



EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Tecnológico Nacional de México

Centro Nacional de Investigación
y Desarrollo Tecnológico

Tesis de Maestría

Análisis automático del discurso en narraciones de
experiencias emocionales escritas bajo la técnica de
Escritura Emocional Autorreflexiva

presentada por

ISC. Pavel Ricardo Morales Ocampo

como requisito para la obtención del grado de
Maestro en Ciencias de la Computación

Director de tesis

Dr. Noé Alejandro Castro Sánchez

Codirector de tesis

Dra. Leonor Rivera Rivera

Cuernavaca, Morelos, México. Agosto de 2024.



Cuernavaca, Mor., 25/junio/2024

Asunto: Liberación de producto académico

PAVEL RICARDO MORALES OCAMPO
CANDIDATO AL GRADO DE MAESTRÍA EN CIENCIAS
DE LA COMPUTACIÓN
PRESENTE

Por este conducto, tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado "ANÁLISIS AUTOMÁTICO DEL DISCURSO EN NARRACIONES DE EXPERIENCIAS EMOCIONALES ESCRITAS BAJO LA TÉCNICA DE ESCRITURA EMOCIONAL AUTORREFLEXIVA", avala que usted tiene el siguiente producto académico, derivado de su investigación.

Artículo: "Análisis del discurso de narraciones emocionales de pacientes tratados por una técnica terapéutica".

Sin más por el momento, reciba un cordial saludo.

ATENTAMENTE

Excelencia en Educación Tecnológica@
"Conocimiento y tecnología al servicio de México"



NOÉ ALEJANDRO CASTRO SÁNCHEZ

Director de tesis



NIMROD GONZÁLEZ FRANCO

Revisor 1




EBW

LEONOR RIVERA RIVERA

Codirectora de tesis



JUAN GABRIEL GONZÁLEZ SERNA

Revisor 2

C.c.p. Jefe (a) del Depto. de Servicios Escolares





Cuernavaca, Mor.,
No. De Oficio:
Asunto:

28/junio/2024
SAC/207/2024
Autorización de
impresión de tesis

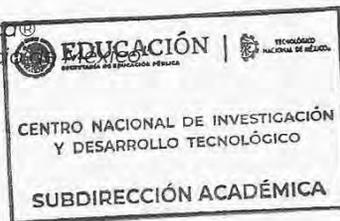
PAVEL RICARDO MORALES OCAMPO
CANDIDATO AL GRADO DE MAESTRO
EN CIENCIAS DE LA COMPUTACIÓN
P R E S E N T E

Por este conducto, tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado **“ANÁLISIS AUTOMÁTICO DEL DISCURSO EN NARRACIONES DE EXPERIENCIAS EMOCIONALES ESCRITAS BAJO LA TÉCNICA DE ESCRITURA EMOCIONAL AUTORREFLEXIVA”**, ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.

Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

ATENTAMENTE

Excelencia en Educación Tecnológica
“Conocimiento y tecnología al servicio”



CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO

C. c. p. Departamento de Ciencias Computacionales
Departamento de Servicios Escolares

CMAZ/lmz



Dedicatoria

A mi familia, que siempre es una inspiración para superarme.

A Scott, mi cómplice en esta aventura llamada vida.

Agradecimientos

Al Consejo Nacional de Ciencia y Tecnología (CONACyT) y su Programa Nacional de Posgrados de Calidad (PNPC) cuya beca me permitió ser estudiante de tiempo completo y desarrollar este trabajo de investigación.

Al Tecnológico Nacional de México, Campus Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET) por la oportunidad de formar parte de su programa y proporcionarme las herramientas para desarrollar este trabajo.

Al cuerpo académico que contribuyó con mi formación como Maestro en Ciencias de la Computación. Especialmente a mi director, Dr. Noé Alejandro Castro Sánchez, y a mi codirectora, Dra. Leonor Rivera Rivera, así como a mis revisores, Dr. Juan Gabriel González Serna y Dr. Nimrod González Franco.

Resumen

La violencia contra las mujeres se define, según la Organización de las Naciones Unidas, como todo acto de violencia basado en el género que tenga o pueda tener como resultado un daño o sufrimiento físico, sexual o mental para la mujer. Una de sus principales consecuencias es el Trastorno de Estrés Postraumático, que puede ser tratado a través de distintos métodos, siendo la terapia de Escritura Emocional Autorreflexiva (EEA) una de ellas y en la que se enfoca este trabajo. El paradigma de esta técnica terapéutica consiste en escribir acerca del evento traumático a través de diferentes ejercicios separados en el tiempo.

En este trabajo se realiza el estudio de la variación de atributos lingüísticos en los diferentes ejercicios que componen la EEA, teniendo como objetivo proveer al terapeuta con una herramienta estandarizada que le ayude a valorar los textos mediante la identificación de atributos relevantes. Se utilizan técnicas de Procesamiento de Lenguaje Natural para realizar la obtención de atributos y un análisis exploratorio manual para la caracterización de textos en el marco de la violencia contra las mujeres.

Los resultados de este trabajo incluyen un módulo de obtención de características, diccionarios que son semánticamente relevantes para el tema de violencia y un sistema basado en reglas que realiza la clasificación de textos, con el que se obtuvo un 63 % de precisión. Adicionalmente, se desarrolló un sistema web donde el terapeuta puede consultar los textos y algunos gráficos de atributos que resultaron relevantes al caracterizar los textos y que se espera sean de apoyo a la práctica clínica del terapeuta.

Abstract

Violence against women is defined, according to the United Nations, as any act of gender-based violence that results or may result in physical, sexual or mental harm or suffering for women. One of its main consequences is Post-Traumatic Stress Disorder, which can be treated through different methods, such as Written Emotional Disclosure therapy, which this work focuses on. The paradigm of this therapeutic technique consists of writing about the traumatic event through different exercises separated in time.

In this work, we study of the variation of linguistic attributes in the different exercises that comprise the Written Emotional Disclosure, with the objective of providing therapists with a standardized tool that helps them evaluate the texts by identifying relevant attributes. Natural Language Processing techniques are used to obtain attributes and a manual exploratory analysis for the characterization of texts in the context of violence against women.

The results of this work include a feature extraction module, dictionaries that are semantically relevant to the topic of violence against women, and a rule-based system that performs text classification, with which 63% accuracy was obtained. Additionally, a web system was developed where the therapist can consult the texts and some graphs of attributes that were relevant when characterizing the texts and that are expected to support the therapist's clinical practice.

Índice

Resumen	2
Abstract.....	7
Agradecimientos.....	5
Dedicatoria.....	4
Índice	8
Índice de tablas	12
Índice de figuras	13
Capítulo I Introducción.....	14
1.1. Descripción del problema.....	15
1.2. Objetivos	16
1.3. Alcances y Limitaciones	16
1.4. Justificación.....	17
Capítulo II Marco teórico	19
2.1. Contexto social	20
2.2. Contexto computacional.....	22
Capítulo III Estado del arte.....	24
3.1. Linguistic Inquiry and Word Count (LIWC) (Pennebaker, et al., 2015).	25
3.2. Coh-Metrix (McNamara, et al., 2017; Graesser, et al., 2004).....	26
3.3. Uso del procesamiento del lenguaje y el análisis del habla para la identificación de psicosis y otros trastornos (Cecchi & Corcoran, 2020).....	28
3.3.2. Análisis lingüísticos manuales en jóvenes en riesgo	28
3.4. Análisis del habla mediante técnicas de procesamiento del lenguaje natural: ¿una posible herramienta para la detección temprana del deterioro cognitivo? (Beltrami, et al., 2018).	

.....	29
3.5. Red neuronal convolucional superficial para el reconocimiento implícito de la relación del discurso (Zhang, et al., 2015).	30
3.6. Exploración de métodos neuronales para analizar estructuras de representación del discurso (Noord, et al., 2018).....	33
3.7. Clasificación automatizada de marcadores discursivos (Robledo & Nazar, 2018).....	35
3.8. Un detector de la unidad central de un texto basado en técnicas de aprendizaje automático en textos científicos para el euskera (Bengoetxea, et al., 2017).....	36
3.9. Un método de análisis de dos etapas para el análisis del discurso a nivel de texto (Yizhong Wang, 2017).....	37
3.10. El procesamiento en lenguaje natural de las notas clínicas de salud mental puede agregar valor predictivo a los modelos de riesgo de suicidio existentes (Maxwell Levis, 2020)	39
3.11. Uso del procesamiento del lenguaje natural para identificar síntomas obsesivo-compulsivos en pacientes con esquizofrenia, trastorno esquizoafectivo o trastorno bipolar (Chandran, et al., 2019).....	39
3.12. Descripción general de la tarea de detección de cambios de estilo en PAN 2020 (Zangerle, et al., 2020)	40
3.13. Análisis de la caracterización discursiva de los relatos migratorios en Twitter. El caso Aquarius. (Fernández, et al., 2020).....	42
3.14. ¿Hablamos? Análisis del discurso y estrategias empleadas en WhatsApp por estudiantes universitarios (García, 2020)	43
3.15. Adaptación de BERT a la clasificación de relaciones implícitas del discurso con un enfoque en los conectivos del discurso (Kishimoto, et al., 2020).....	44
3.16. DisSent: Aprendiendo las representaciones de oraciones a partir de relaciones discursivas explícitas (Nie, et al., 2019).....	45
3.17. Desenmascarando la conversación sobre cubrebocas: procesamiento del lenguaje natural para el análisis de sentimientos en los discursos de COVID-19 en	

