamiento, sobre todo si éste es pequeño (Yang and Pedersen, 1997).
- 3.- Chi cuadrada: Es un test estadístico que mide la independencia entre un término t y una clase c . Para cada término, una puntuación alta indica que la hipótesis nula de independencia debe ser rechazada y la ocurrencia del término y la clase son dependientes (Yang and Pedersen, 1997).

En (Yang and Pedersen, 1997) se encuentra la definición matemática de cada uno de los métodos y (Forman, 2003) presenta un análisis más extenso junto con otros métodos.

2.4. Algoritmos de clasificación

Se han utilizado diversos algoritmos de aprendizaje automático para la clasificación de textos, dentro de los más populares y frecuentemente utilizados como línea base son las máquinas de soporte vectorial (SVM por sus siglas en inglés). Por otro lado, respecto a las arquitecturas de aprendizaje profundo que se han empezado a emplear, se distinguen dos arquitecturas básicas: las redes recurrentes y las redes convolucionales. En esta sección se explican las generalidades de estos algoritmos. En (Minaee et al., 2020) se puede encontrar una revisión más detallada del estado del arte en la clasificación de textos con aprendizaje profundo.

2.4.1. Máquinas de Soporte Vectorial (SVM)

Este algoritmo de clasificación fue propuesto por (Vapnik and Chervonenkis, 1964), desde entonces el algoritmo ha pasado por una serie de mejoras. (Boser, Guyon, y Vapnik, 1992) adaptó el algoritmo para resolver problemas no lineales y la formulación moderna fue desarrollada por (Cortes and Vapnik, 1995).

Retomando las definiciones de (Boser, Guyon, y Vapnik, 1992), SVM encuentra una función de decisión para vectores x de características, de dimensión n , pertenecientes a alguna clase A o B. La entrada al algoritmo de entrenamiento es un conjunto de p ejemplos x_i con etiquetas y_i :

$$(x_1, y_1), (x_2, y_2), (x_3, y_3), \dots, (x_p, y_p) \quad (2.4.1)$$

$$\text{donde } \begin{cases} y_k = 1 & \text{si } x_k \in A \\ y_k = -1 & \text{si } x_k \in B \end{cases}$$

Para los ejemplos de entrenamiento el algoritmo encuentra una función de decisión $D(x)$ durante una fase de aprendizaje. Después del entrenamiento, la clasificación de patrones desconocidos es predicha de conforme a la siguiente regla:

$$\begin{aligned} x \in A & \text{ si } D(x) > 0 \\ x \in B & \text{ si no} \end{aligned} \quad (2.4.2)$$

Las funciones de decisión deben ser lineales en sus parámetros, pero no están restringidas a dependencias lineales de x . Estas funciones pueden ser expresadas idénticamente a un *perceptron* (Block, Knight Jr, y Rosenblatt, 1962):

$$D(x) = \sum_{i=1}^N w_i \phi_i(x) + b \quad (2.4.3)$$

En la ecuación 2.4.3, ϕ_i son funciones predefinidas de x y w_i y b son los parámetros ajustables a aprender.

En la formulación de (Boser, Guyon, y Vapnik, 1992; Cortes and Vapnik, 1995) podemos encontrar la forma de aproximar este tipo de funciones, construyendo hiperplanos separados que maximicen un margen mediante algoritmos de optimización numérica.

Las ventajas⁴ de las SVM son:

- Son efectivas en espacios altamente dimensionales, como sucede en la clasificación de textos.
- Son efectivas en casos donde el número de dimensiones es mayor al número de ejemplos.
- Usa un subconjunto de puntos de entrenamiento en la función de decisión llamados vectores de soporte, así que es también eficiente en el uso de la memoria.
- Se pueden especificar diferentes funciones de núcleo para la función de decisión.

Las desventajas incluyen:

- Si el número de características es mucho mayor al número de ejemplos, elegir una función de núcleo y término de regularización es crucial para evitar el sobre ajuste. Este problema es común en el análisis de historiales muy extensos extraídos de redes sociales.
- Las SVMs no otorgan directamente estimaciones de probabilidad, estas son calculadas utilizando validación cruzada.

⁴Listadas en <https://scikit-learn.org/stable/modules/svm.html>

2.4.2. Redes neuronales profundas

En la definición de (LeCun, Bengio, y Hinton, 2015), el aprendizaje profundo permite a los modelos computacionales que están compuestos de múltiples capas de procesamiento aprender representaciones de los datos con múltiples niveles de abstracción. Estos métodos han mejorado dramáticamente el estado del arte en tareas para el entendimiento de lenguaje natural, particularmente en clasificación de textos, análisis de sentimientos, dar respuesta a preguntas y traducción automática. El aprendizaje profundo descubre estructuras en grandes conjuntos de datos utilizando el algoritmo de retro-propagación para determinar sus parámetros internos los cuales son utilizados para calcular la representación en cada capa de la arquitectura.

A continuación, se describen los conceptos principales en aprendizaje profundo tomados principalmente de (LeCun, Bengio, y Hinton, 2015), para una definición más extensa consultar (Goodfellow, Bengio, y Courville, 2016; Kamath, Liu, y Whitaker, 2019).

Retropropagación y entrenamiento de arquitecturas multicapa

Una arquitectura multicapa es una pila de modelos simples y muchos de estos calculan un mapeo entrada-salida no lineal. El procedimiento de retropropagación calcula el gradiente de una función objetivo con respecto a los pesos de múltiples capas, es una aplicación práctica de la regla de la cadena para derivadas.

Las arquitecturas multicapa aprenden a mapear una entrada de tamaño fijo (por ejemplo, la representación vectorial de un documento) a una salida de tamaño fijo (por ejemplo, las categorías de documentos). Para ir de una capa a la siguiente, un conjunto de unidades (nodos o neuronas) calculan una suma pesada de las entradas de la capa anterior y el resultado pasado es a través de una función no lineal. A la fecha, la función ReLU (2.4.4) es una de las más populares, ya que se ha demostrado empíricamente que permite aprender más rápido en redes neuronales con muchas capas (Glorot, Bordes, y Bengio, 2011). Las neuronas que no forman parte de la capa de entrada ni la de salida se conocen como unidades ocultas.

Las **capas ocultas** pueden ser vistas como una distorsión de la entrada en una forma no lineal, con el objetivo que las categorías sean linealmente separables por la última capa.

$$f(z) = \max(z, 0) \quad (2.4.4)$$

La **capa de entrada** puede ser construida mediante pesado *TF-IDF*, vectores de palabras, alguna otra característica o representación. En la clasificación de documentos usualmente la capa de entrada recibe un documento en representación vectorial (2.4.5).

$$d_j = (w_{1,j}, w_{2,j}, \dots, w_{i,j}, \dots, w_{l_j,j}) \quad (2.4.5)$$

Siendo l_j es el tamaño del documento j y $w_{i,j}$ es la representación vectorial de la palabra i en el documento j .

En la **capa de salida** el número de neuronas es igual al número de clases para clasificaciones con más de dos clases y una para clasificación binaria, la capa de salida, es la encargada de hacer la predicción final a partir de las representaciones capturadas por la red neuronal.

La **inicialización** de los pesos y sesgo (bias) por lo general es con ceros o números generados con base en algún criterio, un algoritmo común es el conocido como inicialización Glorot o Xavier (Glorot and Bengio, 2010) el cual está basado en números aleatorios extraídos de una distribución de probabilidad uniforme.

Cuando se entrena una red neuronal, la propagación hacia adelante es realizada en lotes o **batch** (un número de instancias de entrenamiento determinado por el hiperparámetro llamado tamaño de batch), después se calcula el error para cada neurona mediante retropropagación en el mismo lote.

Una **época** es una sola iteración sobre todo el conjunto de datos, el número de épocas es un hiperparámetro que determina cuantas veces el algoritmo de aprendizaje itera sobre todo el conjunto de entrenamiento.

Redes Neuronales Recurrentes (RNN)

Los modelos basados en RNNs tienen el objetivo principal de capturar la dependencia entre palabras y la estructura del texto para clasificación de textos Goodfellow, Bengio, y Courville (2016).

Las redes recurrentes procesan una secuencia u_t como entrada, un elemento a la vez, manteniendo en sus neuronas ocultas un “vector de estado” x_t el cual implícitamente contiene información acerca de todos los elementos anteriores a la secuencia

procesada LeCun, Bengio, y Hinton (2015). La formulación general de este concepto, es presentada en la ecuación 2.4.6, donde x_t es el vector de estado en tiempo t y u_t se refiere a la entrada en el paso t , siendo θ los parámetros a aprender.

$$x_t = F(x_{t-1}, u_t, \theta) \quad (2.4.6)$$

Las redes recurrentes son sistemas dinámicos muy poderosos, pero su entrenamiento es muy problemático dado que su gradiente al ser retropropagado crece o disminuye en cada paso, así que sobre cada paso típicamente explotan o desaparecen (LeCun, Bengio, y Hinton, 2015), para tratar de solucionar este problema se propuso un tipo especial de red recurrente conocida como LSTM, por sus siglas en inglés (Long Short Term Memory).

LSTM - Red de memoria a corto y largo plazo.

Propuestas originalmente por (Hochreiter and Schmidhuber, 1997), para tratar los problemas de explotación y desvanecimiento de gradientes en redes recurrentes. Las redes LSTM, son un tipo especial de red recurrente que conserva las dependencias largas de maneras más efectivas, en comparación con una red recurrente básica, utilizan múltiples capas para regular el monto de información que será permitida en cada estado de nodo. La figura 2.1 muestra la estructura interna de una celda de una LSTM. Donde x_t , o y h_t representan la entrada, salida y el estado oculto en tiempo t . c_{t-1} es la información llevada del estado $t - 1$ al estado t , el cual será combinado con la entrada x_t y el estado oculto h_{t-1} para formar el estado oculto h_t y el arrastre de c_t el cual será enviado al siguiente paso.

Redes recurrentes bidireccionales

Las redes recurrentes convencionales consideran una estructura causal, significando que cada estado en tiempo t captura solo información del pasado, x, \dots, x^{t-1} , y la entrada actual x^t . Sin embargo, en muchas aplicaciones es deseable realizar una predicción de y^t que dependa de la secuencia entera, las RNNs bidireccionales fueron propuestas para resolver ese problema (Schuster and Paliwal, 1997). Una red recurrente bidireccional combina dos redes recurrentes normales, una red comenzando desde el inicio del texto con otra comenzando desde el fin del texto, para obtener una representación final se combina la red hacia adelante y hacia atrás, mediante alguna

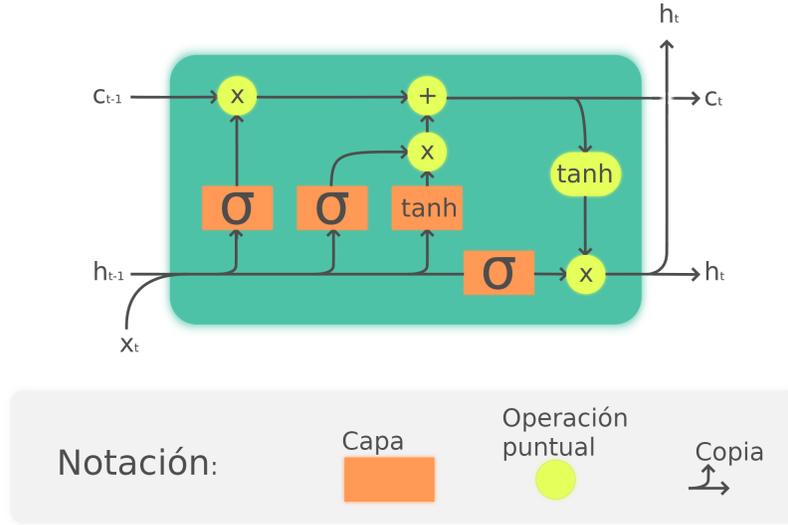


Figura 2.1: Una celda de LSTM desdoblada sobre el tiempo. Obtenida de Wikimedia Commons y modificada bajo la licencia Creative Commons 4.0

operación con tensores (suma, concatenación, multiplicación o promedio).

Redes Neuronales Convolucionales (CNN)

Aunque originalmente fueron diseñadas para reconocimiento de caracteres en imágenes, las redes convolucionales han sido empleadas efectivamente para clasificación de textos (Kim, 2014; Zhang, Zhao, y LeCun, 2015; Zhang and Wallace, 2015; Conneau et al., 2016).

En el contexto de clasificación de textos, el principal objetivo de este tipo de redes es capturar un contexto local de las palabras en el documento, mediante la aplicación de un conjunto de filtros de tamaño $h \times d$. Si denotamos la dimensión de los vectores de palabras por d y el tamaño de la secuencia de entrada como s , entonces la dimensión de la matriz de la secuencia es $s \times d$ (véase la figura 2.2), se puede tratar la matriz de la secuencia como una imagen y hacer las operaciones de convolución sobre esta, vía filtros. Es razonable utilizar filtros con un ancho igual a la dimensión de los vectores de palabras (i.e., d). Así que solo varía la altura del filtro, i.e., el número de filas adyacentes identificado como **tamaño de filtro** o tamaño de núcleo Zhang and Wallace (2015).

Como se ilustra en la figura 2.2, los filtros forman capas de convolución, estas capas de convolución son llamadas mapas de características y pueden ser apiladas para

proporcionar múltiples filtros de la entrada. Para reducir la complejidad computacional, las CNNs utilizan una operación llamada **pooling** la cual reduce el tamaño de la salida de una capa a la siguiente en la red. Existen diferentes técnicas de pooling para reducir la salida y conservar características importantes. El pooling más empleado es el método de **max pooling**, el cual selecciona el elemento máximo en la ventana de pooling. Para pasar la salida de las capas de pooling, los mapas son *aplanados* en una columna. La capa final en una CNN es típicamente una capa totalmente conectada Kowsari et al. (2019).

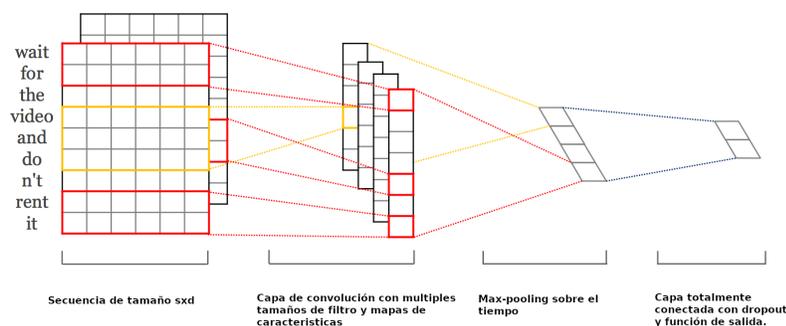


Figura 2.2: Red Convolutiva para clasificación de textos, imagen tomada de Kim (2014)

2.5. Medidas de Evaluación

Existen diferentes métricas para evaluar los modelos de aprendizaje computacional, dependiendo de lo que se quiera medir algunas de las más utilizadas son: exactitud, precisión, recuerdo y F1. Para ilustrar cada una de estas métricas, se parte de la clasificación binaria como ejemplo. La tabla 2.1, conocida como matriz de confusión, resume los resultados de un clasificador. A continuación, se describen los principales conceptos⁵.

La matriz de confusión no es una medida como tal, pero las métricas de evaluación están basadas en los números dentro de esta.

- 1.- **Verdaderos Positivos (VP)**: Es el número total de predicciones en que la clase real es 1 (positiva) y la predicción también es 1 (positiva).

⁵Tomados de <https://medium.com/analytics-vidhya/complete-guide-to-machine-learning-evaluation-metrics-615c2864d916>

Tabla 2.1: Matriz de confusión.

	Predicción: 1	Predicción: 0
Real: 1	<i>VP</i>	<i>FN</i>
Real: 0	<i>FP</i>	<i>VN</i>

- 2.- **Verdaderos Negativos (VN)**: Es el número total de predicciones en que la clase real es 0 (negativa) y la predicción también es 0 (negativa).
- 3.- **Falsos Positivos (FP)**: El número de predicciones en que la clase verdadera es 0 y la predicción es 1:
- 4.- **Falsos Negativos (FN)**: Es el número de predicciones en que la clase verdadera es 1 y la predicción es 0.

El escenario ideal sería que el modelo obtenga 0 falsos positivos y falsos negativos, pero este no es el caso en la vida real, el objetivo en ocasiones es tratar de minimizar ya sea los falsos positivos o los falsos negativos.

Exactitud: La proporción del número de ejemplos en el conjunto de evaluación que son correctamente clasificados por el modelo. La exactitud es utilizada cuando las clases tienen la misma importancia para la clasificación.

$$Exactitud = \frac{VP + VN}{VP + VN + FN + FP} \quad (2.5.1)$$

Precisión: Es la proporción del número de instancias positivas predichas correctamente.

$$Precisión = \frac{VP}{VP + FP} \quad (2.5.2)$$

Recuerdo: Representa la proporción de las instancias positivas que lograron ser recuperadas.

$$Precisión = \frac{VP}{VP + FN} \quad (2.5.3)$$

Medida F1: Es el promedio armónico de precisión y recuerdo. Proporciona una puntuación más realista al considerar a la precisión y el recuerdo.

$$F_1 = \frac{2 * precision * recuerdo}{precision + recuerdo} \quad (2.5.4)$$

Trabajo Relacionado

Descubrir los rasgos de un autor anónimo es de interés para la comunidad científica en procesamiento de lenguaje natural. Existen numerosas razones, una de ellas es aprovechar el constante flujo de información en redes sociales para entender mejor el lenguaje coloquial de uso diario, hacer que nuestras máquinas puedan identificar emociones, estados de ánimo, el género y edad del usuario, etc. Muchos esfuerzos y avances se han realizado en la última década.