Twitter (Sanders, et al., 2021).....	46
3.18. El impacto del discurso científico en Twitter (Denia, 2020).....	47
3.19. Mecanismos lingüísticos de coherencia en el discurso afásico y no afásico (Levis, et al., 2020).....	47
3.20. Discurso y sentimiento públicos durante la pandemia de COVID 19: uso de la Latent Dirichlet allocation para modelar temas en Twitter (XueI, et al., 2020).....	48
3.21. Senicidio moderno frente a una pandemia: un examen del discurso público y el sentimiento sobre los adultos mayores y el COVID-19 mediante el aprendizaje automático (Xiang, et al., 2020).....	49
3.22. ¿La resiliencia media la asociación entre los síntomas de salud mental y los marcadores lingüísticos del procesamiento del trauma? Analizando las narrativas de mujeres sobrevivientes de violencia de pareja (Castiglioni, et al., 2023).....	49
3.23. Tabla comparativa de los trabajos relacionados.....	51
Capítulo IV Metodología de solución.....	57
4.1. Sistemas basados en conocimiento.....	58
4.2. Descripción del corpus.....	59
4.3. Análisis exploratorio manual / Caracterización del fenómeno.....	60
4.4. Generación y recopilación de diccionarios.....	63
4.5. Descripción de los atributos.....	65
4.6. Selección de atributos.....	66
Capítulo V Desarrollo de la solución.....	68
5.1. Etiquetado de los textos.....	69
5.1. Modelo.....	70
5.2. Sistema TerapiaEscritura.....	75
5.3. Generación de reportes/gráficas en el sistema.....	86
Capítulo VI Pruebas.....	87

6.1. Almacenamiento de textos en la base de Datos.....	88
6.2. Ejecución del sistema clasificador	88
6.3. Login en la página web	88
6.4. Exploración y consulta de gráficos, textos e informes	89
Capítulo VII Resultados y conclusiones.....	90
7.1. Resultados obtenidos.....	91
7.2. Conclusiones	92
7.3. Trabajos futuros.....	95
7.4. Aportaciones y productos académicos	96
Referencias	97
Anexos.....	102
Anexo 1 Listado de variables	103
Anexo 2 Pruebas utilizando modelos de aprendizaje automático	106
Anexo 3 Formalización de reglas	107

Índice de tablas

Tabla 1 Comparación de rendimiento con diferentes sistemas	33
Tabla 2 Resultado de la prueba comparando el modelo neuronal	34
Tabla 3 Tabla de resultados	37
Tabla 4 Resumen de la herramienta	47
Tabla 5 Identificación de bigramas por tema	49
Tabla 6 Comparativa de trabajos relacionados, parte 1	51
Tabla 7 Comparativa de trabajos relacionados, parte 2	52
Tabla 8 Comparativa de trabajos relacionados, parte 3	53
Tabla 9 Comparativa de trabajos relacionados, parte 4	54
Tabla 10 Comparativa de trabajos relacionados, parte 5	55
Tabla 11 Comparativa de trabajos relacionados, parte 6	56
Tabla 12 Resumen de cuestionarios de mujeres víctimas de violencia	59
Tabla 13 Resumen del corpus obtenido	60
Tabla 14 Cantidad de textos por	60
Tabla 15 Áreas temáticas y códigos	63
Tabla 16 Resumen de los diccionarios recolectados	64
Tabla 17 resumen de diccionarios generados	64
Tabla 18 Resultados de Info Gain y Anova	67
Tabla 19 Valoración del coeficiente de Kappa (Landis y Koch)	69
Tabla 20 Matriz de confusión del modelo generado	73
Tabla 21 Métricas del modelo	74
Tabla 22 Tabla de objetivos alcanzados en este trabajo	94
Tabla 23 Lista de variables obtenidas (1/3)	103
Tabla 24 Lista de variables obtenidas (2/3)	104
Tabla 25 Lista de variables obtenidas (3/3)	105
Tabla 26 Métricas de los modelos entrenados	106

Índice de figuras

Figura 1 Arquitectura del modelo de Red Neuronal Convolutiva Superficial visualizado con una instancia	32
Figura 2 Pseudocódigo del clasificador de MDs.....	36
Figura 3 Comparación en las tareas.....	42
Figura 4 Método de solución para la caracterización discursiva.....	43
Figura 5 Categorías gramaticales por sexo.....	44
Figura 6 Marcadores del discurso para diferentes corpus	46
Figura 7 Patrones de dependencia para la extracción.....	46
Figura 8 Diseño de sistema experto.....	58
Figura 9 Etiquetado de las partes del texto.....	61
Figura 10 Matriz de correlación de términos.....	61
Figura 11 Agrupamiento.....	62
Figura 12 Diccionarios generados	66
Figura 13 Usos de vocabulario de reflexión.....	70
Figura 14 Gráfico de total de palabras.....	70
Figura 15 En este diagrama se ilustra el funcionamiento.....	71
Figura 16 Arquitectura del sistema.....	75
Figura 17 Sistema TerapiaEscritura y sus subsistemas	76
Figura 18 Diagrama de entidad-relación de la Base de datos.....	77
Figura 19 Inicio de sesión del terapeuta	79
Figura 20 Pantalla de selección de la usuaria y texto	80
Figura 21 El texto seleccionado aparecerá en el textarea	81
Figura 22 Pantalla de revisión temática.....	82
Figura 23 Estadística individual de los textos.. ..	83
Figura 24 Gráficos de vocabularios.....	84
Figura 25 Informe general	85
Figura 26 Proceso de pruebas del sistema	88
Figura 27 Listado de material generado	91

Capítulo I

Introducción

El procesamiento de Lenguaje Natural (PLN) es un campo de las Ciencias de la Computación, la Inteligencia Artificial y la Lingüística que utiliza el aprendizaje automático para procesar e interpretar datos textuales. El PLN puede ser utilizado para desarrollar diferentes herramientas, que pueden ir desde el análisis de textos, sistemas de corrección ortográfica, motores de búsqueda y herramientas de diálogo computacional.

Las técnicas de PLN pueden ser de utilidad en campos diferentes a la computación. En este trabajo, se emplean técnicas de PLN en el tratamiento psicológico de pacientes, específicamente mujeres víctimas de violencia. La terapia de Escritura Emocional Autorreflexiva (EEA) es un tipo de intervención alternativa aplicada para el tratamiento de trastornos ocasionados por eventos traumáticos, principalmente el Trastorno de Estrés Postraumático (TEPT). Por medio de la escritura, la EEA promueve que sus pacientes traten los temas relacionados con su trauma, logrando una mejora en su salud y su bienestar.

En este trabajo se utiliza el Procesamiento de Lenguaje Natural para realizar el procesamiento y el análisis de textos generados por pacientes tratados por la terapia de Escritura Emocional Autorreflexiva (EEA) en una población de mujeres que han sido víctimas de violencia.

1.1.Descripción del problema

La terapia de Escritura Emocional Autorreflexiva (EEA) es un tipo de intervención alternativa aplicada para el tratamiento de trastornos ocasionados por eventos traumáticos (Ortiz-Velázquez, et al., 2022). Por medio de la escritura, la EEA promueve que sus pacientes traten los temas relacionados con su trauma; sin embargo, aunque los beneficios de esta técnica están demostrados en experimentos (Cabrera, 2006), la reestructuración cognitiva del paciente se evalúa tradicionalmente a través de diversos tests (de ansiedad, de estrés postraumático, entre otros) o de forma subjetiva por el terapeuta y su experiencia, lo que requiere de aspectos mayormente cualitativos. Debido a lo anterior, en este trabajo se propuso analizar si la evolución en las narraciones emocionales del paciente está relacionada con la mejora de este. Para lograrlo, se analizan los textos a través de técnicas de Procesamiento de Lenguaje Natural.

1.2.Objetivos

General

Identificar la influencia de narraciones de experiencias emocionales escritas en la reestructuración cognitiva de pacientes tratados por la técnica de EEA aplicando un análisis automático del discurso.

Específicos

- Proponer e implementar un método de análisis del discurso utilizando técnicas de Procesamiento de Lenguaje Natural.
- Generar un corpus de narraciones emocionales.
- Identificar las unidades lingüísticas más representativas al medir el discurso.
- Identificar qué unidades lingüísticas están correlacionadas con la mejora de un paciente.
- Proponer un método de análisis que permita medir cuantitativamente el cambio cognitivo según los atributos del discurso.

1.3.Alcances y Limitaciones

Alcances

- Conformar un corpus de textos de generados con la técnica de EEA.
- Realizar un estudio de correlación entre las características del discurso y la mejora cognitiva medida a través de tests psicométricos.
- Definir las características del discurso que son representativas para medir el cambio cognitivo.
- Desarrollar un método de análisis de discurso que permita medir el cambio cognitivo de un paciente tratado por la técnica de EEA según los atributos del discurso.

Limitaciones

- Se analizarán textos únicamente en español.
- No se evaluarán características que no sean representativas para medir el cambio cognitivo.
- Los resultados arrojados por el método desarrollado serán de apoyo al terapeuta y nunca como un sustituto, además quedarán sujetos a comprobación por el mismo.

1.4. Justificación

La violencia contra las mujeres se define como todo acto de violencia basado en el género que tenga o pueda tener como resultado un daño o sufrimiento físico, sexual o mental para la mujer (Naciones Unidas, 1993). En 2021, a nivel nacional, del total de mujeres mayores de 15 años, más del 70 % ha experimentado al menos un incidente de violencia (INEGI, 2022). Una de las principales secuelas físicas y psicológicas en las víctimas de violencia es el Trastorno por Estrés Postraumático (TEPT).

Según la OMS, el trastorno de estrés postraumático (TEPT) es una enfermedad mental que se desarrolla en algunas personas que han experimentado una situación traumática o aquellos que han sido amenazados de muerte, o han sufrido abuso sexual, violencia o lesiones. Este trauma puede afectar todos los aspectos de la vida de una persona, incluyendo sus aspectos mentales, emocionales y bienestar físico.

La terapia cognitivo conductual (TCC) es el tratamiento más eficaz para el TEPT. Por lo general, TCC implica reunirse con su terapeuta semanalmente durante cuatro meses. (PTSD, 2015). Otra terapia que ha demostrado eficacia en el tratamiento del TEPT es la Escritura Emocional Autorreflexiva, en la que el paciente aborda su trauma a través de ejercicios escritos.

Tradicionalmente, la evaluación de la reestructuración cognitiva en pacientes ha sido llevada a cabo mediante tests estandarizados, como los de ansiedad y estrés postraumático, o mediante la observación subjetiva del terapeuta, basada en su experiencia clínica. Estos métodos, aunque efectivos, dependen en gran medida de aspectos cualitativos, tales como la capacidad del paciente para recuperar la expresión verbal de sus sentimientos, la reaparición de expresiones gestuales o los cambios en los hábitos reportados por el paciente. Sin

embargo, el uso de evaluaciones subjetivas basadas en la experiencia podría representar una limitación para el ejercicio del terapeuta.

Dada la importancia de una evaluación más objetiva en el proceso terapéutico, este trabajo de tesis busca explorar una alternativa innovadora mediante la cuantificación de la evolución en las narraciones emocionales de los pacientes. La hipótesis central es que existe una relación significativa entre la mejora del estado del paciente y la evolución de sus narraciones emocionales, es decir, en la manera en que el paciente narra. Para comprobar esta hipótesis, se propone utilizar técnicas de Procesamiento de Lenguaje Natural (PLN), e identificar y cuantificar las variables lingüísticas en los textos de los pacientes.

El enfoque propuesto tiene como beneficio la creación de un modelo automatizado que puede medir de manera consistente y objetiva las variables lingüísticas asociadas con el progreso terapéutico. Además, este trabajo espera contribuir significativamente a la práctica clínica y a la investigación en psicoterapia, proporcionando herramientas confiables.

Capítulo II

Marco teórico

2.1.Contexto social

En este apartado se muestran los conceptos relacionados con la problemática social abordada en este trabajo, temas relacionados con la violencia contra las mujeres y los efectos en su salud mental, así como los conceptos de terapia y su beneficio. Todos estos conceptos sustentan las bases de este trabajo.

2.1.1. Violencia hacia las mujeres

La Organización Mundial de la Salud (OMS) define como violencia a “El uso deliberado de la fuerza física o el poder, ya sea en grado de amenaza o efectivo, contra uno mismo, otras personas o un grupo o comunidad, que cause o tenga muchas probabilidades de causar lesiones, muerte, daños psicológicos, trastornos de desarrollo o privaciones” (Salud, 2002). En los dos últimos decenios, la violencia contra las mujeres ha llegado a entenderse como forma de discriminación y violación de los derechos humanos de las mujeres (Mujeres, 2012).

La violencia contra las mujeres es transversal, afecta a todas las mujeres en su diversidad, sin distinciones de ningún tipo. Incluye diversas manifestaciones y tipos de violencia y ocurre tanto en el ámbito público como en el privado. En la violencia contra las mujeres se reconocen diferentes tipos, como la Física, la Psicológica, la Sexual y la Económica (Género, 2020).

2.1.2. Trastorno de Estrés Postraumático (TEPT)

Según la OMS, el trastorno de estrés postraumático (TEPT) es una enfermedad mental que se desarrolla en algunas personas que han experimentado una situación traumática o evento aterrador como un desastre natural, una accidente o asalto, o aquellos que han sido amenazados de muerte, sufrido abuso sexual o violencia o lesiones. Este trauma puede afectar todos los aspectos de la vida de una persona, incluyendo sus aspectos mentales, emocionales y bienestar físico. Los síntomas de PTSD a menudo coexisten con otras condiciones como depresión y ansiedad (Organization, 2023).

2.1.3. Terapia

De acuerdo con la American Psychiatric Association (Ferrer & R. Delgado, 2018), la terapia es un tipo de tratamiento que puede ayudar a las personas que experimentan condiciones de salud mental y desafíos emocionales. La terapia puede ayudar no solo a aliviar los síntomas, sino que también pueden ayudar a identificar las causas psicológicas fundamentales de la afección.

2.1.4. Restructuración cognitiva

La reestructuración cognitiva (RC) es una de las técnicas de intervención psicológica más utilizadas en la práctica clínica y es ampliamente utilizada por psicólogos de diferentes orientaciones (Rebeca Pardo Cebrián, 2017).

El término se ha utilizado para describir el cambio del paciente en una Terapia Cognitiva. Se refiere a un enfoque terapéutico estructurado y colaborativo donde el paciente aprende a identificar, evaluar y modificar los pensamientos, valoraciones y creencias defectuosas que se consideran responsables de su trastorno psicológico (Clark, 2014).

A través de esta reestructuración el paciente aprende a modificar pensamientos negativos, así como reconocer que algunos pensamientos pueden ser inexactos; el paciente se vuelve consciente de su trauma y aprende a identificar factores de riesgo para recaídas (Jacob, et al., 2011)

2.1.5. Escritura Emocional Autorreflexiva (EEA)

La Escritura Emocional Autorreflexiva (EEA) una técnica terapéutica que consiste en la escritura de textos sobre un evento traumático; se considera emocional porque es necesario que el paciente no sólo describa objetivamente los acontecimientos, sino que exprese las emociones que ellos le causaron; es autorreflexiva ya que el paciente debe buscar las causas del acontecimiento y de sus emociones, no sólo debe quejarse o intentar demorar una posible solución directa de los problemas. Sin alguno de los dos componentes, los resultados terapéuticos serían de bajo impacto en la salud psicosomática del participante (Valderrama, et al., n.d.) citado por (Dzib Aguilar, et al., 2010).

Según (Olvera, et al., 2002), la EEA permite evaluar el lenguaje emocional según su

valencia positiva y negativa, promueve un lenguaje afectivo que induce cambios en la reestructuración cognitiva. También describe que la técnica consta de cuatro ejercicios escritos que el paciente deberá hacer:

- 1) Escribir alguna experiencia que le haya causado malestar y que no haya contado (ejercicio A);
- 2) Volver a escribir la misma experiencia, pero incorporando la mayor cantidad de palabras que le acomoden a su texto de una lista de palabras afectivas que se le proporciona y se dejan al alcance de su vista (ejercicio B);
- 3) Escribir la misma experiencia, pero ahora narrada en tercera persona (ejercicio C),
- 4) Escribir sobre lo que aprendió de esa experiencia (ejercicio D).

En 1986, Pennebaker y Beall introdujeron el paradigma de la escritura expresiva o la escritura emocional autorreflexiva (EEA) para probar si revelar experiencias estresantes o traumáticas es beneficioso para la salud (Warner, et al., 2006). La confrontación del evento ocurrido requiere la traducción de los pensamientos y sentimientos a palabras, generando en el proceso una integración cognitiva y una comprensión con mayor detalle de la situación, contribuyendo con la disminución de los síntomas fisiológicos y emocionales (Ortiz, et al., 2022). Con sus estudios quedó demostrado el impacto de los ejercicios de escritura en los pacientes, ya que los usuarios sobre los que se aplicó la terapia demostraron escritos más autorreflexivos y más en contacto con sus emociones.

2.2.Contexto computacional

En esta sección se muestran los conceptos relacionados al Procesamiento de Lenguaje Natural y a las técnicas computacionales utilizadas para el análisis de textos desde el punto de vista de la ingeniería.

2.2.1. Procesamiento de Lenguaje Natural (PLN)

El procesamiento del lenguaje natural (PLN) es un conjunto de técnicas computacionales para el análisis automático y representación de lenguajes humanos (Chowdhary, 2020).

El uso de PLN permite el desarrollo de aplicaciones que permitan la interacción humano-computadora entre un usuario y sistemas computacionales e informáticos, siendo una alternativa a interfaces gráficas y permitiendo el desarrollo de interacciones intuitivas que proporcionan una ventaja en la comunicación (Ortiz, et al., 2022).

2.2.2. Preprocesamiento de textos

El preprocesamiento de textos consiste en una etapa inicial del análisis de textos mediante PLN. En esta etapa se transforman los textos identificando qué unidades (por ejemplo, palabras y frases) usar (es decir, tokenizar), eliminando contenido que es irrelevante para algunas tareas (es decir, eliminando caracteres no alfabéticos, palabras vacías, eliminación de puntuación), aglomerando términos semánticamente relacionados para disminuir la escasez de datos y aumentar el poder predictivo (es decir, conversión de minúsculas, corregir errores ortográficos, expandir contracciones/abreviaturas y raíz/lematizar) (Hickman, et al., 2022) .

2.2.3. Discurso

El discurso es un fenómeno humano que involucra complicadas relaciones entre diversas dimensiones o aspectos, principalmente la comunicación (Meruane, 2008). Según la RAE (2020), el discurso es una serie de palabras y frases empleadas para manifestar lo que se piensa o se siente.

2.2.4. Análisis del discurso

El análisis del discurso es un campo interdisciplinario que estudia la estructura y el uso del lenguaje en contextos de comunicación. El análisis del discurso no se limita al estudio de las estructuras lingüísticas del texto o del habla, sino que también abarca las estructuras y los procesos cognitivos y sociales que subyacen a la producción y comprensión del discurso (Dijk, 1997). Este enfoque incluye el análisis de elementos como la cohesión, la coherencia, la semántica, la pragmática y el contexto social.

Capítulo III

Estado del arte

En este capítulo se presentan los trabajos de investigación relacionados con esta tesis. Se consideraron aquellos trabajos que involucran el análisis de textos a través de diferentes métodos de Procesamiento del Lenguaje Natural, específicamente aquellos que realizan estudios semánticos, estudios de variables que se consideraron relevantes y el análisis del discurso, así como de aquellos trabajos que han utilizado la PLN en ámbitos relacionados con la salud.

Se presenta un breve resumen de un total de veintidós artículos. Al final del capítulo se agrega una tabla comparativa y de resumen de estos trabajos.

3.1.Linguistic Inquiry and Word Count (LIWC) (Pennebaker, et al., 2015).

Linguistic Inquiry and Word Count" (LIWC) es un programa de computadora que analiza textos, diseñado por James W. Pennebaker, Roger J. Booth, y Martha E. Francis. El LIWC calcula cómo las personas usan diferentes categorías de palabras a través de diversos textos. LIWC permite determinar el grado en que autores/hablantes usan palabras que connotan emociones positivas o negativas, autoreferencias, palabras extensas o palabras que se refieren a sexo, comer o religión.

El framework de LIWC2015, tanto en su versión estándar como en la versión web de la aplicación LIWC2015 se basan en un diccionario predeterminado interno que define qué palabras deben contarse en los archivos de texto de destino. El procesador LIWC2015 es un archivo ejecutable y no se puede leer ni abrir.