En este capítulo se presenta, por un lado, el trabajo previo en área de perfilado de autor, en específico, los foros de evaluación PAN@CLEF y eRisk, por otro lado, se presenta una revisión general del aumento de datos en tareas de clasificación de textos. Cabe aclarar que no existen estudios específicamente orientados al aumento de datos en la tarea de perfilado de autor.

3.1. Perfilado de autor

Los trabajos en perfilado de autor se han enfocado a identificar diversos rasgos de los autores: género, edad, nivel educativo, ocupación, rasgos de personalidad, tendencia política. Incluso han ido más allá al tratar de determinar características de comportamiento y condiciones médicas (trastornos como la anorexia o la depresión clínica).

Los primeros trabajos, motivados por la sociolingüística, utilizaron documentos formales: libros, ensayos y/o noticias; variando el tamaño del corpus estudiado de docenas a cientos de documentos. Uno de los primeros trabajos en perfilado de autor, usando medios automáticos, fue presentado por (Pennebaker, Mehl, y Niederhoffer, 2002). Los investigadores presentan evidencia que liga el uso de las palabras con

aspectos de personalidad, situaciones sociales y psicológicas. (Argamon et al., 2009) demostró que se puede conocer el género, edad, lengua nativa y personalidad con un buen margen de exactitud, a través de ensayos personales de estudiantes. Las características encontradas como relevantes fueron estilísticas, por ejemplo, el uso de pronombres, preposiciones y verbos modales.

En la actualidad, la investigación se ha enfocado determinar el perfil del autor utilizando datos extraídos de redes sociales, blogs y foros en línea. A continuación, se presentan algunos de los trabajos más relevantes para esta tesis, presentados en las conferencias PAN@CLEF, siendo una de las pioneras en su tipo, al incluir el perfilado de autor en todas sus ediciones.

PAN@CLEF

El mayor evento anual en perfilado de autor, PAN es parte de las competencias organizadas bajo el marco del CLEF (Rangel et al., 2013; Rangel and Rosso, 2019). En este evento se ha estudiado el perfilado de autor desde una perspectiva multi-idioma, siendo el idioma inglés y el español de los más frecuentes. Las características recurrentes a perfilar han sido género, edad y personalidad (Rangel et al., 2013; Rangel and Rosso, 2019; Rangel et al., 2016; Stamatatos et al., 2015). La mayoría del trabajo existente se distingue por (i) el preprocesamiento, (ii) la extracción de características o (iii) el método de clasificación.

La técnica más común de **preprocesamiento** entre los participantes, es remover o enmascarar elementos específicos de las redes sociales (*hashtags*, menciones de usuario, enlaces a páginas web, emoticones) (Daneshvar and Inkpen, 2018; Jimenez-Villar et al., 2019; Pizarro, 2019). Además de convertir las palabras a minúsculas, utilizar lematización o *stemming*; algunos participantes remueven puntuación, palabras de paro y caracteres especiales.

En cuanto a la **extracción de características**, los n-gramas de caracteres y palabras, son ampliamente usados, en efecto las mejores soluciones propuestas para el perfilado de género en el PAN 2017, 2018 y 2019 utilizaron un ensamble de n-gramas de caracteres y n-gramas de palabras (Basile et al., 2017; Daneshvar and Inkpen, 2018; Pizarro, 2019). En estos trabajos se ha identificado que una representación mediante n-gramas de caracteres puede ser capaz de capturar fragmentos relacionados con la estructura y estilo del texto. Algunas implementaciones, también han propuesto esquemas de pesado, inspirados en *tf-idf* poniendo énfasis en el estilo y contenido de

los textos.

Con respecto a los **algoritmos de clasificación**, existe una gran cantidad de enfoques, siendo lo más común el algoritmo de máquinas de soporte vectorial (SVM). Un punto importante a destacar, es que a partir del año 2018 se han presentado algunas propuestas utilizando aprendizaje profundo; mediante la utilización de representaciones distribucionales (e.g., word2vec, glove, etc.), en combinación con diferentes arquitecturas de red basadas en redes recurrentes y redes convolucionales. Sin embargo, hasta la fecha no han podido superar a los algoritmos tradicionales.

La primera vez que un enfoque de aprendizaje profundo, concretamente una arquitectura CNN, aparece entre los primeros lugares (lugar once) fue en la conferencia PAN@2019 (Rangel and Rosso, 2019).

Es importante notar que, a diferencia de los enfoques tradicionales, en el caso de los modelos basados en redes neuronales, la extracción de características está implícita en su arquitectura.

3.1.1. Detección de trastornos mentales en redes sociales

Uno de los primeros estudios, en la detección de depresión mediante medios automáticos (Rude, Gortner, y Pennebaker, 2004), encontró que los participantes deprimidos utilizan más palabras negativas y el uso del pronombre “yo” (“I” en inglés) más que los no deprimidos.

Moviéndose a la investigación en redes sociales (De Choudhury et al., 2013), empleó *crowdsourcing* (una forma de colaboración, empleando a múltiples personas a través del Internet) para obtener un conjunto de usuarios de Twitter, quienes reportaron ser diagnosticados con depresión clínica, en este trabajo demostraron el uso potencial de Twitter como una fuente de información para medir signos de depresión mayor en individuos. Encontraron que los individuos con depresión muestran baja actividad social, emociones negativas, egocentrismo, expresión de preocupaciones médicas y relacionales, además de pensamientos religiosos. Estos atributos fueron considerados para construir un clasificador SVM alcanzando una exactitud del 70%. Estos resultados demostraron la factibilidad de perfilar usuarios con signos de depresión en redes sociales.

Sin embargo, la creación de colecciones de documentos para abordar este tipo de problemas es costosa y difícil. Bajo estas condiciones y debido al particular interés en

el perfilado de características de comportamiento (Kumar et al., 2018) y trastornos mentales (De Choudhury et al., 2013), se han desarrollado conferencias y competencias específicas. Una de ellas es la conferencia eRisk (Losada, Crestani, y Parapar, 2018). El principal objetivo de este foro es la detección temprana de un trastorno a través de los historiales de comunicación de un usuario en blogs. Independientemente del enfoque de detección temprana, también es de interés tratar la detección considerando todo el historial de un usuario como un solo documento.

El eRisk 2018 presentó dos tareas: detección de depresión y detección de anorexia. En ambos casos se trata de un problema de clasificación no temática con datos desbalanceados.

eRisk 2018

En la edición eRisk 2017 (Losada, Crestani, y Parapar, 2017, 2018), los organizadores construyeron un conjunto de datos con publicaciones de usuarios deprimidos y no deprimidos extraídos de la red social Reddit. En eRisk 2018 se complementó el conjunto original con más usuarios y se agregó la tarea de detección de anorexia. Para abordar estas tareas se evaluaron un total de 45 contribuciones de diferentes instituciones, algunas de las propuestas dieron un tratamiento estándar, experimentado con diferentes características, LDA, n-gramas de palabras y diferentes esquemas de pesado (Cacheda et al., 2018; Almeida, Briand, y Meurs, 2017; Ortega-Mendoza et al., 2018b). Mientras que muy pocos utilizaron enfoques de aprendizaje profundo: (Trotzek, Koitka, y Friedrich, 2018; Wang, Huang, y Chen, 2018; Liu et al., 2018).

El equipo TUA1 (Liu et al., 2018), además de presentar un modelo construido con una SVM Lineal, pesado *tf-idf* y normalización *l2*, también construyeron un modelo basado en una arquitectura compuesta de una red CNN, que actúa como extractor de características, y una LSTM. En su configuración experimental utilizaron una longitud de entrada de 2000 tokens, 64 filtros para la red CNN de tamaño 5, *MaxPooling* de tamaño 4, un factor de 0.25 para *dropout* y *Relu* como función de activación. Para la fase de entrenamiento, eligieron entropía cruzada binaria para la función de pérdida y el optimizador *Adam*. Mediante este modelo neuronal se obtuvieron 0.29 de *F1*, en la tarea de depresión y 0.36 para la detección de anorexia.

Los investigadores que conformaron el equipo TBS (Wang, Huang, y Chen, 2018), abordaron las tareas como un problema de clasificación de oraciones y presentaron un modelo basado en CNN, en combinación con un pesado *tf-idf*; obteniendo 0.26 de

$F1$ para la detección de depresión y 0.67 para anorexia.

El equipo ganador (Trotzek, Koitka, y Friedrich, 2018) FHDO-BCSG, presento 5 modelos de clasificación diferentes para la detección de depresión. El mejor modelo fue un ensamble de bolsas de palabras BOW, con diferentes tipos de pesado y n-gramas, el algoritmo de clasificación utilizado fue regresión logística, utilizando un peso modificado para cada clase para incrementar el costo de los falsos negativos; obteniendo 0.64 de $F1$ para depresión y 0.81 para la detección de anorexia. Además, presentaron un modelo basado en una red *CNN*, utilizando vectores *FastText* de 300 dimensiones, entrenados con documentos extraídos de un corpus de 1.37 billones de comentarios en Reddit, una longitud de entrada de 100 tokens, una capa de convolución, 100 filtros con altura igual a 2 y con un ancho correspondiente al tamaño de los vectores de palabras, max pooling de tamaño 1 y *CReLU* como función de activación; resultando en un vector de 200 dimensiones por documento que es propagado a través de cuatro capas totalmente conectadas. El entrenamiento fue realizado utilizando el optimizador *Adam* para minimizar la entropía cruzada, mediante un tamaño de batch de 10,000 documentos de 100 palabras y una tasa de aprendizaje de $1e - 4$ durante 30 épocas. Este modelo logró obtener una puntuación $F1$ de 0.54 para la detección de depresión y 0.81 para anorexia. Agregando características extraídas manualmente lograron mejorar la puntuación $F1$ a 0.85 para la detección de anorexia.

En general la tarea de detección de depresión fue la más difícil y de un total de 45 modelos evaluados, la puntuación $F1$ promedio fue de 0.42 mientras que para anorexia 0.56, indicando que aún falta mucho para mejorar en estas tareas.

eRisk 2019

El propósito general de esta conferencia fue, evaluar las metodologías y técnicas empleadas para la detección temprana de signos de depresión (Losada, Crestani, y Parapar, 2019a). A diferencia de la edición anterior, la tarea de detección de depresión tuvo un nuevo enfoque, fue orientada a analizar las publicaciones de un usuario en redes sociales con el objetivo de extraer evidencia útil para estimar el nivel de depresión de un usuario, esto fue posible mediante el completado automático de un cuestionario, basado en el inventario de Beck Beck et al. (1961).

En esta edición destacó un mayor uso de modelos de aprendizaje profundo para tratar el tema como un problema de clasificación. Los modelos más utilizados fueron basados en redes recurrentes y convolucionales. Algunos participantes se enfocaron en

conseguir más datos de entrenamiento como, por ejemplo: tomar los datos etiquetados de ediciones anteriores, incorporar información extensa y recuperar datos de la red social Reddit. Resalta el hecho que los equipos que utilizaron más evidencia para construir sus modelos de aprendizaje obtuvieron los mejores resultados.

El equipo CAMH (Abed-Esfahani et al., 2019), alcanzó una mayor puntuación en predecir la categoría correcta a nivel de depresión, utilizando el modelo de lenguaje preentrenado GPT-1 como extractor de características y adicionando características de la herramienta LIWC (Pennebaker, Francis, y Booth, 2001). Utilizando un enfoque no supervisado, lograron obtener un 45 % en la métrica DCHR la cual calcula la fracción de casos donde el cuestionario automático indica una categoría de depresión equivalente a la categoría del cuestionario real.

El equipo UNSL (Burdisso, Errecalde, y Montes-Y-Gómez, 2019), obtuvo el mejor desempeño para predecir el cuestionario a nivel pregunta obteniendo una puntuación del 41.43 % en AHR (el promedio de todos los usuarios, en que el cuestionario automático tiene exactamente la misma respuesta que el real) y un 40 % en DCHR. Esta propuesta consistió en utilizar los datos de entrenamiento de la tarea eRisk 2018 y un algoritmo de clasificación diseñado específicamente para las tareas de detección temprana.

Aunque la efectividad de los modelos es aún modesta, los experimentos sugieren que la evidencia adicional extraída de redes sociales es útil y las herramientas automáticas o semi-automáticas pueden ser diseñadas para detectar individuos en riesgo (Losada, Crestani, y Parapar, 2019b).

3.2. Aumento de datos

El aprendizaje profundo típicamente requiere grandes cantidades de datos etiquetados para tener éxito. El aumento de datos promete resolver el problema, de la necesidad de más datos etiquetados, básicamente consiste en aplicar una serie de transformaciones a un ejemplo original, para obtener un nuevo dato, a partir de éste.

El término **aumento de datos**, se refiere a métodos para construir una optimización iterativa o algoritmos de muestreo mediante la introducción de datos no observados o variables latentes (Van Dyk and Meng, 2001). La idea del aumento de datos nació en problemas de **datos incompletos**, como una forma de completar las celdas faltantes en una tabla de contingencia balanceada (Dempster, Laird, y Rubin,

1977). El aumento de datos automático, es mayoritariamente utilizado en tareas relacionadas con visión computacional y ayudan a hacer un entrenamiento más robusto, particularmente, cuando el tamaño de los datos es pequeño.

Derivado del estudio del estado del arte en aumento de datos, las técnicas de aumento de datos se pueden clasificar en dos categorías (ninguna restringida a un solo dominio): aquellas que se basan en aprendizaje supervisado y las que utilizan un enfoque semi-supervisado. Las basadas en un enfoque supervisado crean nuevos ejemplos a partir de datos previamente etiquetados. Las que utilizan un enfoque semi-supervisado obtienen ejemplos totalmente nuevos de un modelo supervisado, supervisado débil o heurísticas conociendo la naturaleza de los datos.

3.2.1. Aumento de datos supervisado

El objetivo es crear datos de entrenamiento nuevos y de aspecto realista mediante la aplicación de una transformación a un ejemplo, sin cambiar su etiqueta. Formalmente, sea $q(\hat{x}|x)$ la transformación de aumento de la cual podemos extraer ejemplos aumentados \hat{x} basado en un ejemplo original x . Para que una transformación de aumento sea válida, es requerido que cualquier ejemplo $\hat{x} \sim q(\hat{x}|x)$ extraído de la distribución, comparta la misma etiqueta de verdad que x , es decir $y(\hat{x}) = y(x)$, (Xie et al., 2019).

El aumento de datos supervisado puede ser equivalentemente visto como, construir un conjunto aumentado etiquetado del conjunto original y entrenar el modelo en el conjunto aumentado. El punto crítico es, cómo diseñar esa transformación, en la literatura podemos encontrar dos grupos de algoritmos para **crear** ejemplos de entrenamiento adicionales: los que operan **a nivel estructural**, los cuales crean transformaciones en un ejemplo (imagen, cadena de caracteres, texto, etc.) (Zhong et al., 2017), y **sobremuestreo sintético** creando ejemplos adicionales a nivel características, es decir, en un espacio vectorial (Chawla et al., 2002).

3.2.2. Aumento de datos semi-supervisado

Estos métodos tienen como característica general aprender un modelo inicial, para posteriormente etiquetar datos nuevos obtenidos de algún dominio similar y reentrenar el modelo con estos datos nuevos. Tomando la definición de (Xie et al., 2019), la forma general de estos trabajos puede ser resumida como sigue:

- Dada una entrada x , se calcula la distribución $p_\theta(y|x)$ dado x y una versión con ruido $p_\theta(y|x, \epsilon)$ mediante la introducción de un pequeño ruido ϵ . El ruido puede ser aplicado a x o estados ocultos.
- Minimizar una métrica de divergencia entre las dos distribuciones $D(p_\theta(y|x)||p_\theta(y|x, \epsilon))$.

Este procedimiento obliga al modelo a ser insensible al ruido ϵ y suave con respecto a los cambios en el espacio de entrada. Desde otra perspectiva, minimizando la pérdida de consistencia gradualmente se propaga la información de la etiqueta de ejemplos etiquetados a ejemplos no etiquetados (Miyato et al., 2019).

3.2.3. Aumento de datos en clasificación de textos

El aumento de datos ha sido ampliamente utilizado en tareas de visión computacional (Cubuk et al., 2019), pero menos en tareas de procesamiento de lenguaje natural. En años recientes ha crecido el interés en proponer diversas técnicas para el aumento de datos en la clasificación de textos, a continuación, se mencionan algunos de los métodos más relevantes para este trabajo.

Basados en métodos semi-supervisados

Datos con ruido (Hedderich and Klakow, 2018), propusieron una capa de ruido la cual es agregada a una arquitectura de red neuronal, esto permite modelar el ruido y entrenar una combinación de datos limpios y con ruido. Para simular escenarios de pocos recursos, el entrenamiento fue realizado con diferentes tamaños de datos limpios, variando desde un 1% el conjunto original hasta un 10% (equivalentes de 407 ejemplos y 20,362 respectivamente). Comprobando que en un contexto de bajos recursos, en la tarea de reconocimiento de entidades nombradas (NER), la clasificación puede mejorar en términos de $F1$ en promedio hasta 10 puntos. Pero variando el tamaño del conjunto original a un 10% la ganancia obtenida no se observa, llegando a concluir que un 10% de datos limpios puede ser suficiente para entrenar el modelo y el ruido adicional puede perjudicar al modelo.

Reinforced Co-Training: (Wu, Li, y Wang, 2018), este método utiliza el algoritmo Q-learning para aprender una política de selección de datos y entonces explotar esta política para coentrenar clasificadores automáticamente. Realizaron experimentos en

la detección de *Clickbait*; este término se refiere a aquellos encabezados con el objetivo de atraer la atención del lector, pero los documentos usualmente tienen menos relevancia con los encabezados correspondientes. El etiquetado de este tipo de datos consume mucho tiempo y labor. En esta tarea lograron mejorar 3 puntos en términos de la métrica $F1$ en comparación con el modelo base entrenado en forma supervisada.

Supervisado débil (Han, Gao, y Ciravegna, 2019), propusieron una técnica de aumento de datos la cual consiste en incorporar ejemplos nuevos al conjunto de entrenamiento, mediante un etiquetado, basado en la búsqueda de similitudes relacionales en millones de tweets no etiquetados. Realizaron experimentos para la detección de rumores en redes sociales, logrando incrementar en promedio la métrica $F1$ entre 9 y 12 puntos en comparación con no hacer aumento de datos.

UDA (Xie et al., 2019), es una propuesta híbrida la cual consiste en utilizar métodos existentes de aumento de datos, reemplazo de sinónimos y traducción inversa, para aumentar datos etiquetados y no etiquetados. Mediante el entrenamiento fino del modelo no supervisado BERT, lograron aproximar el error de clasificación en 4 conjuntos de datos para la clasificación de opiniones, con un margen de un punto porcentual en comparación con el modelo entrenado en el conjunto completo de datos etiquetados. Con esto se logró comprobar que aún existe una brecha por rebasar cuando se comparan los métodos supervisados con los semi-supervisados.

Por lo general los esquemas para hacer aumento de datos de forma semi-supervisada han requerido de modelos complejos para poder implementarse. Si bien los resultados son prometedores y comparables con el estado del arte, no han logrado superar el estado del arte basado en modelos supervisados.

Basados en aprendizaje supervisado

Reemplazo de sinónimos mediante un tesoro (Zhang, Zhao, y LeCun, 2015): presentaron una exploración empírica de redes convolucionales a nivel carácter. Construyeron conjuntos de datos aumentados para la clasificación de opiniones, mediante el reemplazo de palabras por sus sinónimos utilizando un tesoro. Llegando a reducir el error de clasificación en un 1% menos, en comparación con el estado del arte, agregando aumento de datos en cuatro de ocho conjuntos de datos.

Aumento de datos contextual (Kobayashi, 2018): asumen que el sentido de las oraciones no cambia incluso si las palabras en las oraciones son reemplazadas por otras palabras con relaciones paradigmáticas. Este método, estocásticamente reemplaza pa-

labras con otras palabras que son predichas por un modelo de lenguaje bidireccional. Además, proponen un modelo de lenguaje condicionado a la etiqueta que permite al modelo aumentar oraciones considerando la información de la etiqueta. Mediante experimentos en 6 conjuntos de datos en clasificación temática de textos, logran mejorar la exactitud en un 1% en comparación con no hacer aumento de datos y menor a un 1% comparado con el remplazo de sinónimos.

EDA (Wei and Zou, 2019): se presenta como una alternativa simple y escalable en comparación con métodos de aumentos de datos basados en redes neuronales, EDA consiste en una combinación de cuatro operaciones a nivel palabra: reemplazo de sinónimos, inserción aleatoria, intercambio aleatorio y eliminación aleatoria. En cinco tareas de clasificación, muestran que se puede mejorar el rendimiento en redes convolucionales y recurrentes, alcanzado entre un 1 y un 2% en comparación con modelos sin aumento de datos.

Paráfrasis neuronal (Kumar et al., 2019): este trabajo propone un método para obtener paráfrasis neuronales mediante el modelo seq2seq, a diferencia de otros modelos para generar paráfrasis este método busca un balance entre la diversidad y la fidelidad de las oraciones generadas; para esto proponen optimizar una función que combine estos dos factores. Los autores evaluaron su propuesta para la clasificación de intención utilizando una red LSTM y regresión logística, obteniendo una mejora de un 3% en exactitud sobre el método base que es no hacer aumento de datos y de un 2% al compararse con el reemplazo de sinónimos.

Traducción de temas (Zhang, Lertvittayakumjorn, y Guo, 2019): este método traduce todas las palabras reemplazables de una oración a otras clases objetivo. Esta búsqueda de relaciones de similitud se realiza utilizando aritmética de vectores. Realizaron diversos experimentos para la clasificación de documentos mediante *zero-shoot text classification*, esta técnica de clasificación consiste en ser capaz de predecir categorías no vistas en la fase de entrenamiento. Mediante un esquema controlado de pocos recursos logran obtener ganancias de un 1 a un 8% en términos de exactitud, comparado con no hacer aumento de datos.

3.2.4. Discusión del trabajo relacionado

Al revisar la literatura de los métodos de aumento de datos basados en un enfoque supervisado, podemos observar que son complejos y en muchos casos, bajo un esquema

de experimentación controlando la cantidad de datos etiquetados, no logran superar a los modelos supervisados.

Todos los trabajos hasta ahora encontrados en la literatura de aumento de datos mediante un enfoque supervisado, están enfocados a la clasificación de textos cortos o clasificación temática, pero ni una enfocada a tareas de perfilado de autor o demostrado ser efectivos en conjuntos desbalanceados. En algunos casos como *EDA* el reemplazo es totalmente aleatorio o la estructura del documento se corrompe al incorporar operaciones de eliminación sobre las palabras, en otros como el reemplazo de sinónimos no siempre se asegura que la palabra a reemplazar pertenezca a la misma categoría que la palabra original. Los trabajos que respetan la estructura de la oración original están basados en modelos de redes neuronales, pero es difícil hacerlos escalables.

En la tabla 3.1, se presentan las principales características de los diferentes enfoques supervisados, relevantes para este trabajo, en comparación con el método propuesto. La propuesta de Kumar et al. (2019), puede considerarse que respeta el estilo contenido de los textos, mediante la realización de una paráfrasis neuronal, pero este enfoque tiene la desventaja de utilizar un conjunto de datos externos, para aprender a hacer la paráfrasis y considerando que se cuente con este recurso, el tiempo tomado para hacer una paráfrasis neuronal o predecir palabras mediante un modelo de lenguaje hace que el método no sea escalable.

En el caso de perfilado de autor, es necesario que los nuevos ejemplos aumentados respeten tanto el estilo (i.e., la estructura original) como el contenido del texto, por lo que en este trabajo se proponen métodos de aumento de datos a nivel palabra que consideren el estilo y contenido del documento original; considerando estilo como la forma o modo de expresar el contenido, siendo el contenido el tema o mensaje a transmitir.

Los resultados hasta ahora alcanzados muestran un beneficio del uso del aumento de datos, no obstante, estos beneficios son aún modestos. Por otro lado, las técnicas simples de aumento de datos a nivel palabra han demostrado ser efectivas y escalables, y obtienen resultados comparables con técnicas complejas como la paráfrasis neuronal o modelos de lenguaje.

Tabla 3.1: Comparación del método propuesto con el estado del arte en aumento de datos para clasificación de textos.

Método	Clasificación	Datos desbalanceados	Recurso externo	Nivel	Selección	Reemplazo
Zhang, Zhao, y LeCun (2015)	Minería de opiniones	No	Tesaurus	Palabra	Aleatoria	Sinónimos
Kobayashi (2018)	Temática	No	Datos no etiquetados	Secuencia	Aleatoria	Similitud
Wei and Zou (2019)	Minería de opiniones	No	Tesaurus	Palabra	Aleatoria	Sinónimos
Kumar et al. (2019)	Temática	No	Datos alineados	Oración	No aplica	Paráfrasis
Zhang, Lertvittayakumjorn, y Guo (2019)	Temática	No	Glove	Secuencia	Restringida	Similitud
Propuesta	Perfilado	Si	Glove	Palabra	Restringida	Similitud

Método propuesto

En el capítulo 3 se describieron los principales retos del perfilado de autor y las principales características de los métodos existentes para el aumento de datos en la clasificación de textos. Observando las características de los métodos de aumento de datos existentes, en este capítulo se describen los métodos propuestos para hacer el aumento de datos, para tareas relacionadas al perfilado de autor.

Como se mostró en el capítulo anterior, existen numerosas técnicas de aumento de datos, sin embargo, no todas son generalizables o escalables, además de que, en el caso de perfilado de autor se desea conservar tanto el estilo como el contenido de un texto, considerando el estilo como la forma o modo de expresar el contenido, siendo el contenido el tema o mensaje a transmitir. De ahí que la mejor forma de hacer el aumento de datos en esta tarea es mediante el parafraseo humano, pero debido a su costo, no siempre es posible. En cambio, podemos apoyarnos de técnicas automáticas para aproximarse al parafraseo (Androutsopoulos and Malakasiotis, 2010). Cabe mencionar que el resultado de estos métodos automáticos difícilmente obtiene paráfrasis de las oraciones originales.

El aumento de datos propuesto busca conservar el estilo de las frases originales, y con ellas incrementar el conjunto original. Los métodos desarrollados en este trabajo tienen dos pasos generales que se describen a continuación:

- 1.- **Selección de palabras a reemplazar:** El primer paso consiste en identificar el subconjunto de palabras a reemplazar. Dos criterios son relevantes en esta etapa: (i) la importancia de la palabra en la estructura de la frase, es decir, no se tiene el mismo efecto si se reemplaza una palabra de contenido que una palabra funcional; (ii) la cantidad de palabras a reemplazar, dado que se desea conservar la misma interpretación de la frase original, el número de reemplazos

deberá controlarse.

2.- Reemplazo de palabras seleccionadas: Una vez determinado el subconjunto de palabras a reemplazar, se deberán identificar nuevas palabras que no alteren significativamente el sentido de la frase original. Para esto se recurre a un recurso externo, tal como un tesoro, un diccionario, o incluso a modelos distribucionales de vectores de palabras. Después de identificar las palabras sustitutas se reconstruye la secuencia manteniendo el orden original para formar la nueva secuencia aumentada.

Es importante mencionar que los métodos de aumento de datos propuestos son independientes del conjunto de datos. De hecho, no se utiliza la oración como unidad básica, sino una secuencia de palabras de longitud fija. De esta forma el conjunto original es fragmentado obteniendo un conjunto S de secuencias de tamaño fijo. Los métodos de aumento de datos recorren, este conjunto S , obteniendo una nueva aproximación \hat{s} para cada secuencia s en S . El nuevo conjunto \hat{S} obtenido se agrega al conjunto original S aumentando el conjunto de entrenamiento. Este proceso sobre el conjunto original S puede repetirse n veces, incrementando sucesivamente el conjunto de entrenamiento para la clase de interés. En el caso particular de este trabajo, nos interesa analizar el aumento de datos en situaciones con colecciones de datos desbalanceadas, de ahí que el aumento de datos se aplica a la clase minoritaria, es decir, la clase de interés.

4.1. Selección de palabras a reemplazar

El primer punto bajo este proceso es el cálculo del número de palabras a reemplazar. Para esto, se retomó el criterio presentado en (Zhang, Zhao, y LeCun, 2015). El número de palabras a reemplazar r se selecciona mediante un muestreo aleatorio de una distribución de probabilidad geométrica.

Una función de probabilidad geométrica es la función de probabilidad del número X del ensayo de Bernoulli de obtener éxito, soportado en el conjunto de los números naturales. Una distribución geométrica da la probabilidad de que la primera ocurrencia de éxito requiere de k ensayos independientes, cada uno con una probabilidad de éxito p . Si la probabilidad de éxito de cada ensayo es p , entonces la probabilidad

de que en el k -ésimo ensayo, de k ensayos, sea el primer éxito es representada en la ecuación 4.1.1.

$$Pr(X = k) = (1 - p)^{k-1}p \quad (4.1.1)$$

Por lo tanto, la aleatoriedad del número r es controlada mediante la modificación del parámetro p como se representa en figura 4.1. Como puede verse en dicha figura, mientras menor sea el valor de p se modificará un mayor número de palabras, agregando una mayor diversidad y consecuentemente incrementando la probabilidad de alterar el significado original.

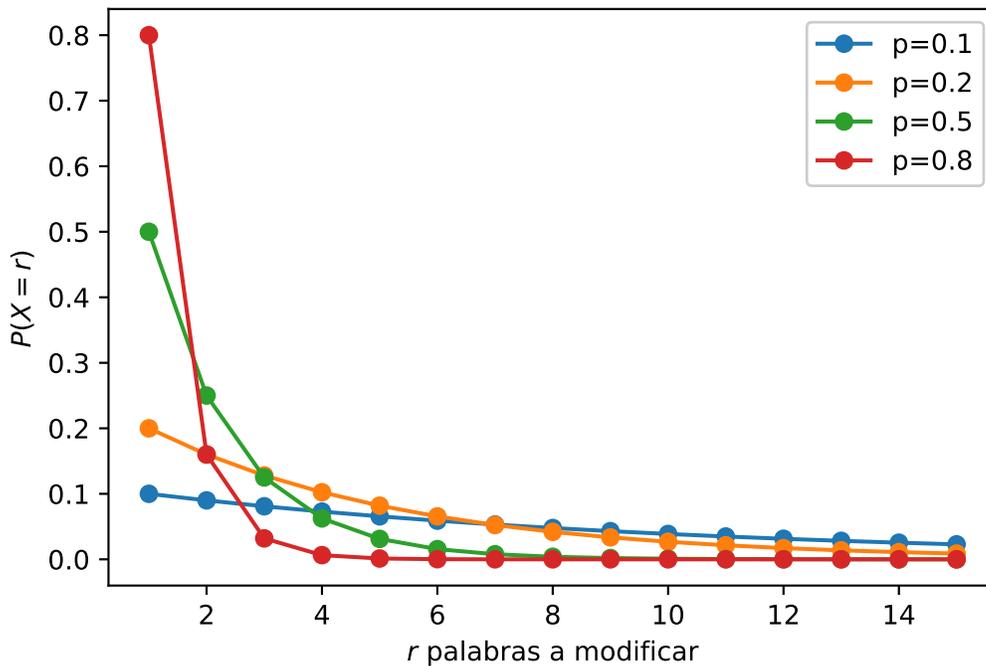


Figura 4.1: Función de masa para la distribución geométrica con diferentes valores de probabilidad.

4.1.1. Etiquetado de partes de la oración

El proceso de selección debe cuidar la modificación de ciertas partes de la oración, por un lado, evitar perder la interpretación original y por otro intentar conservar

el estilo de la frase original. Por tal motivo, cada frase es etiquetada asignando a cada palabra su etiqueta POS (*part of speech*) correspondiente. La tabla 4.1 muestra un ejemplo del etiquetado aplicado. Gracias al etiquetado, las palabras a reemplazar solo son aquellas que están más fuertemente asociadas al contenido de la frase, es decir, solo se seleccionan aquellas palabras con funciones gramaticales de: sustantivo, adjetivo, verbo y/o adverbio.

Tabla 4.1: Ejemplo de etiquetado de partes de la oración.

Secuencia	<i>I</i>	<i>am</i>	<i>running</i>	<i>out</i>	<i>of</i>	<i>ideas</i>
Etiqueta	PRP	VBP	VBG	IN	IN	NNS
Equivalencia	Pronombre	Verbo	Verbo	Preposición	Preposición	Sustantivo

4.1.2. Exclusión de palabras importantes

Además de las palabras funcionales, también es deseable mantener palabras que aportan información para la tarea de clasificación que se desea realizar, por lo tanto, la primera propuesta consiste en evitar seleccionar, entre las palabras a reemplazar, aquellas palabras dependientes a la clase del documento.

Para este proceso, recurrimos a la técnica de selección de características conocida como prueba de independencia χ^2 (chi cuadrada). En estadística, la prueba χ^2 es aplicada para comprobar la independencia de dos eventos, donde los eventos A y B son definidos a ser independientes si $P(AB) = P(A)P(B)$ o, equivalente, $P(A|B) = P(A)$ y $P(B|A) = P(B)$. En la selección de características para la clasificación de textos, los dos eventos son: *ocurrencia del término* y *ocurrencia de la clase*. Posteriormente se ordenan los términos de mayor a menor respecto a la ecuación 4.1.2.

$$\chi^2(D, t, c) = \sum_{e_t \in \{0,1\}} \sum_{e_c \in \{0,1\}} \frac{(N_{e_t e_c} - E_{e_t e_c})^2}{E_{e_t e_c}} \quad (4.1.2)$$

El término e_t indica la ausencia o presencia del término t en el documento, similarmente el término e_c indica si el documento se encuentra en la clase c . N es la frecuencia observada en D y E es la frecuencia esperada. χ^2 mide por cuanto los conteos esperados E y los conteos observados N se desvían de cada uno. Un valor alto de χ^2 indica que la hipótesis de independencia, la cual implica que los conteos

esperados y observados son similares, es incorrecta. Si los dos eventos son dependientes, entonces la ocurrencia del término hace la ocurrencia de la clase más probable (o menos probable), entonces el término debería ser seleccionado como relevante.

A través de este método se identifican todas aquellas palabras dependientes de la clase y, por ende, de relevancia para la tarea de clasificación. Dada la importancia de estas palabras se evitará reemplazarlas, excluyéndolas del proceso de selección de palabras a reemplazar.

4.2. Reemplazo de palabras seleccionadas

Una vez identificadas las palabras a reemplazar, el siguiente paso es, mediante la consulta de alguna fuente de conocimientos externa, buscar palabras candidatas similares a la palabra que se desea reemplazar. En (Zhang, Zhao, y LeCun, 2015) proponen consultar un tesoro con el objetivo de obtener los sinónimos de una palabra, sin embargo, el vocabulario contenido en el tesoro puede ser muy limitado o demasiado formal para el contexto del texto a aumentar.

Una alternativa es buscar palabras similares a través de representaciones distribucionales de las palabras. La idea general de las representaciones distribucionales es codificar los *tokens* de un vocabulario de tamaño finito $|V|$, en un vector que lo represente en espacio de palabras. La principal intuición de este enfoque es que deberá existir algún espacio n -dimensional, tal que $n < |V|$, donde codificar toda la semántica de un idioma. Cada dimensión codificará algún tipo de información, por ejemplo: las dimensiones semánticas podrían indicar el tiempo de conjugación (pasado, presente o futuro), de conteo (singular o plural) y género (masculino o femenino). En la subsección 2.2.4 se describen los modelos del estado del arte que siguen esta metodología.