En operación puede acceder a un solo archivo de texto, a un grupo de archivos o a textos dentro de una hoja de cálculo, y analiza cada uno de forma secuencial. Para cada archivo, LIWC2015 lee una palabra a la vez. A medida que se procesa cada palabra de destino, se busca en el archivo de diccionario, buscando una coincidencia con la palabra de destino actual. Si la palabra de destino coincide con una palabra del diccionario, se incrementa la escala de categoría de palabra apropiada (o escalas) para esa palabra.

Para cada archivo de texto, se escriben aproximadamente 90 variables de salida como una línea de datos en un archivo de salida. Este registro de datos incluye el nombre del archivo y el recuento de palabras, 4 variables de resumen del lenguaje (pensamiento analítico, influencia, autenticidad y tono emocional), 3 categorías de descriptores generales (palabras

por oración, porcentaje de palabras objetivo capturadas por el diccionario y porcentaje de palabras en el texto que tiene más de seis letras), 21 dimensiones lingüísticas estándar (por ejemplo, porcentaje de palabras en el texto que son pronombres, artículos, verbos auxiliares, etc.), 41 categorías de palabras que hacen coincidencia con constructos psicológicos (por ejemplo, afecto, cognición, procesos biológicos, impulsos), 6 categorías de interés personal (p. ej., trabajo, hogar, actividades de ocio), 5 marcadores de lenguaje informal (asentimientos, rellenos, palabrotas, netspeak¹) y 12 categorías de puntuación (puntos, comas, etc.).

3.1.1. El diccionario predeterminado LIWC2015

El Diccionario LIWC2015 es el corazón del análisis de texto. El Diccionario LIWC2015 predeterminado está compuesto por casi 6.400 palabras, raíces de palabras y emoticonos selectos. Cada entrada del diccionario define además una o más categorías de palabras o sub-diccionarios. Por ejemplo, la palabra «lloró» es parte de cinco categorías de palabras: tristeza, emoción negativa, afecto general, verbos y tiempo-pasado. Por lo tanto, si la palabra «lloró» se encuentra en el texto de destino, se incrementará cada una de estas cinco puntuaciones de la escala del sub-diccionario. Como en este ejemplo, muchas de las categorías de LIWC2015 están ordenadas jerárquicamente. Todas las palabras de tristeza, por definición, pertenecen a la categoría más amplia de "emoción negativa", así como a la categoría de "palabras de afecto general".

3.2. Coh-Metrix (McNamara, et al., 2017; Graesser, et al., 2004)

Esta herramienta se concentra en un nivel de lenguaje llamado coherencia o cohesión. Para este trabajo se usa el concepto de cohesión como una característica del texto, mientras que la coherencia es una característica de la representación mental del contenido del texto.

Coh-Metrix analiza textos en más de 50 tipos de relaciones de cohesión y más de 200 medidas de lenguaje, texto y legibilidad. Coh-Metrix es sensible a un amplio perfil de características de lenguaje y cohesión. Hay módulos que utilizan léxicos, categorizadores de parte del discurso, analizadores sintácticos, plantillas, corpus, representaciones estadísticas del conocimiento mundial y otros componentes que se utilizan ampliamente en lingüística

¹ Informal: jerga, abreviaturas y emoticonos que suelen utilizar los usuarios de Internet.

computacional.

Lo que hace Coh-Metrix es aplicar el etiquetado de parte del discurso (POS) a través de un analizador sintáctico e identificar raíces y formas morfológicas (por ejemplo, tiempo pasado, plurales), que se utilizan para luego identificar conexiones relacionales en diferentes partes del texto. Estos incluyen la superposición en el uso de palabras con ellas mismas y con aquellas que comparten una raíz morfológica, así como con pronombres.

Algunos de los aspectos que se analizan son:

- LSA: Análisis Semántico Latente.
- Co-reference Cohesión: La co-referencia ocurre cuando un sustantivo, pronombre o NP se refiere a otro constituyente en el texto. Se ha investigado ampliamente en los campos de la lingüística del texto y los procesos del discurso.
- Word Information: Familiaridad, concreción, imgeabilidad, Paivio meaningfulness, age of acquisition.
- Word Frequency: Qué tan frecuente es una palabra en el idioma.
- Part of Speech: POS para palabras de contenido (sustantivos, verbos, adjetivos, adverbios...) y palabras funcionales (preposiciones, determinantes y pronombres).
- Density Scores: medición de la incidencia, razón o proporción de determinadas clases de palabras o constituyentes en el texto.
- Logical Operators: or, and, not, y if-then.
- Connectives: son palabras extremadamente importantes para medir la cohesión, por ejemplo *en otras palabras, también, además*.
- Polysemy and Hypernym: polisemia para medir la ambigüedad de una palabra, e hiperónimos para medir el índice de abstracción de una palabra.
- Readability: se mide la dificultad del texto usando la fórmula Flesch Reading Ease. Syntactic Complexity: varias métricas que miden qué tan difícil es analizar la composición sintáctica del texto.
Co-reference Cohesion: Ocurre cuando un sustantivo, pronombre o frase nominal refiere a otro en el texto.
- Concept Clarity: determinan la ambigüedad y qué tan vago o abstracto es un texto.

3.3. Uso del procesamiento del lenguaje y el análisis del habla para la identificación de psicosis y otros trastornos (Cecchi & Corcoran, 2020)

El lenguaje es la principal fuente de información en psiquiatría y representa grandes volúmenes de datos a nivel del individuo. En este artículo se propone el procesamiento automático del lenguaje natural (PNL) para aplicar un examen del estado mental. Se describen métodos basados en datos para comprender la estructura de las alteraciones en el lenguaje, con un enfoque en el análisis del "procesamiento del lenguaje natural" (PNL) del habla transcrita. Se usa la esquizofrenia como ejemplo, ya que la estructura del lenguaje es anormal en la esquizofrenia, aunque sutilmente en las primeras etapas previas a la psicosis.

En este trabajo, el deterioro del lenguaje en la esquizofrenia se establece en el nivel de coherencia y cohesión semántica del discurso, que son el mantenimiento del flujo de significado y la consistencia de referencias a través de cláusulas y oraciones.

3.3.1. La conceptualización de Andreasen del trastorno del pensamiento positivo y negativo (E., et al., 1986)

Andreasen conceptualizó el "trastorno del pensamiento" en dos dominios: positivo y negativo. El trastorno del pensamiento positivo se expresa como la interrupción del flujo normal del discurso (tangencialidad, descarrilamiento y circunstancialidad) y puede ser capturado por la noción de coherencia. El trastorno del pensamiento negativo se expresa como el empobrecimiento estructural del discurso y puede describirse como una disminución de la complejidad (concreción, pobreza del habla). Si bien la "pobreza del habla" puede indexarse simplemente como la cantidad de habla, en términos más generales, la heurística del trastorno del pensamiento positivo y negativo puede corresponder a las medidas de coherencia y complejidad de la PNL, respectivamente, así como a las características derivadas del habla. En apoyo de esto, las calificaciones clínicas de TLC del trastorno del pensamiento se asocian con medidas de coherencia semántica de LSA en pacientes con esquizofrenia.

3.3.2. Análisis lingüísticos manuales en jóvenes en riesgo (Bearden, et al., 2011)

El análisis lingüístico manual de las narrativas de los adolescentes con alto riesgo clínico

(CHR) identificó características lingüísticas significativamente predictivas de la psicosis, incluidos los recuentos de contenido de pensamiento ilógico, pobreza de contenido, y errores en el uso de pronombres o comparativos para referirse a individuos u objetos mencionados anteriormente. El pensamiento ilógico, la pobreza de contenido y los errores en la cohesión referencial son características previamente descritas en la esquizofrenia por Andreasen, Hoffman y otros.

3.3.3. Análisis automático de PNL

Cada métrica identificada en el estudio lingüístico manual de Bearden es susceptible de procesamiento automatizado de PNL. En este trabajo se evalúa la cohesión referencial de las narrativas de los adolescentes con CHR utilizando la herramienta Coh-Metrix. Se identificó una cohesión referencial anormal en los pacientes con CHR, específicamente menos superposición en las raíces morfológicas en los escritos de los pacientes con CHR que en los sanos, asociada con la severidad de los síntomas sub-umbrales positivos y de desorganización, y puntuaciones más bajas de aprendizaje verbal. Coh-Metrix también fue utilizado para mostrar una disminución de la cohesión de manera más amplia en el primer episodio de psicosis, correlacionada con las calificaciones clínicas de desorganización.

3.4. Análisis del habla mediante técnicas de procesamiento del lenguaje natural: ¿una posible herramienta para la detección temprana del deterioro cognitivo? (Beltrami, et al., 2018)

Este trabajo tiene el objetivo de desarrollar biomarcadores tempranos y no invasivos para la identificación de la enfermedad de Alzheimer "preclínica" o "presintomática" y otras demencias. Estudios recientes han sugerido que las alteraciones del habla podrían ser uno de los primeros signos de deterioro cognitivo, que con frecuencia se nota años antes de que se hagan evidentes otros déficits cognitivos. Las pruebas de lenguaje neuropsicológico tradicionales proporcionan resultados ambiguos en este contexto. Por el contrario, el análisis de las producciones del lenguaje hablado mediante técnicas de PNL puede identificar modificaciones del lenguaje. En este artículo se usa el PNL para identificar los primeros signos lingüísticos de deterioro cognitivo en una población de personas mayores. El estudio

está conformado por 96 participantes (de 50 a 75 años): 48 en un grupo de control (GC) y 48 participantes con deterioro cognitivo, de los cuales 16 tenían amnesia (aMCI), 16 amnesia con dominios múltiples (mdMCI) y 16 con temprana demencia (eD). Se evaluó el habla espontánea en tres tareas (describir una imagen compleja, un día de trabajo típico y recordar su último sueño), se registró, transcribió y anotó en varios niveles lingüísticos. Las pruebas neuropsicológicas mostraron diferencias significativas entre el CG y mdMCI, y entre CG y de eD. para diferenciar entre mdMCI, eD y CG fue significativa una serie de características relacionadas con los aspectos léxicos, acústicos y sintácticos. Para este trabajo se utilizó Turin University Linguistic Environment (TULE), un sistema basado en reglas que incluye herramientas lingüísticas para general un texto etiquetado en italiano. Para hacer el análisis estadístico de los resultados se utilizaron las siguientes pruebas: *kruskal-wallis*, *mann-whitney u* y *Dunn's multiple comparison*.