El presente trabajo explora dos enfoques utilizando este recurso, la siguiente sección explica ambos enfoques.

4.2.1. Similitud relacional

Las representaciones distribucionales calculadas utilizando redes neuronales son muy interesantes debido a que los vectores aprendidos codifican muchas regularidades lingüísticas y patrones (Mikolov et al., 2013). Una de estas regularidades es la

sinonimia y puede ser recuperada mediante alguna medida de distancia entre una palabra objetivo w y el resto del vocabulario V . Esto se puede observar en la figura 4.2, en la cual se proyectan los vectores correspondientes a las palabras en un plano de dos dimensiones. En la figura, se observan las distancias entre palabras relacionadas con la palabra *depresión* las cuales aparecen cercanas a una palabra, cuyo significado es más contrastante como la palabra *feliz*.

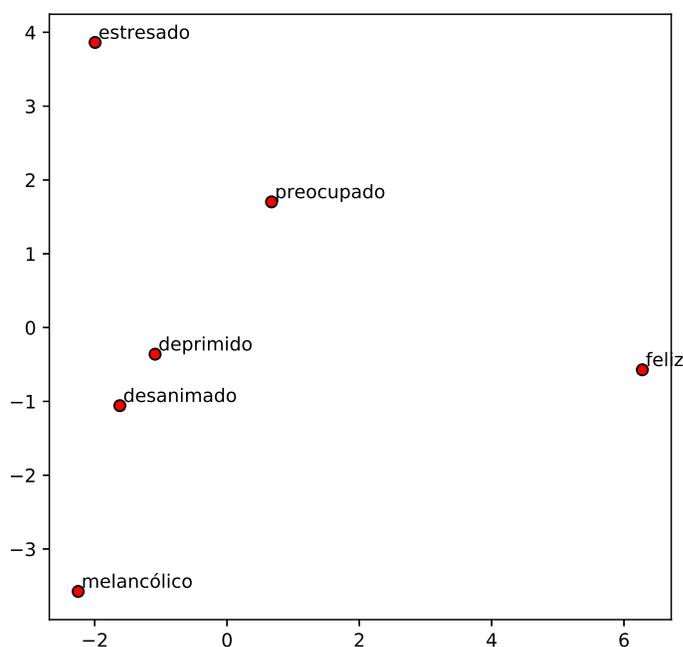


Figura 4.2: Ejemplo comparando las distancias entre las proyecciones de los vectores de palabras relacionadas a la palabra *depresión* en contraste a la palabra *feliz*.

Reemplazo por similitud relacional coseno

La primera propuesta de reemplazo utiliza las representaciones distribucionales para reemplazar una palabra en una secuencia, por una palabra similar o altamente relacionada (i.e., aparecen en contextos similares). Para realizar esto se recupera el vector de la palabra a reemplazar de un modelo preentrenado de vectores de palabras y se calcula la distancia respecto a cada vector (representación de una palabra) en

el modelo preentrenado. En este caso, hemos usado la medida de similitud coseno, véase la ecuación 4.2.1. Esta ecuación indica que para obtener la distancia coseno de dos vectores de palabras se debe hacer un producto punto entre los vectores (\vec{w}, \vec{v}) y dividir el resultado por la multiplicación de la magnitud de los mismos.

$$\cos(\vec{w}, \vec{v}) = \frac{\vec{w} \cdot \vec{v}}{\|\vec{w}\| \|\vec{v}\|} = \frac{\sum_{i=1}^n w_i v_i}{\sqrt{\sum_{i=1}^n (w_i)^2} \sqrt{\sum_{i=1}^n (v_i)^2}} \quad (4.2.1)$$

Específicamente para encontrar el conjunto de palabras candidatas W , dada una palabra w se buscan las k palabras más similares a w de acuerdo con la ecuación 4.2.2.

$$\operatorname{argmax}_{v \in V} (\cos(\vec{w}, \vec{v})) \quad (4.2.2)$$

Donde \vec{v} es la representación vectorial de cada palabra en el vocabulario V de vectores preentrenados y \vec{w} es la representación vectorial de la palabra a sustituir. Una alta similitud coseno (cercana a 1) significa que los vectores comparten una dirección muy similar y por lo tanto hay una mayor probabilidad que las palabras sean utilizadas en los mismos contextos. En la tabla 4.2 se muestra el ejemplo de una secuencia, aumentada mediante este método, las palabras en negritas no se modifican debido a que son palabras con alta puntuación χ^2 y en cursiva son resaltadas las palabras que se reemplazaron de la secuencia original. En el ejemplo la palabra *morning* tiene como palabras candidatas las palabras: *sunday*, *afternoon* y *evening*. Aunque estas palabras no representan sinónimos de *morning*, si conservan la misma etiqueta POS manteniendo el estilo de la secuencia original.

Tabla 4.2: Ejemplos del aumento de datos, para el método con restricción χ^2 y sustitución por similitud relacional.

	Secuencia
Original	just waking up every morning and talking to my gf
Aumentada	just waking up every <i>sunday</i> and talking to my gf
Aumentada	just waking up every <i>afternoon</i> and talking to my gf
Aumentada	just <i>woke</i> up every <i>evening</i> and talking to my gf

Reemplazo por relaciones equivalentes

Una de las características deseables en el aumento de datos es agregar un grado de diversidad o variabilidad en nuestros datos, sin embargo, al utilizar las representaciones distribucionales encontramos que las palabras con alta similitud coseno a una palabra, son por lo general variaciones pequeñas de esta misma palabra, por ejemplo, en la figura 4.3 lo más cercano a *llorar* es *llorando*. En este caso notamos que la diversidad deseada no se logra. Otro problema encontrado al calcular la similitud coseno entre dos palabras, dados sus vectores, es encontrar que palabras como *llorar* y *reír* suelen ser similares. Esto sucede porque ambas palabras ocurren en contextos de uso similares. Sin embargo, no deseamos hacer este tipo de sustituciones ya que sustituir una palabra por su antónimo (en lugar de un sinónimo) podría causar que la etiqueta original del documento se pierda.

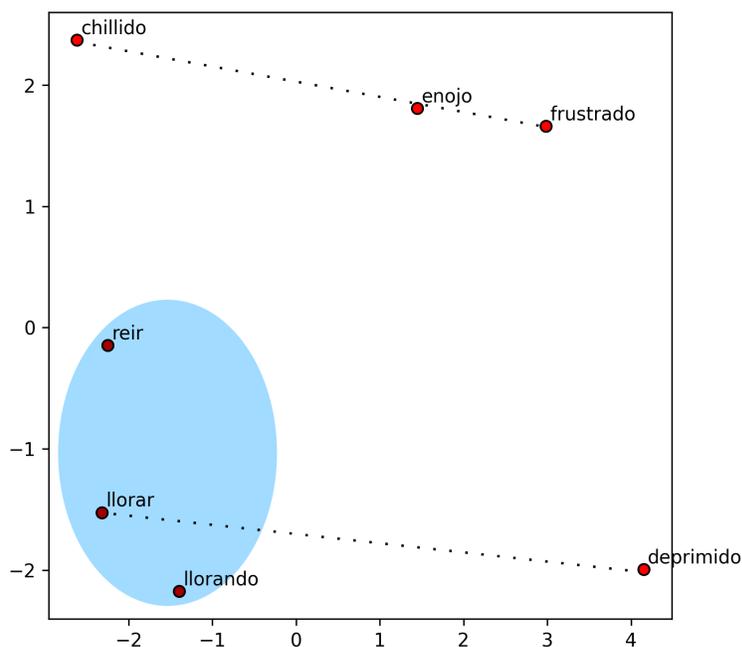


Figura 4.3: Palabras que ocurren en contextos de uso similares tienen una similitud relacional alta, incluyendo el caso de antónimos, por ejemplo *llorar* vs *reír*

Para resolver este problema, explotamos la similitud relacional entre pares de

palabras. Por ejemplo, al recuperar las palabras más similares a la palabra *llorar*, encontramos: reír y llorando. Si sumamos el vector de la palabra *llorar* con el vector de la palabra *frustrado* podemos encontrar entre las palabras más cercanas: *chillido* y *enojo*, tal como se muestra en la figura 4.3. De esta forma, mediante la aritmética de vectores podemos descubrir relaciones no tan obvias, y con ello crear una mayor diversidad en el vocabulario. Estas relaciones han sido previamente demostradas en (Mikolov, Yih, y Zweig, 2013), junto con relaciones como singular - plural, adjetivos posesivo - no posesivo, base - comparativo, base - superlativo. Por supuesto, se trata de una aproximación con la cual se ha alcanzado exactitudes de hasta un 41 %.

En un contexto de aumento de datos asumimos que existe una relación entre la etiqueta de la clase y las palabras de una secuencia en un documento de esa clase. Para observar esta relación empleamos pares de palabras, intentando identificar analogías. Por ejemplo, se busca encontrar un segundo par de palabras que presente una relación análoga entre las palabras *deprimido* (etiqueta de la clase) y *llorar* (palabra de una secuencia perteneciente a la clase). En este caso suponemos que existe una relación entre *deprimido* y *llorar*; el siguiente paso es buscar una relación similar entre un sinónimo de *deprimido*, puede ser *frustrado*, y una palabra v que desconocemos. Estas relaciones se muestran en la figura 4.3 mediante una línea punteada.

$$v \approx \textit{llorar} - \textit{deprimido} + \textit{frustrado} \quad (4.2.3)$$

De manera general para el aumento de datos proponemos expresar una analogía de la forma “ w_{label} es a w como w_{syn} es a v ”, resolviendo la ecuación 4.2.4 mediante aritmética de vectores.

$$\vec{v} \approx \vec{w} - w_{label} + w_{syn} \quad (4.2.4)$$

La ecuación 4.2.3 resulta de sustituir en la ecuación 4.2.4 las palabras involucradas para el aumento de datos. Siendo \vec{w} , w_{label} y w_{syn} las representaciones vectoriales de la palabra w a reemplazar, la etiqueta de la clase a aumentar w_{label} y un sinónimo de la etiqueta de la clase a aumentar w_{syn} . El vector \vec{v} es la representación vectorial de la palabra a encontrar. Se busca que la palabra v sea muy similar a w pero orientada en el contexto del sinónimo w_{syn} . Es decir, el objetivo principal es encontrar palabras candidatas v que compartan la misma relación reflejada entre *llorar* - *deprimido* pero no necesariamente similar a *llorar*.

La ecuación 4.2.4 es una forma directa para resolver preguntas de analogía. En (Mikolov, Yih, y Zweig, 2013), propusieron este método nombrándolo método de compensación de vectores, en este método se asume que las relaciones semánticas entre palabras están presentes como una compensación de vectores, así que, en el espacio de características, todos los pares de palabras compartiendo una relación en particular están relacionadas por la misma constante de compensación. La variable \vec{v} es la representación del espacio continuo de la palabra que esperamos sea la mejor respuesta. Claramente no existe ninguna palabra en la posición exacta, así que se busca la palabra cuyo vector tenga la mayor similitud coseno a \vec{v} . Resultando en:

$$\operatorname{argmax}_{\vec{v} \in V} (\cos(\vec{v}, \vec{w} - w_{label}^{\vec{}} + w_{syn}^{\vec{}})) \quad (4.2.5)$$

Antes de aplicar la operación en 4.2.5, todos los vectores son normalizados al vector unitario. Bajo esta normalización, dicha ecuación se puede expandir como en 4.2.6

$$\operatorname{argmax}_{\vec{v} \in V} (\cos(\vec{v}, \vec{w}) - \cos(\vec{v}, w_{label}^{\vec{}}) + \cos(\vec{v}, w_{syn}^{\vec{}})) \quad (4.2.6)$$

El objetivo anterior busca encontrar una palabra similar a w (la palabra que deseamos reemplazar), diferente de w_{label} (la etiqueta de la clase a aumentar) y similar a w_{syn} (un sinónimo de la etiqueta a aumentar). Al maximizar este objetivo (Mikolov et al., 2013) comprobó que se puede recuperar hasta un 53% de las analogías en el conjunto de datos MSR¹. Aun así, (Levy and Goldberg, 2014) encontró que la formulación en 4.2.6 permite que un término suficientemente grande domine la expresión y como consecuencia obtener resultados incorrectos, para alcanzar un mejor balance entre los diferentes aspectos de similitud, propusieron la ecuación 3COSMUL (4.2.7). Esta fórmula amplifica las diferencias entre pequeñas cantidades y las reduce entre las grandes. Mediante esta fórmula se logro recuperar el 59% de las analogías en el conjunto MSR.

$$\operatorname{argmax}_{\vec{v} \in V} \frac{\cos(\vec{v}, \vec{w}) \cos(\vec{v}, w_{syn}^{\vec{}})}{\cos(\vec{v}, w_{label}^{\vec{}}) + \epsilon} \quad (4.2.7)$$

Bajo este nuevo escenario, primero se obtiene la similitud de la palabra w a ser reemplazada y una palabra v en el vocabulario, el resultado es multiplicado por la

¹research.microsoft.com/en-us/projects/rnn/

similitud de la palabra v y un sinónimo de la etiqueta de la clase a aumentar w_{syn} . Con esto se espera amplificar la similitud entre v y la palabra a reemplazar w por la magnitud de la similitud entre v y w_{syn} . El denominador busca incrementar el resultado anterior si existe disimilitud entre v y la etiqueta w_{label} de la palabra a aumentar. Finalmente, sustituyendo las representaciones vectoriales de v para cada palabra en el vocabulario V , w , w_{label} y w_{syn} en la formula 4.2.7 obtenemos las palabras candidatas W con mayor puntuación. Antes de obtener el resultado de 4.2.7, las similitudes coseno son transformadas en el rango $[0,1]$ utilizando $\frac{x+1}{2}$ y ϵ es un número muy pequeño usado para evitar la división por cero.

En la tabla 4.3, se presenta un ejemplo de este método de aumento, el cual hemos nombrado de **reemplazo por relaciones equivalentes**. En la primera columna se indica la etiqueta de la clase a aumentar *depressed* y sus sinónimos: *anxious*, *frustrated*, *unhappy*, *despondent* y *discouraged*; por cada sinónimo se obtiene una secuencia aumentada.

Tabla 4.3: Ejemplos del aumento de datos para el método basado en reemplazo por relaciones equivalentes.

	Secuencia
Original	oh man this sucks it maybe looks funny from outside but it just looks like hell from here
depressed-anxious	oh man this sucks it maybe look funny from outside but it just <i>looked</i> like <i>wait</i> from here
depressed-frustrated	oh man this suck it <i>perhaps</i> looks <i>stupid</i> from outside but it just looks like hell from here
depressed-unhappy	oh <i>woman</i> this sucks it maybe <i>looking</i> funny from outside but it just looks like hell from here
depressed-despondent	oh man this <i>pisses</i> it though looks <i>humourous</i> from outside but it just <i>dashing</i> like <i>purgatory</i> from here
depressed-discouraged	oh <i>god</i> this <i>sucked</i> it <i>anyway</i> <i>seems</i> <i>humorous</i> from outside but it just think <i>like</i> <i>bother</i> from here

Reemplazo por relaciones contrarias

En escenarios desbalanceados el aumento de datos puede llevarnos a un sobremuestreo de la clase minoritaria, generalmente la clase de interés. Los métodos presentados anteriormente fueron diseñados para aumentar esta clase minoritaria (a la cual también nos referimos como clase positiva). Sin embargo, una desventaja de hacer esto es que el modelo de aprendizaje se restringe al vocabulario de la clase positiva lo que provoca un sobreajuste. En un intento de contrarrestar esta situación, se propone un

método que incorpora documentos seleccionados de la clase negativa a la clase positiva. Por supuesto, para ello es necesario realizar una transformación de las instancias negativas.

Para llevar a cabo esta transformación adaptamos el método propuesto por (Zhang, Lertvittayakumjorn, y Guo, 2019). En dicho método se aborda el problema de *zero-shot text classification*, en esa situación se toma un documento de una clase etiquetada y lo *traduce* para considerarlo como instancia de una clase totalmente nueva. Este método no tiene ninguna restricción respecto sobre las palabras a reemplazar, en nuestro caso hemos incluido un criterio de selección para guiar la generación de los nuevos documentos los cuales servirán para aumentar el conjunto de la clase de interés.

La idea básica de la transformación recae en el mismo método visto en la sección anterior. Sin embargo, los pares de palabras usadas para representar la analogía son escogidas para identificar palabras con una relación opuesta o *contraria*. Por ejemplo, en el caso de la tarea de detección de depresión, asociaremos la palabra “*feliz*” como representativa de la clase *no deprimidos* y la palabra “*deprimido*” para la clase *deprimidos*. Ahora bien, reemplazaremos palabras de documentos de la clase *no deprimidos* por palabras que presentan la relación opuesta deseada, la cual es guiada por el par de palabras *feliz* vs *deprimido*.

En la ecuación 4.2.8 se asume que existe una relación entre la palabra a reemplazar (novia) y la etiqueta de la clase no depresiva (feliz), buscamos una palabra v que comparte una relación similar entre (novia) y la etiqueta que deseamos aumentar (feliz).

$$v \approx \text{novia} - \text{feliz} + \text{deprimido}. \quad (4.2.8)$$

Sustituyendo las palabras de 4.2.8: novia, feliz y deprimido por su representación vectorial en 4.2.7 como \vec{w} , w_{label} y w_{syn} respectivamente.