Se concluye que las características lingüísticas del habla espontánea transcritas y analizadas mediante técnicas de PNL muestran diferencias significativas entre los CG y los estados patológicos y se recomienda que el análisis del habla se incluya como punto final exploratorio en los estudios de prevención de la EA.

3.5.Red neuronal convolucional superficial para el reconocimiento implícito de la relación del discurso (Zhang, et al., 2015).

En este trabajo se propone una Red Neuronal Convolutiva Superficial (Shallow Convolutional Neural Network) con una sola una capa oculta para el reconocimiento implícito de la relación del discurso. La estructura superficial alivia el problema de sobreajuste, mientras que las operaciones de convolución y las operaciones no lineales ayudan a preservar la capacidad de reconocimiento y generalización del modelo. Los experimentos con el conjunto de datos de referencia muestran que el modelo logra un rendimiento comparable e incluso mejor cuando se compara con los sistemas actuales de última generación.

Los métodos convencionales para el Reconocimiento de la relación del discurso (RRD) implícita se basan directamente en la ingeniería de características, en la que los investigadores generalmente explotan varias características hechas a mano, como palabras, etiquetas de parte del discurso y reglas de producción. Aunque estos métodos han demostrado

ser exitosos, estas funciones manuales requieren mucha mano de obra y son débiles para capturar aspectos intencionales, semánticos y sintácticos que rigen la coherencia del discurso (Li, et al., 2014), limitando así la efectividad de estos métodos. Recientemente, los modelos de aprendizaje profundo han logrado resultados notables en el procesamiento del lenguaje natural; sin embargo, hay poco trabajo de aprendizaje profundo específicamente para la RRD implícita. El descuido de este importante dominio puede deberse a las siguientes dos razones: (1) la distribución de las relaciones discursivas es bastante desequilibrada y la generalización de modelos profundos es relativamente insuficiente a pesar de su poderosa capacidad de estudio; (2) el conjunto de datos de entrenamiento en RRD implícito es relativamente pequeño, donde los problemas de sobreajuste se vuelven más prominentes.

Se realiza una evaluación de la RRD implícita en inglés en el corpus estilo PDTB². Los resultados experimentales muestran que el método propuesto puede obtener un rendimiento comparable, incluso mejor, cuando se compara con varias líneas de base. En este corpus las relaciones implícitas del discurso están anotadas con expresiones de conexión que mejor reflejan las relaciones implícitas entre dos argumentos vecinos. Por ejemplo:

- *Argumento1: (But) our competitions say we overbid them*
- *Argumento2: who cares*

En el ejemplo anterior el conectivo “but”, agregado manualmente, se usa para expresar una *comparación*. A partir de este corpus se entrenó un clasificador para el RRD implícita cuya arquitectura se muestra en la Figura 1.

² The Penn Discourse Treebank (PDTB) es un corpus a gran escala anotado con información relacionada con la estructura del discurso y la semántica del discurso.

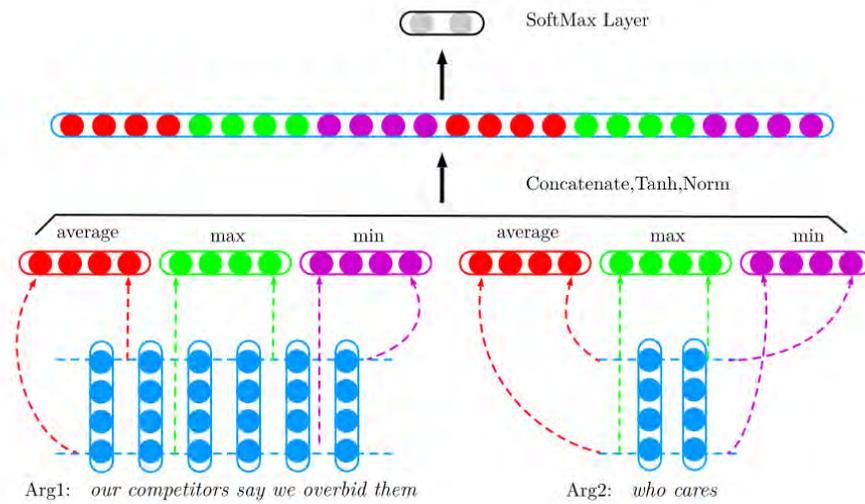


Figura 1 Arquitectura del modelo de Red Neuronal Convocucional Superficial visualizado con una instancia

Finalmente se evalúa el modelo contra el mismo pero sin normalización y contra cinco modelos más SVM, TSVM, RAE, Add-Bro, No-Cro, SCNN-No-Norm. Para ello se miden las siguientes relaciones lógicas: Temporal, Contingencia, Expansión, Comparación. Estas clases semánticas son descritas por (Pitler, et al., 2008) de la siguiente forma: Expansión cubre aquellas relaciones donde el segundo argumento expande el discurso del primer argumento o hace avanzar su narrativa. Las relaciones de Comparación resaltan diferencias prominentes entre los dos argumentos. La Contingencia se marca cuando una de las situaciones descritas en un argumento influye causalmente en el otro argumento. Las relaciones Temporales se marcan cuando las situaciones descritas en los argumentos se relacionan temporalmente, ya sea de forma sincrónica o secuencial.

Relación	Modelo	Precision	Recall	Accuracy	F1
COMP. vs Other	SVM	22.22	60.53	63.48	32.51
	TSVM	20.53	66.45	57.74	31.37
	Add-Bro	22.79	64.47	63.10	33.68
	No-Cro	22.89	67.76	62.14	34.22
	RAE	18.38	62.50	54.21	28.40
	SCNN-No-Norm	21.07	54.61	63.67	30.40
	SCNN	22.00	67.76	60.42	33.22
	SVM	39.70	67.03	64.05	49.87

CONT. vs Other	TSVM	38.72	67.03	62.91	49.08
	Add-Bro	39.14	72.40	62.62	50.82
	No-Cro	39.50	74.19	62.81	51.56
	RAE	37.55	68.10	61.28	48.41
	SCNN-No-Norm	39.02	71.33	62.62	50.44
	SCNN	39.80	75.29	63.00	52.04
EXP. vs Other	SVM	66.35	60.10	61.38	63.07
	TSVM	66.48	61.15	61.76	63.70
	Add-Bro	65.89	58.89	60.71	62.19
	No-Cro	66.73	61.15	61.95	63.82
	RAE	58.24	70.29	56.02	63.67
	SCNN-No-Norm	59.39	74.39	58.03	66.05
	SCNN	56.29	91.11	56.30	69.59
TEMP. vs Other	SVM	15.76	68.24	67.78	25.61
	TSVM	16.26	77.65	65.68	26.88
	Add-Bro	15.10	68.24	66.25	24.73
	No-Cro	13.89	64.71	64.53	22.87
	RAE	10.02	60.00	52.96	17.17
	SCNN-No-Norm	18.26	67.06	72.94	28.71
	SCNN	20.22	62.35	76.95	30.54

Tabla 1 Comparación de rendimiento con diferentes sistemas

Finalmente, se concluye que este modelo logra un rendimiento satisfactorio frente a los modelos de referencia.

3.6.Exploración de métodos neuronales para analizar estructuras de representación del discurso (Noord, et al., 2018)

El análisis semántico es la tarea de mapear una expresión de lenguaje natural con una representación interpretable de significado. Recientemente, los métodos neuronales, y en particular los modelos secuencia a secuencia (sequence-to-sequence), se han aplicado con éxito a una amplia gama de tareas de análisis semántico. Estas incluyen la generación de código, la respuesta a preguntas y el análisis sintáctico de la representación de significado abstracto. Dado que estos modelos no tienen un conocimiento intrínseco de la estructura (árboles, grafos, conjuntos) que deben producir, los trabajos recientes se han enfocado en métodos de decodificación estructurados, creando arquitecturas neuronales que siempre

generan un gráfico o un árbol. Estos métodos a menudo superan a los modelos de secuencia a secuencia más generales, pero se adaptan a representaciones de significado específicas.

Este artículo se centra en analizar las estructuras de representación del discurso (DRS, Discourse Representation Structures) propuestas en la teoría de la representación del discurso (DRT, Discourse Representation Theory), un formalismo bien estudiado desarrollado en semántica formal, que trata con muchos fenómenos semánticos: cuantificadores, negación, ambigüedades de alcance, pronombres, presuposiciones y estructura del discurso. Las DRS son estructuras recursivas y, por lo tanto, constituyen un desafío para los modelos secuencia a secuencia porque necesitan generar una estructura bien formada y no algo que se parezca a una pero que no sea interpretable.

Los objetivos de este artículo son aplicar métodos neuronales al análisis de las DRS y compararlos con otros modelos base (Tabla 2).

	Prec	Rec	F-score
SPAR	48.0	33.9	39.7
SIM-SPAR	55.6	57.9	56.8
AMR2DRS	43.3	43.0	43.2
Boxer	75.7	72.9	74.3
Neural Char	79.7	76.2	77.9
Neural Word	77.1	73.3	75.1
Neural Char + silver	84.7	82.4	83.6
Neural Word + silver	84.0	82.3	83.1

Tabla 2 Resultado de la prueba comparando el modelo neuronal contra dos modelos y dos analizadores base

Como se puede observar en la Tabla 2, se realizó la comparación de los modelos Neuronales desarrollados contra SPAR, SIM-SPAR, Boxer y AMR2DRS, modelos base en el área. La experimentación se hizo considerando el parseo a nivel carácter y palabra.

Se concluye que el modelo neuronal seq2seq implementado es capaz de producir DRS con alta precisión. Los modelos a nivel de carácter pueden superar a los modelos a nivel de palabra, aunque no dependen de la tokenización y las incrustaciones de palabras previamente entrenadas. Obtener y emplear datos adicionales también beneficiar el rendimiento, aunque podría ser mejor utilizar un analizador externo en lugar de realizar un trabajo de aprendizaje completo. El F score es sólo una medida aproximada de la precisión semántica.

3.7. Clasificación automatizada de marcadores discursivos (Robledo & Nazar, 2018)

Los llamados marcadores del discurso (MDs) corresponden a un amplio y heterogéneo conjunto de unidades lingüísticas (por ejemplo, *sin embargo, no obstante, es decir, claramente*, entre muchas otras) de uso habitual tanto en la escritura como en la oralidad. La categoría de unidades que funcionan como MDs está constituida por elementos que provienen de distintas categorías gramaticales, como conjunciones y locuciones conjuntivas, adverbios y locuciones adverbiales, interjecciones, preposiciones, expresiones performativas, sintagmas preposicionales, entre otras. Además, los MDs operan en distintos niveles: conectan oraciones, cumplen funciones en el texto y operan a nivel interpersonal.

En este trabajo se propone un método de clasificación de marcadores del discurso utilizando una técnica de clustering. El sistema está basado en el cálculo de la similitud estadística entre el marcador y las categorías; tiene enfoque cuantitativo, lo que permite la reproducción del experimento en otras lenguas. El sistema propuesto es un clasificador multicategoría que representa un primer acercamiento al estudio de la polifuncionalidad de los marcadores del discurso desde un enfoque empírico e inductivo. Se utiliza un corpus paralelo español-inglés de 1.1 mil millones de tokens para inducir automáticamente categorías de MDs según la similitud entre los elementos, sin recurrir a ningún tipo de anotación previa. El corpus utilizado está alineado a nivel de oración y la elección del inglés no es relevante, motivada solamente por la mayor disponibilidad de información (Robledo, et al., 2017).

A continuación se describe la metodología utilizada. En primer lugar se genera una matriz de asociación que representa los MDs. Lo que esta medida hace es oponer las veces en que aparecen juntos con las veces en que aparecen separados, y esto da la pauta del grado de asociación de los elementos.

Algorithm 2 Clasificación de MDs.

Require: (marcador castellano i ; taxonomía de marcadores T ; matriz binaria M ; umbral de similitud $u \approx 0,4$; hash table S)

- 1: **if** $i \notin M$ **then**
- 2: \vec{i} = vectorizar i
- 3: **end if**
- 4: **for each** $\vec{j} \in M$ **do**
- 5: **if** $i \neq j \wedge (Jaccard(\vec{i}, \vec{j}) > u)$ **then**
- 6: $S[T(j)] ++$
- 7: **end if**
- 8: **end for**
- 9: $T(i) = \arg \max (S)$

Figura 2 Pseudocódigo del clasificador de MDs.

Para evaluar el clasificador se utilizan las métricas de Precisión, Recall y F1 Score. Se concluye que, además de consecuencias teóricas, este trabajo tiene aplicaciones prácticas como la segmentación discursiva.

3.8. Un detector de la unidad central de un texto basado en técnicas de aprendizaje automático en textos científicos para el euskera (Bengoetxea, et al., 2017)

El euskera, vasco o vascuence es una lengua que se habla principalmente en Euskal Herria. El euskera es oficial junto al castellano en el País Vasco y en la zona vascófona de Navarra.

El objetivo de este artículo es la construcción de un detector automático de unidades centrales en textos científicos para el euskera con un clasificador del tipo Multivariate Bernoulli Naive Bayes. La detección del tema principal o unidad central (UC) es de gran ayuda en la anotación de la estructura retórica, ya que conocer de antemano cuál es la UC permite mejorar el ratio de acuerdo entre anotadores en la Rhetorical Structure Theory (RST). Teniendo en cuenta esos resultados, se piensa que un analizador discursivo automático podría ofrecer resultados más fiables si detectara la unidad central tras la segmentación discursiva automática.

La metodología utilizada consta de los siguientes puntos:

- Corpus. Se ha reutilizado el mismo corpus de Iruskieta et al. (2015) que consta de 100 resúmenes científicos en euskera segmentados y con las UCs anotadas manualmente.
- Indicadores. Se han utilizado los indicadores de Iruskieta et al. (2015).
- Optimización. Se ha elegido y optimizado el algoritmo de aprendizaje automático.

- Evaluación. Se ha evaluado el detector automático de UCs.

Para la evaluación se utilizaron las medidas se han utilizado las medidas habituales: Recall, Precisión, y los valores de ambas métricas combinadas en una media armónica denominada valor-F (F-score o F1)

Como los algoritmos ingenuos de Bayes sufren con las características redundantes o correlacionadas, después de seleccionar el algoritmo de aprendizaje con todas las características de entrada, hemos aplicado un wrapper que permite seleccionar el mejor subconjunto de características para el clasificador seleccionado.

En la Tabla 3 se pueden ver los resultados obtenidos con el clasificador Bernoulli Naive Bayes utilizando todas las características (ML); los resultados obtenidos después de emplear el wrapper (ML + Wrap), y aplicando el mejor subconjunto de características obtenido; y se presentan los resultados después de aplicar el post-proceso estadístico (ML + Wrap + Post.), obteniendo los mejores resultados en F-score de 0,54 con 10-fold cross-validation y 0,57 con los datos de validación.

Sistema	Datos	Prec.	Rec.	F1
ML	Dev	0,47	0,48	0,48
	Test	0,46	0,54	0,50
ML+Wrap	Dev	0,58	0,46	0,51
	Test	0,46	0,59	0,51
ML+Wrap+Post	Dev	0,56	0,53	0,54
	Test	0,48	0,70	0,57

Tabla 3 Tabla de resultados

3.9.Un método de análisis de dos etapas para el análisis del discurso a nivel de texto (Yizhong Wang, 2017)

En este trabajo se utiliza la Teoría de la Estructura Retórica (TER), que propone el análisis de un texto en un árbol de discurso jerárquico, donde las hojas corresponden a Unidades de Discurso Elementales (UDE, generalmente cláusulas) y están conectados recursivamente por relaciones retóricas. Se diseñó un método de análisis sintáctico de dos etapas para generar un árbol TER a partir de texto: la construcción de la estructura de árbol y el etiquetado de

relaciones.

La primera etapa consiste en un sistema basado en transiciones que construye el árbol sin etiquetas de relación. Se diseñaron cuatro tipos de acciones, que incluyen: Shift, Reduce-NN, Reduce-NS, Reduce-SN.

En la segunda etapa, se determinan de forma independiente las etiquetas de relación para cada tramo. Se entrenan a tres clasificadores separados (Máquinas de Soporte Vectorial) para etiquetar relaciones en tres niveles: dentro de la oración, a través de la oración y a través de los párrafos. Primero se recorre el árbol en orden posterior, en seguida, para cada nodo interno, se determina si sus subárboles izquierdo y derecho están en párrafos diferentes, o en el mismo párrafo, o en la misma oración.

Para el clasificador, las características se extraen de los 2 elementos superiores S_1 , S_2 en la pila y la primera UDE Q_1 en la cola. Las características usadas en este trabajo son:

- Funciones de estado: la acción anterior; número de elementos en la pila y cola.
- Características de la posición: si S_1 , S_2 o S_1 , Q_1 están en la misma oración o párrafo; si son el comienzo o el final de una oración, párrafo o documento; distancia desde S_1 , S_2 , Q_1 hasta el inicio y el final del documento.
- Características estructurales: tipo de nuclearidad (NN, NS o SN) de S_1 , S_2 ; número de UDE y oraciones en S_1 , S_2 ; comparación de longitud de S_1 , S_2 con respecto a las UDE y las oraciones.
- Características de dependencia: si existen relaciones de dependencia entre S_1 , S_2 o entre S_1 , Q_1 ; la dirección de dependencia y el tipo de relación.
- Funciones de N-grama: la primera y la última n palabras y sus etiquetas POS en el texto de S_1 , S_2 , Q_1 , donde $n \in \{1, 2\}$.
- Características del núcleo: los jefes de dependencia de las UDE₂ del núcleo para S_1 , S_2 , Q_1 y sus etiquetas POS; grupos marrones de todas las palabras en las UDE básicas de S_1 , S_2 , Q_1 .

Dado un nodo interno P en el árbol, se predice la relación entre su hijo izquierdo C_{left} y el hijo derecho C_{right} , agregando las siguientes características:

- Características estructurales refinadas: tipo de nuclearidad del nodo P ; distancia desde P , C_{left} , C_{right} al comienzo y al final del documento/párrafo/oración con respecto a párrafos/oraciones/UDE; número de párrafos/oraciones/UDE en C_{left} y C_{right} ;

comparación de longitud de C_{left} y C_{right} con respecto a párrafos/oraciones/UDE.

- Características del árbol: profundidad y altura del nodo P en el árbol; tipo de nuclearidad del nodo abuelo de P y P, si existen.

3.10. El procesamiento en lenguaje natural de las notas clínicas de salud mental puede agregar valor predictivo a los modelos de riesgo de suicidio existentes (Maxwell Levis, 2020)

En este artículo se describe un experimento en el que se utilizan las notas clínicas para buscar indicadores que puedan ayudar a modelos de riesgo de suicidio ya existentes. En el experimento se trabajó con dos grupos diagnosticados con Trastorno de estrés postraumático entre 2013 y 2014: el primero conformado por aquellos que cometieron suicidio y aquellos que permanecieron vivos hasta un año después del diagnóstico. Para ambos grupos se reunieron las notas de los psicoterapeutas. Se analizaron las notas utilizando Sentiment Analysis and Cognition Engine (SEANCE), una herramienta de Python que, a diferencia de LIWC, es de código abierto. Esta herramienta es capaz de analizar las siguientes variables: Acción, Excitación; Artes y academia; Cognición; Comunicación; Dominio, respeto, dinero y poder; Economía, política y religión; Esfuerzo; Evaluación; Sentimiento / emoción; Palabras de emoción negativa; Físico; Palabras de emoción positiva; Calidad y cantidad; Referencia; Relaciones sociales; Sorpresa; Tiempo y espacio; Valencia/polaridad. Todas estas variables son comparadas en el experimento utilizando la métrica AUC. Los datos se analizaron utilizando el modelo estadístico LASSO que controlaba el número variables de sesiones de psicoterapia. LASSO es un algoritmo de aprendizaje automático que reduce los errores de predicción asociados con frecuencia con la selección por pasos.