La tabla 4.4 presenta ejemplos del aumento basado en relaciones contrarias, las palabras relacionadas con un contexto feliz, son llevadas a un contexto contrario. Por ejemplo, el verbo “*talked*” es reemplazado por “*complained*” y “*bothered*”. Similar al método anterior se utilizan los sinónimos de la palabra *depressed* para el aumento.

Tabla 4.4: Ejemplos del aumento de datos para el método basado en relaciones contrarias, las palabras en cursiva, son las que resultaron afectadas después de la transformación.

	Secuencia
Original	i connected with a girl we sat up and talked all night
happiness - anxious	i <i>disconnected</i> with a girl we sat up and talked all night
happiness - frustrated	i connected with a girl we sat up and <i>complained</i> all night
happiness - unhappy	i connected with a <i>boy</i> we <i>complained</i> up and talked all night
happiness - despondent	i <i>dispirited</i> with a girl we sat up and talked all night
happiness - discouraged	i connected with a <i>shy</i> we <i>dismayed</i> up and <i>bothered</i> all night

Configuración experimental y resultados

En este capítulo se presenta la configuración experimental y el detalle de los conjuntos de datos empleados, además de los parámetros elegidos para la construcción de los diferentes clasificadores para la evaluación del método propuesto, al final se presenta un análisis de los resultados y se comparan las diferentes estrategias de aumento de datos. Adicionalmente, para poder reproducir los resultados, este proyecto está públicamente disponible en github¹.

5.1. Configuración experimental

La configuración experimental sigue un enfoque supervisado. En la cual se cuenta con un conjunto de historiales de usuario, los cuales pueden verse como un sólo documento, a este documento X le corresponde su etiqueta correspondiente $y \in Y$ en una relación uno a uno. En todos los conjuntos de datos usados se trata únicamente de dos clases, es decir, se trata de una clasificación binaria ($|Y| = 2$).

La metodología empleada está compuesta de 4 fases: preprocesamiento, aumento de datos, entrenamiento y evaluación. En el preprocesamiento, se realizan las modificaciones necesarias para normalizar los documentos, además de segmentarlos y filtrarlos en secuencias de 64 palabras, este valor fue encontrado empíricamente para optimizar el aprendizaje en las redes neuronales; posteriormente, continúa la etapa de aumento de datos. Una vez que se han aumentado los datos de entrenamiento para la clase de interés, se construye un modelo de clasificación, mediante un algoritmo

¹github.com/v1ktop/data_augmentation_for_author_profiling

de aprendizaje automático (en específico, es de nuestro interés los métodos de redes profundas). Finalmente, se evalúa el modelo de clasificación sobre un conjunto de datos que no ha sido aumentado ni utilizado en la búsqueda de parámetros durante el entrenamiento, únicamente es preprocesado de la misma forma que los datos de entrenamiento. La figura 5.1 muestra las diferentes fases descritas.

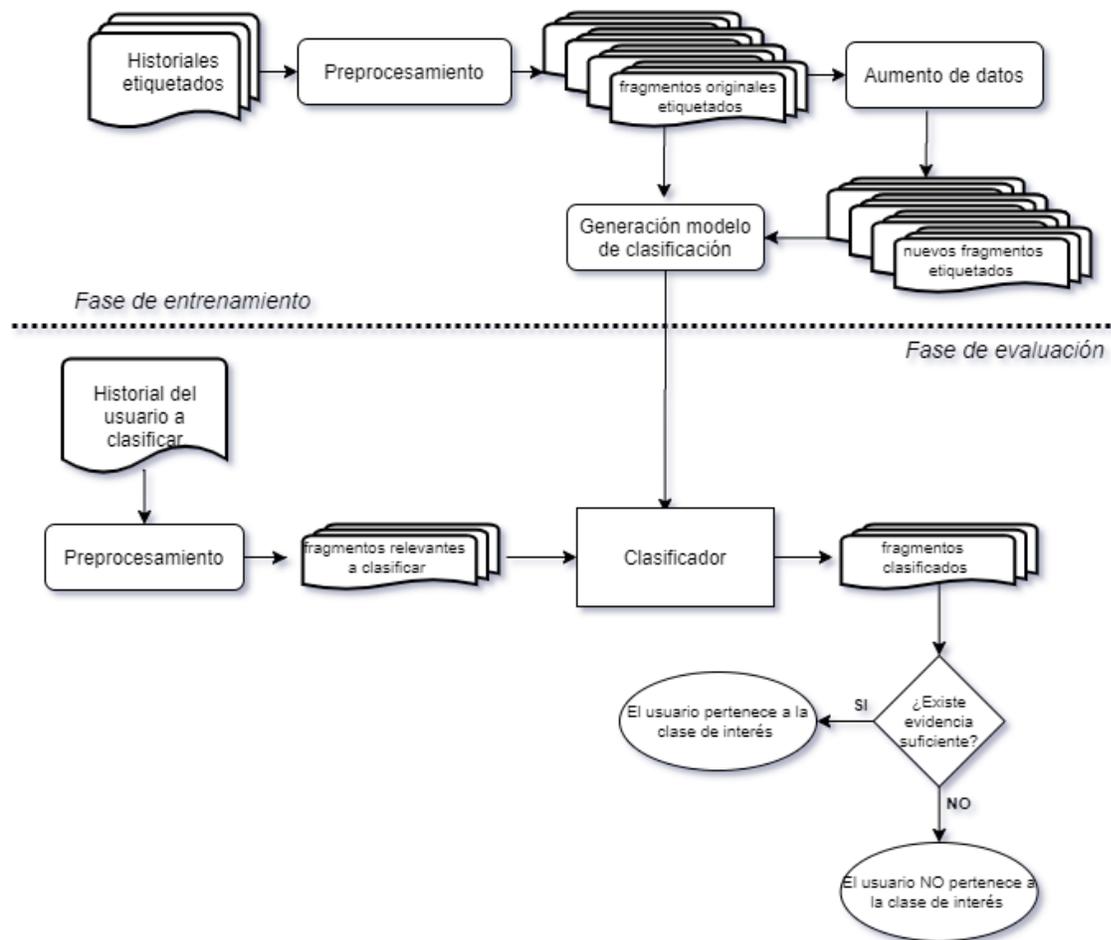


Figura 5.1: Diagrama general de la configuración experimental

5.1.1. Conjunto de datos

Depresión 2018 y Anorexia: Con el propósito de estudiar la detección temprana de depresión y anorexia, los autores (Losada, Crestani, y Parapar, 2018) recopilaron publicaciones de usuarios diversos, de la red social Reddit. Para cada usuario la

colección contiene una secuencia de publicaciones en orden cronológico. Este conjunto de datos, se caracteriza por tener una gran cantidad de texto, pero con muy pocos usuarios, como se puede observar en la figura 5.2. Hay dos categorías para cada usuario en cada tarea. El número de usuarios total en cada conjunto se presenta en la tabla 5.1. Dado que se trabaja con conjuntos de datos muy desbalanceados, el aumento de datos solo se aplica sobre la clase de interés o clase positiva.

Depresión 2019: Presentado en las tareas eRisk 2019 Losada, Crestani, y Parapar (2019a), a diferencia de la edición 2018, en esta ocasión el objetivo es predecir los niveles de depresión de un usuario (mínima, media, moderada, severa). Con el objetivo de que los resultados sean comparables, en este trabajo el problema fue reducido a una clasificación binaria, al igual que el conjunto de 2018; para esto los usuarios con depresión media a severa se tomaron como ejemplos de la clase positiva.

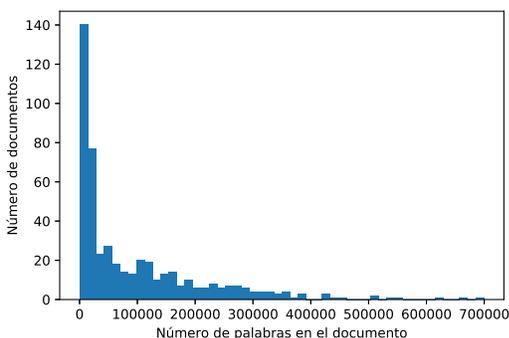
Para el entrenamiento solo se consideraron 16 usuarios para la clase positiva como se muestra en la tabla 5.1, para obtener usuarios de la clase negativa, se tomaron los usuarios etiquetados como no deprimidos del conjunto de entrenamiento eRisk 2018. Finalmente, el conjunto de evaluación, solo se dividió en dos clases quedando 60 positivos y 10 negativos (deprimidos y no deprimidos respectivamente).

Tabla 5.1: Número de usuarios en los conjuntos de datos y número de secuencias con 64 palabras. Los números resaltados en negritas representan el número de historiales.

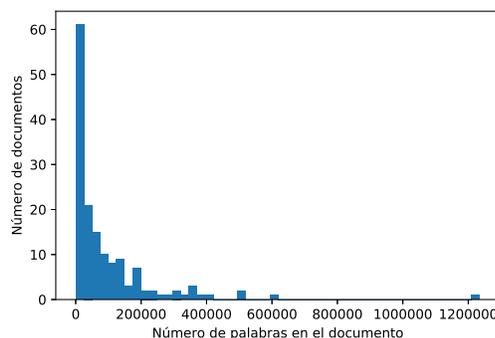
Usuarios	Entrenamiento	Evaluación	Vocabulario
<i>Conjunto 1: Depresión 2018</i>			
deprimido	135 - 31,396	79 - 25,967	
no-deprimido	752 - 227,189	741 - 272,703	
Total	887 - 258,585	820 - 298,670	202,151
<i>Conjunto 2: Depresión 2019</i>			
deprimido	16 - 5,731	60 - 18,534	
no-deprimido	752 - 227,189	10 - 5,011	
Total	768 - 232,920	70 - 23,545	195,047
<i>Conjunto 3: Anorexia</i>			
con anorexia	61 - 23,335	73 - 16,751	
sin-anorexia	411 - 107,239	742 - 254,640	
Total	472 - 130,574	815 - 271,391	131,264

Tabla 5.2: Número de usuarios en los conjuntos de datos y número de secuencias con 64 palabras después del preprocesamiento y filtrado. Los números resaltados en negritas representan el número de historiales.

Usuarios	Entrenamiento	Evaluación	Vocabulario
<i>Conjunto 1: Depresión 2018</i>			
deprimido	135 - 24,483	79 - 25,967	
no-deprimido	744 - 98,783	741 - 272,703	
Total	879 - 123,266	820 - 298,670	104,800
<i>Conjunto 2: Depresión 2019</i>			
deprimido	16 - 5,731	60 - 18,534	
no-deprimido	746 - 125,823	10 - 5,011	
Total	762 - 131,554	70 - 23,545	118,668
<i>Conjunto 2: Anorexia</i>			
con anorexia	61 -15,657	73 -16,751	
sin-anorexia	405 -58,837	742 -254,640	
Total	466 -74,494	815 -271,391	80,964



(a) Depresión 2018



(b) Anorexia

Figura 5.2: Distribución del número de palabras en los historiales de usuarios estudiados

5.1.2. Preprocesamiento

Dado que los documentos extraídos de redes sociales no siguen un lenguaje formal y además de texto, existen direcciones de páginas web que los usuarios comparten, emoticonos y caracteres especiales, entre otros; es necesario que antes del aumento de datos exista un preprocesamiento de los textos como una forma de reducir el ruido de los documentos originales.

Los pasos del procesamiento seguido, son los siguientes:

- 1.- Normalización: Se identifican las páginas web en el texto y se reemplazan mediante la etiqueta *http*.
- 2.- Tokenización: Utilizando la herramienta NLTK se remueve de cada texto signos de puntuación y caracteres especiales.
- 3.- Segmentación: Los documentos originales son segmentados en pequeños fragmentos. Es decir, cada historial de usuario se fragmenta en secuencias de 64 palabras (véase la siguiente sección).
- 4.- Filtrado: Solo se conservan segmentos identificados como importantes para la clasificación (véase la siguiente sección).

Segmentación y filtrado

Con el propósito de que el aumento de datos pueda ser proporcional independientemente de la longitud del documento original, cada documento se dividió en segmentos de 64 palabras². Posteriormente, se filtró el conjunto de entrenamiento para conservar solo los segmentos importantes para realizar la clasificación. Es decir, se identificaron aquellos fragmentos con la mayor cantidad de palabras discriminantes. Para esto se identificaron las palabras más discriminantes dentro del vocabulario del conjunto de entrenamiento, mediante la técnica de selección de características χ^2 . Posteriormente, se conservaron aquellos fragmentos que contengan un número determinado de palabras con alta puntuación χ^2 .

Específicamente, solo se seleccionaron términos estadísticamente significativos al nivel 0.001, equivalente a una puntuación $\chi^2 > 10.83$ con un grado de libertad. En la tabla 5.2 se muestran los números de usuarios y secuencias obtenidas después de aplicar este filtro; para el conjunto de depresión el criterio de selección fue que la secuencia contuviera al menos 20 palabras de 1071 palabras con alta puntuación, y para el conjunto de anorexia 18 palabras de 1032. Como puede observarse en ambos casos se trata de umbrales altos. Esto se debe principalmente a que en las palabras con alta puntuación se consideran palabras vacías, palabras que tradicionalmente se eliminan para tareas de clasificación temática. No obstante, en nuestro caso, se trata de una tarea donde el estilo es importante (p.e. uso de pronombres personales).

²Este parámetro se determinó de manera empírica.

5.1.3. Configuración de los métodos propuestos

Para comprobar la efectividad del método propuesto se experimenta con 7 configuraciones diferentes: 2 líneas base, 2 métodos del estado del arte y 3 métodos propuestos. Además de esto se introduce un parámetro n para observar el grado pertinente del aumento de datos, el cual indica el número de documentos nuevos aumentados por cada documento original, tomando valores enteros en el rango $[1, 10]$. Por lo tanto, para todos los métodos propuestos y de comparación (o referencia) solo se aumenta la clase positiva n veces, desde $n = 1$ hasta $n = 10$.

Sin aumento de datos

Este método es la primera línea base y solo considera los datos originales filtrados para el entrenamiento de los modelos (véase la tabla 5.2).

Sobremuestreo

Esta línea base, consiste en incrementar el número de ejemplos de la clase minoritaria mediante su replicación; este método no implica ninguna pérdida de información, ya que ningún elemento es modificado ni descartado. Sin embargo, la única desventaja es que el modelo de aprendizaje generado tiende a sobre ajustarse, debido a que no agrega variabilidad en los datos.

Tesaurus

Este método del estado del arte fue propuesto por (Zhang, Zhao, y LeCun, 2015) y demostró mejoras de un 1 a un 2% en exactitud para la clasificación de opiniones. También fue implementado por (Wei and Zou, 2019) con algunas modificaciones obteniendo una mejora entre un 1 y un 2% en comparación de no hacer aumento de datos, otros trabajos que utilizan este método como referencia y han encontrado evidencia de que agrega una ganancia en los resultados de clasificación son: (Jungiewicz and Smywiński-Pohl, 2019), (Kumar et al., 2019), (Park and Ahn, 2019).

Para decidir cuantas palabras reemplazar dada una secuencia de palabras, se calcula un número aleatorio r , generado de una distribución geométrica con un parámetro $p = 0.5$; el recurso externo para encontrar sinónimos es un tesaurus (en este caso Word-

net³), y finalmente en la fase de reemplazo, de las palabras candidatas, se selecciona un número aleatorio s generado de una distribución geométrica con parámetro $q = 0.5$.

El propósito de este método es, ser muy conservativo en la modificación del texto original y el número s controla la diversidad del vocabulario que por lo general para decidir qué palabras reemplazar empleada la palabra más utilizada.

Sustitución sin restricción y reemplazo mediante similitud coseno

Diversos estudios sugieren utilizar vectores de modelos preentrenados como Word2Vec, Glove, entre otros; la idea es recuperar palabras que se utilizan en contextos similares, en lugar de sinónimos.

Para decidir qué palabras reemplazar se omiten palabras de paro y aquellas que no sean etiquetadas como sustantivos, adjetivos, verbos y adverbios; con el propósito de agregar más variabilidad en los ejemplos el número r es calculado con el parámetro $p = 0.2$. En la fase de reemplazo las palabras más similares se seleccionan mediante similitud coseno, utilizándolas de mayor a menor en una selección sin reemplazo.

El modelo de vectores preentrenados para representar las palabras de una secuencia fue Glove⁴, con 300 dimensiones (Pennington, Socher, y Manning, 2014). Este modelo fue preentrenado con la base de datos Common Crawl, con 42 millones de tokens y 1.9 millones de palabras.

Sustitución con restricción χ^2 y reemplazo mediante similitud relacional

A diferencia del método anterior, una vez calculado el número r de palabras a reemplazar, se omiten las palabras con mayor puntuación χ^2 con un nivel de significación estadística de 0.001.

Reemplazo mediante similitud relacional equivalente

En la fase de selección se fija el valor del parámetro $p = 0.2$ y en la fase de reemplazo se utiliza la similitud relacional equivalente; esto es, obtener un vocabulario muy similar a la etiqueta de la clase, pero no el mismo. Las relaciones buscadas se listan en la tabla 5.3, para cada tarea de clasificación. Por ejemplo, para buscar las

³www.wordnet.princeton.edu/

⁴<https://nlp.stanford.edu/projects/glove/>

palabras candidatas a la palabra “boyfriend”, se utiliza la relación “*depressed*” es a “*boyfriend*” como “*anxious*” es a ?.

Reemplazo mediante similitud relacional contraria

Este último método es similar al método anterior, lo único que cambia es la clase objetivo, en este caso se toman los documentos de clase opuesta (la clase negativa). Por ejemplo, para buscar las palabras candidatas a la palabra “boyfriend”, se utiliza la relación “*happiness*” es a “*boyfriend*” como “*anxious*” es a ?. La tabla 5.3 resume las etiquetas empleadas para hacer el aumento.

Tabla 5.3: Etiquetas utilizadas en el proceso de aumento para los métodos de similitud relacional.