Se concluye que la PNL es un método novedoso para medir el riesgo de suicidio a lo largo del tiempo y categorizar potencialmente los subgrupos de pacientes con distintas sensibilidades al riesgo.

3.11. Uso del procesamiento del lenguaje natural para identificar síntomas obsesivo-compulsivos en pacientes con esquizofrenia, trastorno esquizoafectivo o trastorno bipolar (Chandran, et al., 2019)

Los síntomas obsesivos y compulsivos (SOC) o el trastorno obsesivo compulsivo (OCD) en

el contexto de la esquizofrenia o trastornos relacionados son de importancia clínica, ya que se asocian con una variedad de resultados adversos. PLN aplicado a los Registros de Salud Electrónicos (RSE) presenta una oportunidad para crear grandes conjuntos de datos para facilitar la investigación en esta área. En este trabajo se desarrolla un algoritmo de PLN para extraer información de SOC de un recurso de datos de RSE de salud mental. Se extrajeron documentos de personas que habían recibido un diagnóstico de esquizofrenia, trastorno esquizoafectivo o trastorno bipolar. Estos documentos de texto, anotados por codificadores humanos, se utilizaron para desarrollar y perfeccionar el algoritmo de PNL (600 documentos) con un conjunto adicional reservado para la validación final (300 documentos). El algoritmo de PNL desarrollado utilizó un enfoque basado en reglas para identificar cada uno de los síntomas asociados con SOC, y luego los combinó para determinar el número total de instancias de SOC. Después de su implementación, se demostró que el algoritmo identifica SOC con una precisión y recuperación (con intervalos de confianza del 95%) de 0,77 (0,65 a 0,86) y 0,67 (0,55 a 0,77) respectivamente. El desarrollo de esta aplicación demostró el potencial de extraer datos sintomáticos complejos de los RSE de salud mental utilizando PLN para facilitar análisis adicionales de estos síntomas clínicos y su relevancia para el pronóstico y la respuesta a la intervención.

3.12. Descripción general de la tarea de detección de cambios de estilo en PAN³ 2020 (Zangerle, et al., 2020)

La detección de cambios de estilo se basa en análisis estilométricos intrínsecos de los documentos, sin hacer referencia a documentos externos o corpus para la comparación, haciendo perfiles estilísticos que se basan en características léxicas como n-gramas de caracteres, frecuencias de palabras y longitudes promedio de palabras/oraciones, características sintácticas como frecuencias/estructuras de etiquetas de parte de la oración y características estructurales como el uso de sangría.

En la tarea de detección de cambios de estilo en el evento PAN de 2020, se pidió a los participantes que respondieran las siguientes preguntas para un documento determinado:

³ PAN es una serie de eventos científicos y tareas compartidas sobre estilometría y textos digitales.

1. ¿Fue escrito por varios autores?
2. Para cada par de párrafos consecutivos, ¿hay un cambio de estilo entre estos párrafos?

Para este trabajo se exponen los dos enfoques que lograron un mejor desempeño al realizar la tarea.

3.12.1. Representación de características de estilo mixto y agrupación en clústeres

Este enfoque hace uso de una variante de agrupamiento máximo B0 para resolver la tarea de detección de cambios de estilo (Castro-Castro, et al., 2020). Primero, se formula una representación para un párrafo como un conjunto de 185 características estilométricas, que consisten en características basadas en caracteres, léxicos y sintácticos, pero excluyen características que capturan explícitamente la semántica del texto dado. Las características se dividen en tres categorías diferentes: características booleanas, características que consisten en un solo número de punto flotante y características que consisten en vectores de números. Para cada una de estas categorías, se define un criterio de comparación que expresa si una característica dada de dos párrafos diferentes es “similar” o no. La similitud entre dos párrafos se define como el número de características similares entre ellos. En base a esto, se realiza la agrupación donde cada grupo se considera un autor.

3.12.2. Detección del cambio de estilo usando BERT

Este enfoque se basa en el uso del modelo BERT de Google como extractor de características y bosques aleatorios como clasificador. Primero, los documentos contenidos en el conjunto de datos se dividen en oraciones, y cada oración se envía a BERT, tomando los resultados de las últimas cuatro capas de BERT para representar una oración. Dado que el tamaño de la matriz de características producida por esto depende del número de tokens en una oración, los valores a lo largo de la dimensión de longitud se suman para obtener una matriz de características de una longitud fija. Se formulan representaciones para pares consecutivos de párrafos (para resolver la segunda tarea), y el documento completo (para resolver la primera tarea), a partir de las representaciones de oraciones, sumando (párrafos) o promediando (documentos completos) los valores característicos de las oraciones que componen el párrafo o documento. Estas representaciones se utilizan para entrenar modelos de bosque aleatorios

para ambas tareas.

3.12.3. Conclusión

Se concluye que el enfoque usando BERT y bosques aleatorios ofrecen el mejor desempeño. Esto se ilustra en la Figura 3, donde se utiliza la métrica F1 Score como referente.

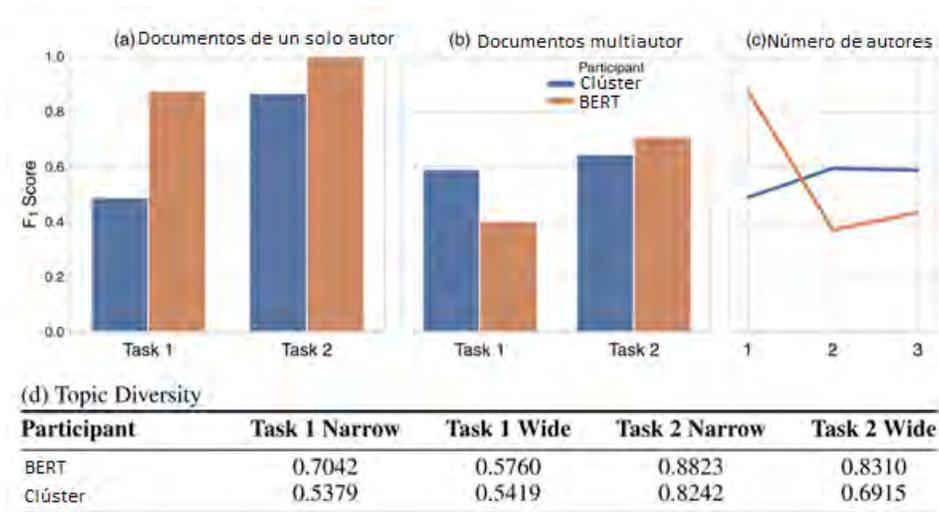


Figura 3 Comparación en las tareas (a) documentos de un solo autor, (b) documentos de múltiples autores, y (c) número de autores por documento. (d) La tabla muestra los puntajes F1 obtenidos en función de la diversidad de temas.

3.13. Análisis de la caracterización discursiva de los relatos migratorios en Twitter. El caso Aquarius. (Fernández, et al., 2020)

El objetivo de este artículo es analizar las representaciones construidas en Twitter alrededor de la migración a partir del estudio del caso Aquarius. Para ello, se monitorizaron cerca de dos millones de tuits relacionados con el término Aquarius y se analizó la influencia de Twitter en la creación y viralización de noticias falsas y la presencia de estrategias discursivas que favorecen el discurso del odio

La recolección de los twitts que fueron usados como corpus se realizó mediante la API de Twitter, realizando un proceso de filtrado entre twitts duplicados. El proceso seguido en este trabajo, así como las herramientas utilizadas, se muestran en la Figura 4.



Figura 4 Método de solución para la caracterización discursiva de los relatos migratorios en Twitter

3.14. ¿Hablamos? Análisis del discurso y estrategias empleadas en WhatsApp por estudiantes universitarios (García, 2020)

Este artículo tiene como objetivo detectar los hábitos, estrategias y características lingüísticas utilizados en el sistema comunicativo de WhatsApp por estudiantes de la Universidad de Granada (España). Los criterios de selección del corpus fueron temporales (entre treinta y sesenta minutos de duración y escritos en un plazo no superior a un mes), formales (con un mínimo de tres dialogantes de entre 19-25 años del mismo sexo, cuyo principal conversador fuera el propio sujeto participante pero sin identificación de los nombres de los interlocutores) y de contenido (diversidad temática y con eventual presencia de emojis, imágenes o cualquier otro recurso icónico, así como de saludos y despedidas), consiguiendo una muestra de 342 conversaciones (198 de mujeres y 144 de hombres).

Para realizar el análisis se utilizó el Parametrizador Morfológico de Textos (ParamText TIP) de Carreras-Riudavets y otros (2011), con el que se indaga en el contenido morfológico, léxico y discursivo de la muestra.

Finalmente en los resultados se obtuvo la frecuencia de categorías gramaticales utilizadas por cada sexo, como se observa en la Figura 5.

	HOMBRES	MUJERES
Sustantivos	1272	6456
Verbos	670	3737
Adjetivos	441	2077
Adverbios	332	2199
Pronombres	443	2794
Preposiciones	313	1381
Artículos	194	1047
Conjunciones	323	1952
No reconocidas	77	516

Figura 5 Categorías gramaticales por sexo

3.15. Adaptación de BERT a la clasificación de relaciones implícitas del discurso con un enfoque en los conectivos del discurso (Kishimoto, et al., 2020)

BERT es una arquitectura de red neuronal basada en transformadores con procedimientos de formación especializados. Se pre-entrena con grandes corpus como Wikipedia y BooksCorpus, y se afina utilizando conjuntos de datos específicos de tareas para transferir las representaciones pre-entrenadas a tareas posteriores. Aunque BERT es conceptualmente simple, supera significativamente a los modelos de vanguardia anteriores en muchas tareas de procesamiento del lenguaje natural, como comprensión de lectura, análisis sintáctico y análisis de sentimientos.

En este trabajo se examinan tres métodos de adaptación para BERT.

- 1) Explotar datos sin etiquetar del mismo texto de dominio. Se realiza un entrenamiento previo adicional en el texto del dominio. Se recopilan pares de argumentos de un corpus sin etiquetar y se utilizan para hacer un pre-entrenamiento adicional de BERT.
- 2) Los pares de argumentos explícitos tienen conectivos del discurso. Se entrena el modelo para predecir las conexiones explícitas. Se agrega esta tarea junto con las tareas habituales de pre-entrenamiento de BERT.
- 3) Consiste en explotar las conectivas implícitas. Se inserta una conectiva implícita entre un par de argumentos implícitos para facilitar una anotación coherente. Se entrena BERT para predecir la relación implícita tanto conectiva como discursiva.