Conjunto	Clase	Etiqueta	Palabra relacionada	
Depresión	1	depressed	anxious	
	0	happiness	frustrated	
				unhappy
				despondent
			discouraged	
Anorexia	1	anorexic	bulimic	
	0	healthy	underweight	
				obese
				malnourished
				unhealthy

Ejemplos del aumento de datos

En la tabla 5.4 se presentan diversos ejemplos de aumento, el método basado en tesaurus agrega un vocabulario más formal, en comparación con los basados en similitudes relacionales. El método basado en restricción χ^2 conserva palabras importantes como “feel”, mientras que los demás no toman en consideración esto. Por otra parte, el método basado en relaciones equivalentes agrega la palabra “*unfortunate*” como una palabra relacionada a la palabra “*unhappy*”.

Tabla 5.4: Ejemplos del aumento de datos, las palabras resaltadas en negritas son las que resultaron afectadas después de la transformación.

Método	Secuencia
Sin Aumento	a lot of the time i have trouble communicating why i feel so unhappy
Thesauro	a lot of the time i hold trouble communicating why i feel thusly infelicitous
Sin Restricción	a lots of the time i have trouble communicating why i feeling so unhappy
Restricción χ^2	a lot of the time i have difficulty informing why i feel so unhappy
Equivalencia	a much of the place i have troubles informing why i feeling so unfortunate

5.1.4. Configuración de los modelos de aprendizaje

Para evaluar el efecto del aumento de datos se utilizaron dos arquitecturas de aprendizaje profundo. Ambas son arquitecturas con resultados relevantes en tareas de clasificación de textos: una red LSTM bidireccional y una red convolucional CNN. Cada arquitectura tiene diferencias, por ejemplo, al considerar el aspecto secuencial inherente de un texto, en el caso de la red recurrente; o cuando se consideran subsecuencias como elementos aislados en el caso de la red convolucional.

A pesar de que, el enfoque principal de este trabajo está enfocado al efecto del aumento de datos en redes neuronales profundas, también se realizaron experimentos en modelos tradicionalmente usados en la clasificación de textos. El objetivo es tener valores de referencia respecto a los métodos propuestos.

Como métodos de clasificación tradicional, se usaron las Máquinas de Soporte Vectorial, considerando el desbalanceo o no al modificar el parámetro de regularización c . Nos referiremos al modelo que no considera el desbalanceo como SVM y cuando se considera lo indicamos como SVM-C.

Modelos lineales

El primer modelo es construido mediante una Máquina de Soporte Vectorial (SVM) con kernel lineal, la entrada es el historial completo de un usuario representado como un vector de características mediante el pesado $tf-idf$ y normalizado mediante la norma l_2 , las palabras de paro se mantienen, y se utiliza todo el vocabulario extraído como características.

El segundo algoritmo utilizado SVM-C, está basado en el primer modelo, con la diferencia de que en este caso se modifica el parámetro de regularización C y

automáticamente se ajustan los pesos inversamente proporcionales a la frecuencia de las clases en los datos de entrada de acuerdo con la ecuación 5.1.1

$$C = N/2c_n \quad (5.1.1)$$

Donde N es el número total de ejemplos y c_n el número de ejemplos en la clase c .

Modelos basados en redes neuronales

Con el objetivo principal de establecer las bases, sobre en qué tipo de arquitecturas es más recomendable hacer aumento de datos. Se implementan dos arquitecturas diferentes: una red Bidireccional LSTM (Bi-LSTM) y una red convolucional (CNN); teniendo en común la capa de entrada y capa de salida.

La **capa de entrada** recibe una secuencia de 64 palabras, cada palabra es representada por un vector de 300 dimensiones, obtenido del modelo preentrenado FastText⁵, si alguna palabra no está en el vocabulario, su vector es obtenido de la representación de sus n-gramas de caracteres. En el entrenamiento, esta capa es estática para reducir el número de parámetros a entrenar.

La **capa de salida** es una neurona que recibe como entrada la última capa oculta del modelo, la cual es la representación aprendida de los parámetros internos. Mediante la función sigmoide, ecuación 5.1.2, se calcula la probabilidad de que la secuencia de palabras pertenezca a la clase 0 o a la clase 1.

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (5.1.2)$$

Para inicializar los pesos de la capa final correctamente, el *bias* (sesgo) inicial se deriva de la ecuación 5.1.3. Con la inicialización correcta la función de pérdida inicial se debe aproximar a $\ln(2) = 0.69314$.

$$\begin{aligned} p_0 &= \frac{pos}{pos + neg} = \frac{1}{1 + e^{-b_0}} \\ b_0 &= -\log_e\left(\frac{1}{p_0 - 1}\right) \\ b_0 &= \log_e(pos/neg) \end{aligned} \quad (5.1.3)$$

⁵<https://fasttext.cc/docs/en/crawl-vectors.html>

Configurando el sesgo inicial correctamente ayuda a la convergencia del modelo desde la primera época.

Derivado de la arquitectura presentada en (Adhikari et al., 2019), en la figura 5.3, se presenta la arquitectura empleada para el modelo Bi-LSTM, la red bidireccional se compone de dos redes LSTM con 256 neuronas cada una, posteriormente se aplica una capa de *Dropout* con una tasa de 0.2, una capa totalmente conectada con 256 unidades, una capa de *Dropout* con una tasa de 0.2 y en la última capa una sola neurona activada mediante la función sigmoide 5.1.2. Los nodos intermedios de las capas ocultas se activan con la función de activación Relu 2.4.4.

En la figura 5.4, se presenta la arquitectura empleada para la red convolucional (CNN), esta arquitectura esta basada en el trabajo de (Kim, 2014). Se implementan tres tamaños de filtro [3,4,5], cada uno con 300 filtros. Los filtros hacen convoluciones en una matriz que representa a la secuencia de palabras y generan mapas de características de longitud variable; la operación de *Max Pooling* se realiza sobre cada mapa, es decir, se calcula el número mayor de cada mapa de características. A partir de esto se obtienen diferentes vectores de características de diferentes tamaños y la penúltima capa se forma concatenándolos, para formar un vector final de características, la capa final recibe este vector de características, para clasificar la secuencia de palabras. Los nodos intermedios de las capas ocultas se activan con la función de activación Relu 2.4.4.

Entrenamiento

Para encontrar los hiperparámetros de los modelos se realizó una división del conjunto de entrenamiento en 3 particiones diferentes (3 K-Folds) con una proporción de 66% para entrenar y 33% para evaluar.

Observando el desbalance existente en los conjuntos de entrenamiento, por ejemplo, para el conjunto *Depresión 2019*. Se necesita aumentar más de 20 veces la clase positiva para llegar a balancear los datos, por lo tanto, para realizar experimentos consistentes, en caso de los modelos de redes neuronales, se entrenan de forma que sean sensibles al desbalance (Wang et al., 2016), utilizando un peso adicional para cada clase, calculado mediante la fórmula 5.1.1. Con esto el error es incrementado para ejemplos en la clase de interés y decrementado para la clase menos importante. Esto se realiza para compensar el desbalance que no se alcanza a cubrir con el aumento de datos para cada configuración de n .

Los parámetros elegidos para el entrenamiento se resumen en la tabla 5.5.

Evaluación

Como resultado del entrenamiento se tiene un clasificador. Este clasificador es evaluado a través de un conjunto de datos previamente seleccionado, el cual no ha sido utilizado en la fase de entrenamiento. Cabe recordar que este clasificador, se ha entrenado para determinar la clase de un fragmento del historial de un usuario. De esta forma, la predicción final se realiza observando la clase de todos los fragmentos del

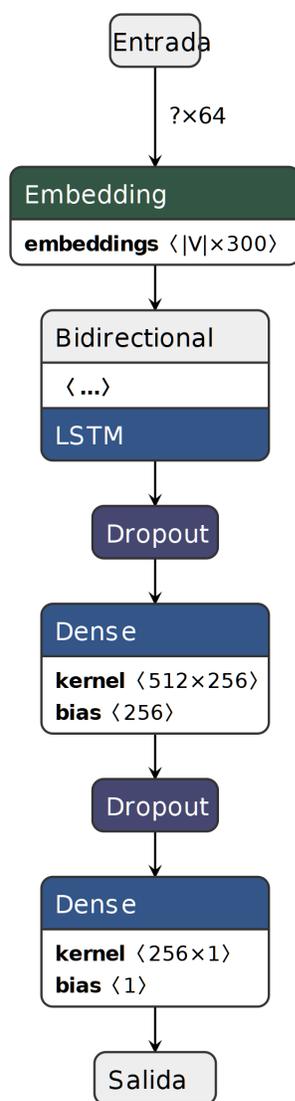


Figura 5.3: Arquitectura del modelo Bi-LSTM

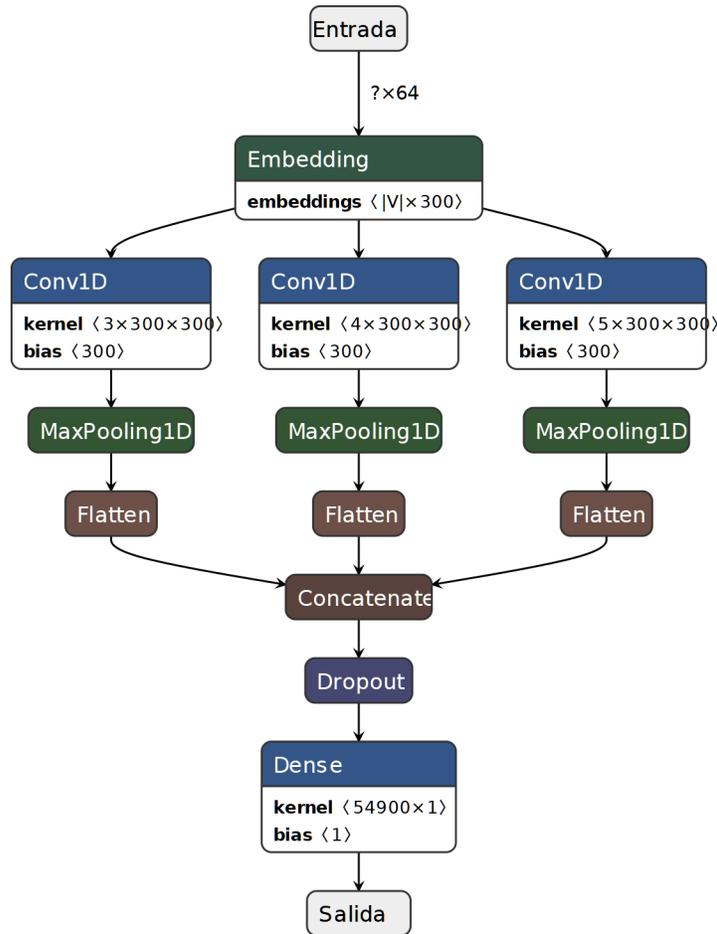


Figura 5.4: Arquitectura del modelo CNN con múltiples tamaños de convolución

usuario en evaluación. Si el número de fragmentos pertenecientes a la clase de interés supera cierto umbral, se considera que se tiene suficiente evidencia para determinar que el usuario pertenece a la clase de interés (véase la figura 5.1). En este caso se calculó un promedio de las predicciones pertenecientes a un historial. El umbral de decisión se fijó en 0.5 para los modelos basados en SVM, SVM-C, Bi-LSTM y en 0.4 para la red convolucional CNN.

Implementación

Para el preprocesamiento y el etiquetado de las secuencias de texto se utilizó la librería NLTK (Loper and Bird, 2002), para la normalización y el cálculo de medi-

Tabla 5.5: Parámetros utilizados para el entrenamiento de los modelos basados en redes neuronales.

Parámetro	Valor
Tasa de aprendizaje	1.00E-03
Tamaño del Batch	1024
Función de pérdida	Entropía cruzada binaria
Máximo número de épocas	20
Criterio de paro	CNN=6; Bi-LSTM=3
Pruebas independientes	3

das de similitud de los embeddings la librería gensim⁶. Los modelos lineales fueron implementados utilizando la librería scikit-learn 0.22.1⁷, los modelos neuronales mediante tensorflow 2.2⁸. Finalmente, el 50 % de los modelos fueron entrenados con una computadora personal y el 50 % en Colab⁹ (una herramienta de acceso gratuito para entrenar redes neuronales en la nube).

5.2. Resultados

En la tabla 5.6 se presentan los resultados de los experimentos mediante el promedio de la métrica $F1$, calculada en base a la clase de interés (la clase positiva). Debido a la aleatoriedad de las redes neuronales los resultados obtenidos en estos modelos se presentan como un promedio de 3 ejecuciones independientes y la desviación estándar obtenida; la columna nombrada como n indica el valor de aumento correspondiente en el conjunto de datos, así con $n = 1$ indica que se realizó el entrenamiento con la línea base mas un conjunto aumentado de la clase positiva. En la evaluación se utilizó un umbral igual a 0.5 para los modelos Bi-LSTM, SVM y SVM-C; 0.4 para el modelo CNN, estos umbrales fueron encontrados en validación. Además, se comparan los métodos propuestos; reemplazo mediante relaciones equivalentes, relaciones contrarias y restricción mediante la selección de características χ^2 , contra la línea base (sin aumento de datos) y los métodos de referencia: (i) sobre muestreo, (ii) utilizando

⁶www.radmehurek.com/gensim

⁷www.scikit-learn.org/stable/

⁸www.tensorflow.org

⁹colab.research.google.com

un tesauro, y (iii) selección sin restricción.

Los mejores valores encontrados para cada conjunto de datos están resaltados en negritas. Así, para el conjunto de *Depresión 2018* el mejor valor encontrado fue de $53\% \pm 1$ en $F1$ utilizando el método Restricción χ^2 , para el conjunto de *Depresión 2019* $88\% \pm 2$ mediante los métodos: Tesauro, Restricción χ^2 y Relación Positiva; finalmente para el conjunto de *Anorexia* $81\% \pm 1$ mediante el método Restricción χ^2 y sin restricción. En general, los resultados para el conjunto de Depresión 2019 y Anorexia, son mejores en comparación a los obtenidos en el conjunto Depresión 2018, esto se lo podemos atribuir a la forma en que se etiquetaron los datos ya que para el conjunto de Depresión 2018 el etiquetado se realizó de forma automática y presumimos se capturaron muchos falsos negativos.

En primer lugar, se compara la línea base (no realizar aumento de datos) contra los diferentes métodos de aumento de datos, en donde se puede observar que la mayoría de los métodos superan esta línea base, a excepción en el modelo basado en SVM-C para el conjunto de depresión 2019 en donde no se consigue mejorar el modelo base.

Al comparar los algoritmos de aumento de datos, el método Restricción χ^2 obtiene un mejor rendimiento, ya que obtiene los mejores resultados para los tres conjuntos de datos en diferentes configuraciones y solo duplicando la clase positiva en la mayoría de los casos. Por otra parte, en los algoritmos lineales se observa un gran incremento en el modelo SVM obteniendo mejores resultados, a excepción del conjunto Depresión 2019, en comparación con el algoritmo SVM-C que considera el desbalance de las clases.

5.3. Análisis y discusión de los resultados

Con el objetivo de observar la relación entre el valor F1 alcanzado y la magnitud de aumento n en el conjunto de datos, se presentan las figuras 5.5, 5.6 y 5.7. En las gráficas se comparan los métodos: sin aumento de datos, Tesauro, restricción χ^2 , relación equivalente y relación contraria. Las gráficas se presentan en una escala de 0 a 100%, representando la ganancia obtenida para la métrica $F1$, el eje x refleja el número de secuencias aumentadas por cada secuencia original en el conjunto de entrenamiento y el eje y la ganancia o pérdida porcentual en $F1$ en comparación con la línea base que es no realizar aumento de datos.

En la figura 5.5 (a), el aumento para la red Bi-LSTM en el conjunto *Depresión*

Tabla 5.6: Resultados en términos de la métrica F1, la variable n indica la magnitud del aumento en el conjunto original.

Conjunto de datos	Método	Bi-LSTM		CNN		SVM		SVM-C	
		F1	n	F1	n	F1	n	F1	n
Depresión 2018	Sin aumento	47±3	-	45±5	-	16	-	50	-
	Over	48±3	2	51±2	2	51	4	51	9
	Tesouro	45±3	4	52±2	2	50	10	48	1
	Sin restricción	47±4	1	52±1	2	53	10	50	3
	Restricción χ^2	49±3	9	53±1	1	53	10	50	1
	Relación equivalente	45±5	4	48±4	1	41	8	49	1
	Relación Contraria	35±6	1	49±1	10	52	8	51	1
Depresión 2019	Sin aumento	74±8	-	81±3	-	0	-	50	-
	Over	81±13	1	85±3	2	13	9	50	1
	Tesouro	80±5	7	88±2	7	10	10	49	1
	Sin restricción	74±10	1	85±2	2	10	7	47	1
	Restricción χ^2	88±4	1	87±3	1	10	8	47	1
	Relación equivalente	78±15	1	88±2	6	6	8	46	1
	Relación Contraria	65±7	9	82±3	9	31	4	15	5
Anorexia	Sin aumento	75±3	-	80±0	-	67	-	72	-
	Over	76±4	1	80±1	1	77	7	75	6
	Tesouro	74±5	3	80±1	4	76	2	75	3
	Sin restricción	76±4	4	81±1	1	78	6	78	6
	Restricción χ^2	76±3	1	81±1	1	78	5	77	1
	Relación equivalente	76±3	1	80±1	1	78	6	76	1
	Relación Contraria	74±1	1	80±1	1	81	8	75	5

2018, el mejor resultado con una ganancia de 4.31 %, se obtiene con $n = 9$ y el método *Restricción χ^2* . Se puede observar, que es el único método que logra superar la línea base, una vez alcanzado el balance, con $n = 3$ la ganancia comienza a decrecer hasta $n = 6$, por lo que en esta tarea es importante conservar las características discriminantes cuando se realiza el aumento de datos, sin embargo, si el conjunto se aumenta muchas veces el modelo se sobreajusta a los datos que se conservan.

En la figura 5.5 (b), aumento de datos para la red CNN en el conjunto *Depresión 2018*, el mejor valor encontrado con una ganancia de 18.81 % fue con $n = 1$ y el método *Restricción χ^2* . A diferencia de la red recurrente, las ganancias en F1 son más significativas y se encuentran en un rango entre 0 y 18 %, el método con menor ganancia fue el basado en relaciones contrarias llegando a empeorar la línea base hasta en un 50 % indicando que se está introduciendo ruido en exceso a los datos de entrenamiento originales. Aun así, logra obtener ganancias con $n = 1$.

Las gráficas que representan la comparación de los algoritmos propuestos, para el conjunto de datos Depresión 2019, se presentan en la figura 5.6. En la subfigura (a) la única ganancia significativa se da en el modelo Bi-LSTM con el método restricción χ^2 obteniendo una mejora de 18.72% en $F1$ con respecto a no realizar aumento de datos, sin embargo, después de triplicar conjunto de entrenamiento para la clase positiva ocurre lo contrario. Estas variaciones muy notables se deben a que el conjunto de prueba es menor y por lo tanto los falsos positivos afectan en gran medida en la evaluación. En la subfigura (b), se presenta la evaluación en el modelo CNN, en este caso el método propuesto Restricción χ^2 obtiene mejores resultados en comparación con el método del estado del arte Tesouro.

La figura 5.7 presenta el aumento de datos para el conjunto de anorexia. Al igual que en las gráficas anteriores se presenta el efecto del aumento de datos en los diferentes algoritmos de clasificación empleados. Similar a los conjuntos de depresión, el método de Restricción χ^2 obtiene mejores ganancias en los diferentes aumentos. Para la red convolucional la ganancia es menor, pero se observa que es el método más consistente, ya que los diferentes aumentos no afectan en sentido contrario a la clasificación como sucede con el método de tesouro y equivalencia contraria.

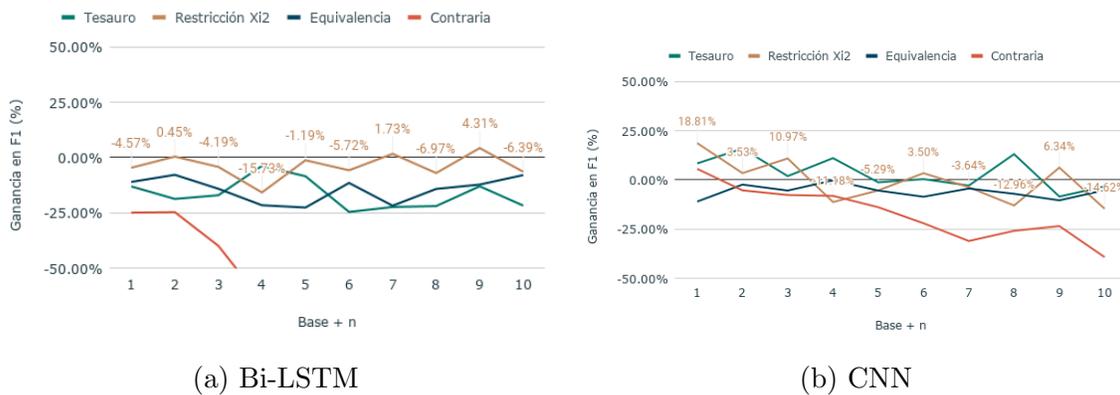
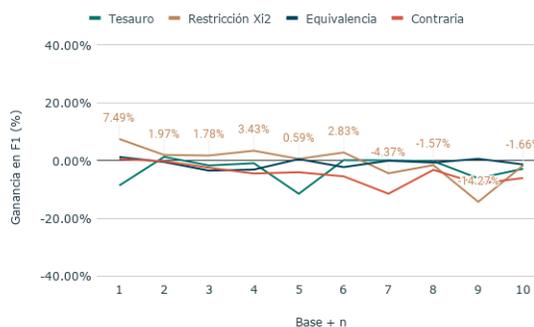


Figura 5.5: Relación entre el aumento del conjunto de datos *Depresión 2018* y la ganancia porcentual en $F1$.

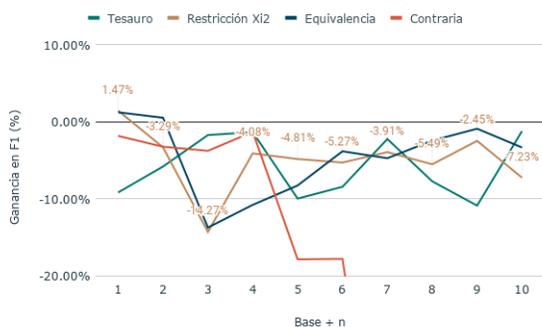


(a) Bi-LSTM

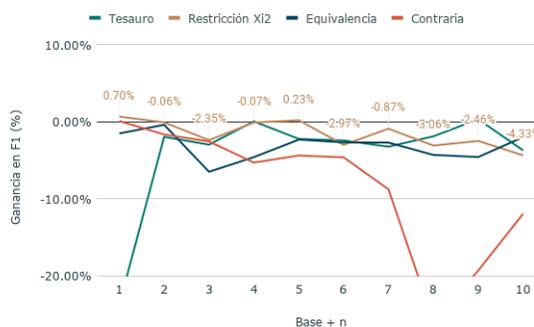


(b) CNN

Figura 5.6: Relación entre el aumento del conjunto de datos *Depresión 2019* y la ganancia porcentual en F1.



(a) Bi-LSTM



(b) CNN

Figura 5.7: Relación entre el aumento del conjunto de datos *Anorexia* y la ganancia porcentual en F1.

5.3.1. Comparación con el estado del arte en detección de depresión y anorexia

En la figura 5.8, se comparan los resultados obtenidos mediante aumento de datos utilizando una red CNN y el aumento de datos mediante el método Restricción χ^2 , con los modelos evaluados en la conferencia eRisk 2018 (Losada, Crestani, y Parapar, 2018). Aunque la mayoría de los sistemas participantes en eRisk 2018 utilizaron todo el historial de los usuarios para tomar sus decisiones, algunos las hicieron considerando solo parte de las publicaciones, esto debido al énfasis de este foro de evaluación en la detección temprana de los usuarios con depresión y anorexia.

Para detección de depresión, de un total de 45 modelos nuestra propuesta se puede ubicar en el sexto lugar ubicado en el primer cuartil, aunque solo ligeramente por arriba del segundo. Para la detección de anorexia, de un total de 35 propuestas nuestro modelo quedaría en el segundo lugar y claramente ubicado en el primer cuartil, muy por encima del segundo. Es importante señalar que para la detección de depresión el mejor modelo presentado en la tarea eRisk 2018 se obtuvo mediante la ingeniería de características y para la detección de anorexia se utilizó una red convolucional con vectores distribucionales entrenados en un corpus perteneciente al dominio, por lo que dichas propuestas podrían mejorar mediante el aumento de datos propuesto.

Como nota final, los resultados para el conjunto de Depresión 2019 no se comparan con los obtenidos en el evento eRisk 2019, porque el objetivo principal de esta tarea fue rellenar un cuestionario de forma automática y en base a este calcular el nivel de depresión que sufre el usuario; en este trabajo, se le dio un tratamiento como clasificación binaria, en la cual, en base al historial del usuario se predice si está deprimido o no.

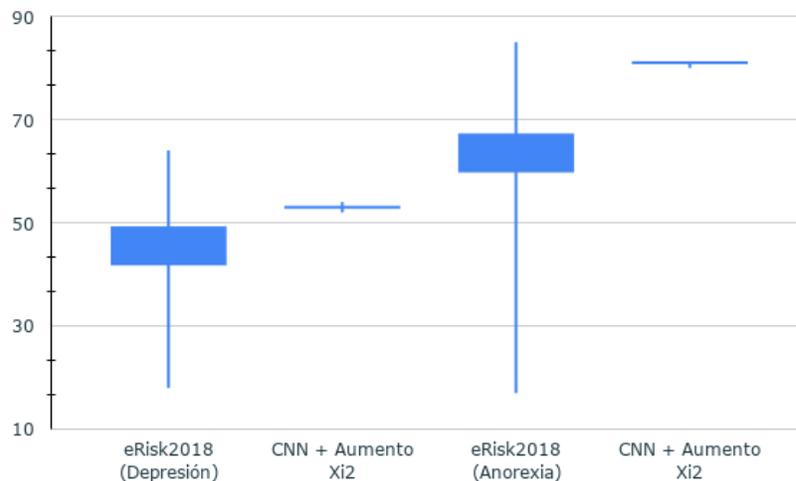


Figura 5.8: Comparación con el estado del arte en detección de depresión y anorexia

5.3.2. Análisis del aumento de datos

Con el objetivo de comprobar como afecta el aumento de datos a la originalidad y diversidad del documento original, se recopilieron estadísticas del aumento en el

vocabulario además de presentar las palabras más relevantes utilizadas por el método de Restricción χ^2 y para el filtro de secuencias en el pre-procesamiento.

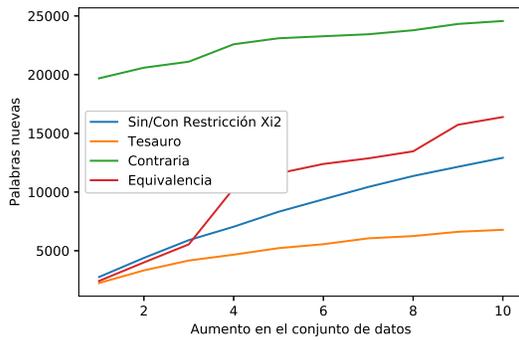
Aumento del vocabulario

En la figura 5.9 se representa para el eje y el número de palabras nuevas agregadas en relación con el parámetro n , que indica, la magnitud del aumento de datos. El objetivo de esta figura es comparar el vocabulario nuevo introducido, de acuerdo a cada método de aumento, en los diferentes conjuntos de datos.

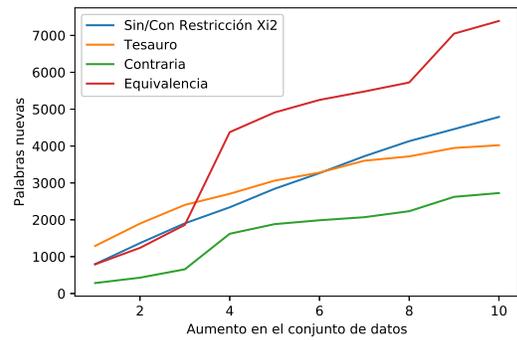
Como se puede esperar conforme aumenta el número de documentos el vocabulario también lo hace. En las subfiguras (a, c y e), se compara el aumento del vocabulario para la clase positiva, en la cual el método basado en relaciones contrarias incrementa drásticamente el vocabulario desde un documento por cada instancia y el que menos agrega palabras es el basado en tesauro, debido a que el método tesauro utiliza el parámetro p para selección igual a 0.5 y en promedio solo reemplaza 2 palabras por cada segmento a aumentar. Los métodos con y sin restricción agregan el mismo número de palabras debido a que solo difieren en que palabras reemplazar. Por otra parte, el método basado en relaciones de equivalencia agrega un mayor vocabulario a los dos anteriores, por lo tanto, se logra el objetivo de insertar un vocabulario diferente al emplear un criterio de similitud, basado en pares de palabras.

En la subfiguras 5.9 (b, d y f), se compara el aumento del vocabulario considerando ambas clases, debido a que el aumento de datos propuesto se basa sobre la clase de interés (la clase positiva). Resalta el hecho de que, aunque el método de equivalencias contrarias introduce un gran vocabulario en la clase positiva para el conjunto de depresión 2018 y anorexia, solo agrega de 500 a 2000 mil palabras nuevas considerando ambas clases, sin embargo, para el conjunto de depresión 2019 agrega hasta 7000 palabras nuevas. Este incremento drástico en el vocabulario impacta de forma negativa a los resultados.

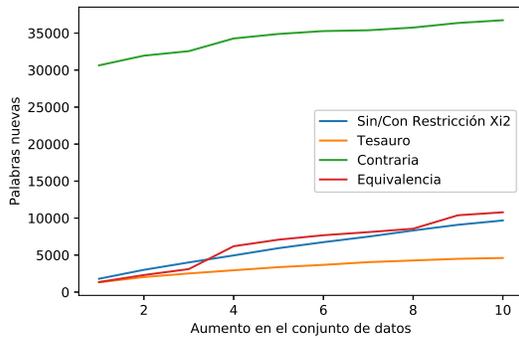
En resumen, el método que agregó más vocabulario fue el basado en relaciones contrarias, seguido del basado en equivalencias; el método Tesauro es muy conservador en el número de palabras nuevas agregadas, pero se puede observar que las palabras agregadas no aparecen en la clase contraria. Es interesante que el método con restricción agrega la misma modificación que el que no la realiza y puede obtener mejores resultados, por lo que se comprueba la efectividad del método.



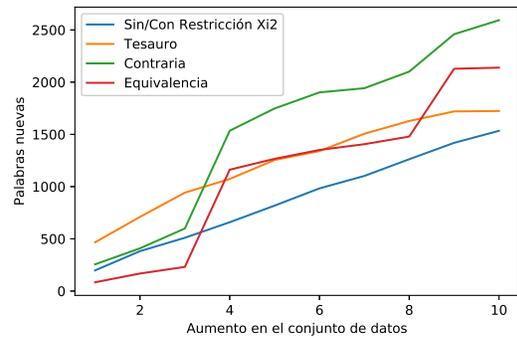
(a) Depresión 2018: Clase positiva



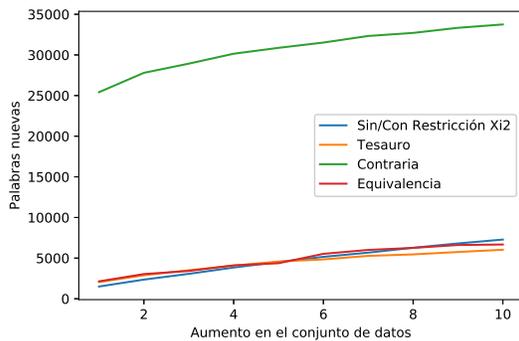
(b) Depresión 2018: Ambas clases



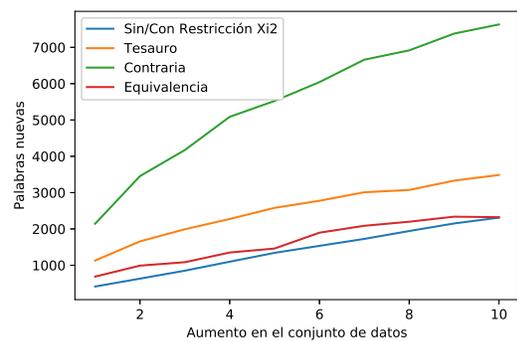
(c) Depresión 2019: Clase positiva



(d) Depresión 2019: Ambas clases



(e) Anorexia: Clase positiva



(f) Anorexia: Ambas clases

Figura 5.9: Relación entre el aumento de datos y el vocabulario nuevo agregado.

Palabras con mayor puntuación χ^2

En la figura 5.10, se representan las palabras con mayor puntuación χ^2 mismas que sirvieron para realizar el preprocesamiento y también para el método de aumento con restricción. La figura muestra las palabras más importantes en un tamaño de

Conclusiones y Trabajo Futuro

El aumento de datos estructural no es una tarea trivial ya que pertenece al área de generación de lenguaje natural. Se deben considerar muchos factores: la originalidad del texto, la diversidad, la conservación del estilo, la conservación de la etiqueta etc.

Con el objetivo general de “Proponer un método de aumento de datos considerando estilo y contenido del texto, para mejorar la predicción de los modelos de aprendizaje profundo en las tareas de perfilado de autor”, se presentaron diferentes estrategias de aumento de datos y se evaluaron en dos arquitecturas de aprendizaje profundo.

Gracias a los experimentos realizados y al análisis de los resultados, se llegaron a las siguientes conclusiones.

6.1. Conclusiones

Nuestra primera conclusión, es que el aumento de datos ayuda a los métodos basados en redes neuronales, al menos, en las dos arquitecturas evaluadas. Los métodos propuestos mejoran el resultado de clasificación y dependen fuertemente del conjunto de datos. El método propuesto *Restricción χ^2* obtiene mejores resultados, en comparación con los diferentes métodos estudiados. Este método conserva, sin alteración, las palabras con mayor puntuación χ^2 , sin embargo, corre el riesgo de sobreajuste conforme aumenta el número de documentos nuevos. Si se necesita un gran número de documentos, el método basado en relaciones equivalentes es el ideal, ya que ofrece un vocabulario más amplio mediante la elección de diferentes semillas (palabras relacionadas con la clase de interés).

Con respecto al efecto del aumento de datos en diferentes arquitecturas de red,

el aumento de datos, obtiene un efecto negativo para arquitecturas basadas en redes recurrentes, ya que consideran el texto como secuencia con valores dependientes en lugar de considerar características aisladas como es el caso de las redes convolucionales y los modelos lineales. Por consiguiente, la red convolucional fue más robusta en los diferentes aumentos de datos. En los modelos lineales, fue posible observar un incremento significativo en los resultados de clasificación, pero esto es debido a la importancia que se le está dando a la clase positiva y se logró comprobar con un modelo lineal que considera el desbalance; donde la línea base es muy cercana a los valores que se pueden obtener utilizando aumento de datos. Incluso considerando este hecho es preferible utilizar aumento de datos por los beneficios de regularización que ofrece.

Finalmente, se comprobó que se puede mejorar la predicción en el perfilado de depresión y anorexia, logrando una ganancia porcentual entre un 1 y 18% en términos de la métrica F1 en comparación con no ocupar aumento de datos y una ganancia entre un 1 y 7% en comparación con otros métodos de aumento. Además, fue posible igualar los resultados del estado del arte utilizando modelos neuronales menos complejos.

6.2. Trabajo futuro

Debido a las limitaciones de este proyecto, existen alternativas que no se estudiaron, por ejemplo:

- Explorar técnicas supervisadas basadas en parafraseo neuronal, estas técnicas pueden ofrecer una mayor calidad de generación de texto, la principal limitante es el costo computacional.
- Explorar técnicas semi-supervisadas o auto-supervisadas, el aprendizaje auto-supervisado es una rama del aprendizaje computacional que ha demostrado ser una opción para obtener grandes cantidades de datos con etiquetas débiles, sin embargo, exige contar con muchos recursos computacionales para poder ser implementado.
- Evaluar el aumento de datos en otras tareas de clasificación similares como: detección de engaño, tendencias suicidas, lenguaje agresivo, entre otras.

- Finalmente, se pueden implementar los modelos del estado del arte para la detección de depresión y anorexia, mejorándolos mediante el aumento de datos.

Bibliografía

- Abed-Esfahani, P.; Howard, D.; Maslej, M.; Patel, S.; Mann, V.; Goegan, S.; y French, L. 2019. Transfer learning for depression: Early detection and severity prediction from social media postings. *CEUR Workshop Proceedings* 2380(September 2019):9–12.
- Adhikari, A.; Ram, A.; Tang, R.; y Lin, J. 2019. Rethinking complex neural network architectures for document classification. In *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers)*, 4046–4051.
- Almeida, H.; Briand, A.; y Meurs, M.-J. 2017. Detecting early risk of depression from social media user-generated content. In *CLEF (Working Notes)*.
- Androutsopoulos, I., y Malakasiotis, P. 2010. A survey of paraphrasing and textual entailment methods. *Journal of Artificial Intelligence Research* 38:135–187.
- Aragón, M. E.; López-Monroy, A. P.; González-Gurrola, L. C.; y Montes, M. 2019. Detecting depression in social media using fine-grained emotions. In *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers)*, 1481–1486.
- Argamon, S.; Koppel, M.; Pennebaker, J. W.; y Schler, J. 2009. Automatically profiling the author of an anonymous text. *Communications of the ACM* 52(2):119.
- Basile, A.; Dwyer, G.; Medvedeva, M.; Rawee, J.; Haagsma, H.; y Nissim, M. 2017. Is there life beyond n-grams? a simple svm-based author profiling system. In *Working Notes of CLEF 2017-Conference and Labs of the Evaluation Forum*.

- Beck, A. T.; Ward, C. H.; Mendelson, M.; Mock, J.; y Erbaugh, J. 1961. An inventory for measuring depression. *Archives of general psychiatry* 4(6):561–571.
- Block, H. D.; Knight Jr, B.; y Rosenblatt, F. 1962. Analysis of a four-layer series-coupled perceptron. ii. *Reviews of Modern Physics* 34(1):135.
- Bogdanova, D.; Rosso, P.; y Solorio, T. 2012. On the impact of sentiment and emotion based features in detecting online sexual predators. In *Proceedings of the 3rd workshop in computational approaches to subjectivity and sentiment analysis*, 110–118. Association for Computational Linguistics.
- Boser, B. E.; Guyon, I. M.; y Vapnik, V. N. 1992. A training algorithm for optimal margin classifiers. In *Proceedings of the fifth annual workshop on Computational learning theory*, 144–152.
- Burdisso, S. G.; Errecalde, M.; y Montes-Y-Gómez, M. 2019. UNSL at Erisk 2019: A Unified Approach for Anorexia, Self-harm and Depression Detection in Social Media. *CEUR Workshop Proceedings* 2380:9–12.
- Cacheda, F.; Iglesias, D. F.; Nóvoa, F. J.; y Carneiro, V. 2018. Analysis and experiments on early detection of depression. *CLEF (Working Notes)* 2125.
- Chawla, N. V.; Bowyer, K. W.; Hall, L. O.; y Kegelmeyer, W. P. 2002. Smote: synthetic minority over-sampling technique. *Journal of artificial intelligence research* 16:321–357.
- Conneau, A.; Schwenk, H.; Barrault, L.; y Lecun, Y. 2016. Very deep convolutional networks for text classification. *arXiv preprint arXiv:1606.01781*.
- Cortes, C., y Vapnik, V. 1995. Support-vector networks. *Machine learning* 20(3):273–297.
- Cubuk, E. D.; Zoph, B.; Mane, D.; Vasudevan, V.; y Le, Q. V. 2019. Autoaugment: Learning augmentation strategies from data. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 113–123.
- Daneshvar, S., y Inkpen, D. 2018. Gender identification in twitter using n-grams and lsa. In *Proceedings of the Ninth International Conference of the CLEF Association (CLEF 2018)*.

- De Choudhury, M.; Gamon, M.; Counts, S.; y Horvitz, E. 2013. Predicting depression via social media. *Icwsn* 13:1–10.
- Dempster, A. P.; Laird, N. M.; y Rubin, D. B. 1977. Maximum likelihood from incomplete data via the em algorithm. *Journal of the Royal Statistical Society: Series B (Methodological)* 39(1):1–22.
- Devlin, J.; Chang, M.-W.; Lee, K.; y Toutanova, K. 2018. Bert: Pre-training of deep bidirectional transformers for language understanding. *arXiv preprint arXiv:1810.04805*.
- Forman, G. 2003. An extensive empirical study of feature selection metrics for text classification. *Journal of machine learning research* 3(Mar):1289–1305.
- Glorot, X., y Bengio, Y. 2010. Understanding the difficulty of training deep feedforward neural networks. In *Proceedings of the thirteenth international conference on artificial intelligence and statistics*, 249–256.
- Glorot, X.; Bordes, A.; y Bengio, Y. 2011. Deep sparse rectifier neural networks. In *Proceedings of the fourteenth international conference on artificial intelligence and statistics*, 315–323.
- Goodfellow, I.; Bengio, Y.; y Courville, A. 2016. *Deep learning*. MIT press.
- Grave, E.; Bojanowski, P.; Gupta, P.; Joulin, A.; y Mikolov, T. 2018. Learning word vectors for 157 languages. *arXiv preprint arXiv:1802.06893*.
- Han, S.; Gao, J.; y Ciravegna, F. 2019. Neural language model based training data augmentation for weakly supervised early rumor detection. In *Proceedings of the 2019 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining*, 105–112.
- Hedderich, M. A., y Klakow, D. 2018. Training a neural network in a low-resource setting on automatically annotated noisy data. *arXiv preprint arXiv:1807.00745*.
- Hochreiter, S., y Schmidhuber, J. 1997. Long short-term memory. *Neural computation* 9(8):1735–1780.

- Ikeda, K.; Hattori, G.; Ono, C.; Asoh, H.; y Higashino, T. 2013. Twitter user profiling based on text and community mining for market analysis. *Knowledge-Based Systems* 51:35–47.
- Jimenez-Villar, V.; Sánchez-Junquera, J.; Montes-y Gómez, M.; Villaseñor-Pineda, L.; y Ponzetto, S. P. 2019. Bots and gender profiling using masking techniques. In *Proceedings of the Ninth International Conference of the CLEF Association (CLEF 2019)*.
- Jones, K. S. 1972. A statistical interpretation of term specificity and its application in retrieval. *Journal of documentation* 28(1):11–21.
- Jungiewicz, M., y Smywiński-Pohl, A. 2019. Towards textual data augmentation for neural networks: synonyms and maximum loss. *Computer Science* 20:57–83.
- Kadhim, A. I. 2019. Survey on supervised machine learning techniques. *Artificial Intelligence Review* 52(1):273–292.
- Kamath, U.; Liu, J.; y Whitaker, J. 2019. *Deep learning for nlp and speech recognition*, volume 84. Springer.
- Kim, Y. 2014. Convolutional neural networks for sentence classification. In *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 1746–1751.
- Kobayashi, S. 2018. Contextual augmentation: Data augmentation by words with paradigmatic relations. In *Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 2 (Short Papers)*, 452–457.
- Kowsari, K.; Jafari Meimandi, K.; Heidarysafa, M.; Mendu, S.; Barnes, L.; y Brown, D. 2019. Text classification algorithms: A survey. *Information* 10(4):150.
- Kumar, R.; Reganti, A. N.; Bhatia, A.; y Maheshwari, T. 2018. Aggression-annotated corpus of hindi-english code-mixed data. *arXiv preprint arXiv:1803.09402*.
- Kumar, A.; Bhattamishra, S.; Bhandari, M.; y Talukdar, P. 2019. Submodular optimization-based diverse paraphrasing and its effectiveness in data augmentation. In *Proceedings of the 2019 Conference of the North American Chapter of the*

- Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers)*, 3609–3619.
- Laserna, C. M.; Seih, Y. T.; y Pennebaker, J. W. 2014. Um. . Who Like Says You Know: Filler Word Use as a Function of Age, Gender, and Personality. *Journal of Language and Social Psychology* 33(3):328–338.
- LeCun, Y.; Bengio, Y.; y Hinton, G. 2015. Deep learning. *nature* 521(7553):436–444.
- Levy, O., y Goldberg, Y. 2014. Linguistic regularities in sparse and explicit word representations. In *Proceedings of the eighteenth conference on computational natural language learning*, 171–180.
- Liu, N.; Zhou, Z.; Xin, K.; y Ren, F. 2018. Tual at erisk 2018. In *CLEF (Working Notes)*.
- Loper, E., y Bird, S. 2002. Nltk: the natural language toolkit. *arXiv preprint cs/0205028*.
- Losada, D. E.; Crestani, F.; y Parapar, J. 2017. erisk 2017: Clef lab on early risk prediction on the internet: experimental foundations. In *International Conference of the Cross-Language Evaluation Forum for European Languages*, 346–360. Springer.
- Losada, D. E.; Crestani, F.; y Parapar, J. 2018. Overview of eRisk 2018: Early Risk Prediction on the Internet (extended lab overview). *CEUR Workshop Proceedings* 2125.
- Losada, D. E.; Crestani, F.; y Parapar, J. 2019a. Overview of eRisk 2019 Early Risk Prediction on the Internet. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* 11696 LNCS:340–357.
- Losada, D. E.; Crestani, F.; y Parapar, J. 2019b. Overview of erisk at clef 2019: Early risk prediction on the internet (extended overview). In *CLEF (Working Notes)*.
- Manning, C. D. 2015. Computational Linguistics and Deep Learning. *Computational Linguistics* 41(4).

- Mikolov, T.; Sutskever, I.; Chen, K.; Corrado, G. S.; y Dean, J. 2013. Distributed representations of words and phrases and their compositionality. In *Advances in neural information processing systems*, 3111–3119.
- Mikolov, T.; Grave, E.; Bojanowski, P.; Puhersch, C.; y Joulin, A. 2017. Advances in pre-training distributed word representations. *arXiv preprint arXiv:1712.09405*.
- Mikolov, T.; Yih, W.-t.; y Zweig, G. 2013. Linguistic regularities in continuous space word representations. In *Proceedings of the 2013 conference of the north american chapter of the association for computational linguistics: Human language technologies*, 746–751.
- Minaee, S.; Kalchbrenner, N.; Cambria, E.; Nikzad, N.; Chenaghlu, M.; y Gao, J. 2020. Deep learning based text classification: A comprehensive review. *arXiv preprint arXiv:2004.03705*.
- Miyato, T.; Maeda, S.-i.; Koyama, M.; y Ishii, S. 2019. Virtual Adversarial Training : A Regularization Method for Supervised and Semi-Supervised Learning. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 41(8):1979–1993.
- Nothman, J.; Qin, H.; y Yurchak, R. 2018. Stop word lists in free open-source software packages. In *Proceedings of Workshop for NLP Open Source Software (NLP-OSS)*, 7–12.
- Ortega-Mendoza, R. M.; López-Monroy, A. P.; Franco-Arcega, A.; y Montes-y Gómez, M. 2018a. Emphasizing personal information for Author Profiling: New approaches for term selection and weighting. *Knowledge-Based Systems* 145:169–181.
- Ortega-Mendoza, R. M.; López-Monroy, A. P.; Franco-Arcega, A.; y Montes-y Gómez, M. 2018b. Peimex at erisk2018: Emphasizing personal information for depression and anorexia detection. In *CLEF (Working Notes)*.
- Park, D., y Ahn, C. W. 2019. Self-supervised contextual data augmentation for natural language processing. *Symmetry* 11(11):1393.
- Pennebaker, J. W.; Francis, M. E.; y Booth, R. J. 2001. Linguistic inquiry and word count: Liwc 2001. *Mahway: Lawrence Erlbaum Associates* 71(2001):2001.

- Pennebaker, J. W.; Mehl, M. R.; y Niederhoffer, K. G. 2002. Psychological Aspects of Natural Language Use: Our Words, Our Selves. *Annual Review of Psychology* 54(1):547–577.
- Pennington, J.; Socher, R.; y Manning, C. D. 2014. Glove: Global vectors for word representation. In *Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP)*, 1532–1543.
- Peters, M. E.; Neumann, M.; Iyyer, M.; Gardner, M.; Clark, C.; Lee, K.; y Zettlemoyer, L. 2018. Deep contextualized word representations. *arXiv preprint arXiv:1802.05365*.
- Pizarro, J. 2019. Using n-grams to detect bots on twitter: notebook for pan at clef 2019. In *Proceedings of the Ninth International Conference of the CLEF Association (CLEF 2019)*.
- Porter, M. F. 2001. Snowball: A language for stemming algorithms.
- Rangel, F., y Rosso, P. 2019. Overview of the 7th Author Profiling Task at PAN 2019: Bots and Gender Profiling. *CLEF 2019 Labs and Workshops, Notebook Papers. CEUR Workshop Proceedings*.
- Rangel, F.; Rosso, P.; Koppel, M.; Stamatatos, E.; y Inches, G. 2013. Overview of the author profiling task at PAN 2013. *CLEF Conference on Multilingual and Multimodal Information Access Evaluation* 352–365.
- Rangel, F.; Rosso, P.; Verhoeven, B.; Daelemans, W.; Potthast, M.; y Stein, B. 2016. Overview of the 4th author profiling task at PAN 2016: Cross-genre evaluations. *CEUR Workshop Proceedings* 1609:750–784.
- Rude, S.; Gortner, E.-M.; y Pennebaker, J. 2004. Language use of depressed and depression-vulnerable college students. *Cognition & Emotion* 18(8):1121–1133.
- Schuster, M., y Paliwal, K. K. 1997. Bidirectional recurrent neural networks. *IEEE transactions on Signal Processing* 45(11):2673–2681.
- Stamatatos, E.; Daelemans, W.; Verhoeven, B.; Juola, P.; López-López, A.; Pott-hast, M.; y Stein, B. 2015. Overview of the 3rd Author Profiling Task at PAN 2015.

- CLEF 2015 Labs and Workshops, Notebook Papers. CEUR Workshop Proceedings* 1391(31):898–927.
- Trotzek, M.; Koitka, S.; y Friedrich, C. M. 2018. Word embeddings and linguistic metadata at the clef 2018 tasks for early detection of depression and anorexia. In *CLEF (Working Notes)*.
- Van Dyk, D. A., y Meng, X.-L. 2001. The art of data augmentation. *Journal of Computational and Graphical Statistics* 10(1):1–50.
- Vapnik, V., y Chervonenkis, A. Y. 1964. A class of algorithms for pattern recognition learning. *Avtomat. i Telemekh* 25(6):937–945.
- Wang, S.; Liu, W.; Wu, J.; Cao, L.; Meng, Q.; y Kennedy, P. J. 2016. Training deep neural networks on imbalanced data sets. In *2016 international joint conference on neural networks (IJCNN)*, 4368–4374. IEEE.
- Wang, A.; Singh, A.; Michael, J.; Hill, F.; Levy, O.; y Bowman, S. R. 2018. Glue: A multi-task benchmark and analysis platform for natural language understanding. *arXiv preprint arXiv:1804.07461*.
- Wang, Y.-T.; Huang, H.-H.; y Chen, H.-H. 2018. A neural network approach to early risk detection of depression and anorexia on social media text. In *CLEF (Working Notes)*.
- Wei, J., y Zou, K. 2019. Eda: Easy data augmentation techniques for boosting performance on text classification tasks. In *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*, 6383–6389.
- Wu, J.; Li, L.; y Wang, W. Y. 2018. Reinforced co-training. *arXiv preprint arXiv:1804.06035*.
- Xie, Q.; Dai, Z.; Hovy, E.; Luong, M.-T.; y Le, Q. V. 2019. Unsupervised data augmentation. *arXiv preprint arXiv:1904.12848*.
- Yang, Y., y Pedersen, J. O. 1997. A comparative study on feature selection in text categorization. In *Icml*, volume 97, 35.

-
- Zhang, Y., y Wallace, B. 2015. A sensitivity analysis of (and practitioners'guide to) convolutional neural networks for sentence classification. *arXiv preprint arXiv:1510.03820*.
- Zhang, J.; Lertvittayakumjorn, P.; y Guo, Y. 2019. Integrating semantic knowledge to tackle zero-shot text classification. In *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers)*, 1031–1040.
- Zhang, X.; Zhao, J.; y LeCun, Y. 2015. Character-level convolutional networks for text classification. In *Advances in neural information processing systems*, 649–657.
- Zhong, Z.; Zheng, L.; Kang, G.; Li, S.; y Yang, Y. 2017. Random erasing data augmentation. *arXiv preprint arXiv:1708.04896*.