Finalmente se compara el desempeño de este trabajo con otros modelos en el estado del arte.

Concluyendo que BERT logró una puntuación F1 superior al 70%, mientras que muchos modelos anteriores lograron menos del 50%. Se recomienda a los investigadores que cambien de la clasificación One-Versus-All Binary a tareas de clasificación de segundo o tercer nivel. Se recomienda la combinación de la tarea de predicción de conectivos explícitos en el pre-entrenamiento.

3.16. DisSent: Aprendiendo las representaciones de oraciones a partir de relaciones discursivas explícitas (Nie, et al., 2019)

Se propone aprovechar una relación de alto nivel entre oraciones que está marcado frecuente y sistemáticamente en el lenguaje natural: las relaciones de discurso entre oraciones. Los escritores humanos naturalmente usan un pequeño conjunto de palabras de transición muy comunes entre oraciones (o frases parecidas a oraciones) para identificar las relaciones entre ideas adyacentes. Estas son palabras como *porque*, *pero*, *y*, ampliamente estudiadas en lingüística; en este trabajo se usa el nombre de “marcadores de discurso”.

Los marcadores del discurso anotan relaciones conceptuales profundas entre oraciones. Aquí se propone DisSent, que utiliza la tarea de predicción del discurso para entrenar los embeddings. Mediante un procedimiento de preprocesamiento de datos basado en el análisis de dependencias, se selecciona un conjunto de entrenamiento considerable de pares de oraciones. Luego, se entrena un modelo de codificación de oraciones para aprender los embeddings para cada oración en un par, de modo que un clasificador pueda identificar qué marcador de discurso se usó para vincular las oraciones. Finalmente se usa la tarea DisSent para ajustar el modelo BERT, previamente entrenado.

Para los conjuntos de datos de entrenamiento y evaluación se utilizaron pares de oraciones de BookCorpus y texto de novelas inéditas (géneros: romance, fantasía, ciencia ficción y adolescentes). En este trabajo se usa la dependencia Stanford CoreNLP como analizador de los marcadores del discurso. Los marcadores obtenidos para diferentes tamaños de corpus se muestran en la Figura 6.

Label	Discourse Markers
Books 5	<i>and, but, because, if, when</i>
Books 8	<i>and, but, because, if, when, before, though, so</i>
Books ALL	<i>and, but, because, if, when, before, though, so, as, while, after, still, also, then, although</i>

Figura 6 Marcadores del discurso para diferentes corpus. Books ALL contiene 4.7 millones de pares de oraciones, Books 8 contiene 3.6 millones y Books 5 contiene 3.2 millones

Se consideran, además, dos patrones en que pueden presentarse los marcadores del discurso (Figura 7).

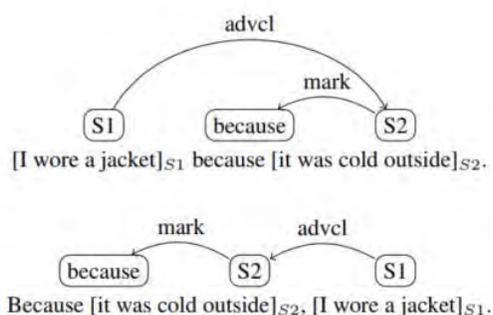


Figura 7 Patrones de dependencia para la extracción

Finalmente se compara el modelo con otros en el Estado del Arte, concluyendo que la propuesta consigue un rendimiento comparable a ellos.

3.17. Desenmascarando la conversación sobre cubrebocas: procesamiento del lenguaje natural para el análisis de sentimientos en los discursos de COVID-19 en Twitter (Sanders, et al., 2021)

En este estudio se analiza una base de datos de más de un millón de tweets recopilados de marzo a julio de 2020 que ilustra la postura del público hacia el uso de cubrebocas durante la pandemia de COVID-19. Se emplean técnicas de procesamiento de lenguaje natural, agrupamiento y análisis de sentimientos para organizar los tweets relacionados con el uso de cubrebocas. Como técnicas de PLN se utilizan los métodos de LDA18 y TF-IDF. También se utiliza BART (concretamente DistilBART) para extraer resúmenes temáticos en cinco

categorías. Como algoritmo de agrupación se usa k-means.

Se concluye que la agrupación temática y basada en datos de Twitter pueden ofrecer conocimientos distintos sobre las percepciones sociales de COVID-19.

3.18. El impacto del discurso científico en Twitter (Denia, 2020)

En este trabajo se toma como corpus de estudio textos provenientes de la red social Twitter. En las pruebas se analiza el discurso de un divulgador de Ciencias. El impacto de la información se calcula en términos de: likes y retweets; medidas sugeridas para la popularidad y el grado de contenido polémico; y la red semántica. Se identifican y clasifican los elementos relevantes del discurso por categorías (ciencia, cultura, político-social, creencias, medios y emocional). Los resultados revelan que una transmisión con carga emocional en el mensaje despierta una respuesta sustancialmente más profunda en el público.

Se desarrolló un algoritmo en Swift que extrae las estadísticas de palabras ponderando la frecuencia de aparición por un factor de popularidad (cantidad de favoritos), polemicidad (si fue retweeteada), se genera una lista de palabras, se asocian a un tema y se muestra un gráfico de red semántica. Finalmente, un humano es quien categoriza las palabras respecto a los temas elegidos.

Herramienta	Tarea
Algoritmo en swift	Estadísticas de los términos Lista de palabras Asociaciones de palabras Visualización de la red semántica
Codificador humano	Categorización de palabras

Tabla 4 Resumen de la herramienta

3.19. Mecanismos lingüísticos de coherencia en el discurso afásico y no afásico (Levis, et al., 2020)

En este trabajo se presenta una investigación cualitativa y manual sobre la coherencia en el discurso de hablantes nativos de ruso con y sin afasia. Se examina la conexión entre las alteraciones del lenguaje en la afasia y diferentes aspectos de la coherencia del discurso con el fin de determinar los mecanismos lingüísticos que podrían estar involucrados en su

establecimiento y mantenimiento. La coherencia se puso en práctica como una combinación de cuatro aspectos: informatividad, claridad, conexión y comprensibilidad. Se pidió a veinte participantes que volvieran a contar el contenido de un cortometraje. Los recuentos fueron anotados utilizando la Teoría de la Estructura Retórica (RST), un marco formalista para el análisis de la estructura del discurso. Se concluye que los relatos producidos por hablantes con afasia recibieron calificaciones más bajas que las de los participantes de control en todos los aspectos de la coherencia. Los resultados indican que diferentes combinaciones de variables microlingüísticas y de estructura del discurso juegan un papel en el establecimiento de cada uno de los aspectos de coherencia.

3.20. Discurso y sentimiento públicos durante la pandemia de COVID 19: uso de la Latent Dirichlet allocation para modelar temas en Twitter (XueI, et al., 2020)

Este estudio utiliza datos recopilados de Twitter (1,930,000 tweets) para agregar conocimiento a la comprensión de la pandemia. Se utiliza un enfoque de aprendizaje automático con el objetivo de explorar el discurso público y las reacciones psicológicas durante la etapa inicial de COVID-19. Se examinan: los temas latentes relacionados con el COVID-19, la reacción emocional de los usuarios de Twitter ante la pandemia y cómo cambian los sentimientos con el tiempo.

En la etapa de preprocesamiento se realizan los siguientes pasos:

- Eliminación del símbolo de hashtag y su contenido.
- Eliminación todos los caracteres no ingleses.
- Eliminación de las palabras repetidas
- Eliminación los caracteres especiales, los signos de puntuación y los números.

Para la extracción de temas se utiliza Latent Dirichlet allocation (LDA) y un enfoque de aprendizaje automático no supervisado (no se especifica el modelo usado). Algunos de los bigramas obtenidos en este trabajo se muestran en Tabla 5.

Tema	Bigrama por tema
Actualizaciones acerca del número de casos de COVID-19	Confirmed cases, total confirmed, cases reported, total number, number confirmed, new confirmed

	Tested positive, cases confirmed, new case, positive case
Muerte relacionada con el COVID-19	New deaths, total deaths
	Death rate, mortality rate, fatality rate, coronavirus spread
	People die

Tabla 5 Identificación de bigramas por tema

3.21. **Senicidio moderno frente a una pandemia: un examen del discurso público y el sentimiento sobre los adultos mayores y el COVID-19 mediante el aprendizaje automático (Xiang, et al., 2020)**

Senicidio es el asesinato de personas mayores o su abandono a la muerte. En este estudio se examina el discurso público y los sentimientos respecto a los adultos mayores y COVID-19 en las redes sociales. Se analizaron datos de Twitter (82,893 tweets) relacionados tanto con adultos mayores como con COVID-19 y fechados del 23 de enero al 20 de mayo de 2020. Se utilizan métodos de ciencia de datos:

- TF-IDF: para la conversión numérica de las palabras.
- Aprendizaje automático supervisado: Regresión logística, Linear Support Vector Classifier (SVC) y Random Forest. Utilizando como métrica de referencia Accuracy.
- Modelado de temas usando el modelo LDA
- Análisis de sentimientos: léxico afectivo NRC

Finalmente se extrajeron las palabras más representativas, 14 temas, como las percepciones de encierro y riesgo. Una prueba de causalidad bivariada de Granger sugirió que los tweets informativos sobre poblaciones en riesgo aumentaron la prevalencia de tweets que restaron importancia a la pandemia.

3.22. **¿La resiliencia media la asociación entre los síntomas de salud mental y los marcadores lingüísticos del procesamiento del trauma? Analizando las narrativas de mujeres sobrevivientes de violencia de pareja (Castiglioni, et al., 2023)**

En este artículo se estudia el caso de textos escritos por mujeres recluidas en servicios para

mujeres víctimas de abuso en el norte y centro de Italia. En él se explora la relación entre el trastorno de estrés postraumático y el uso del lenguaje, centrándose particularmente en los patrones lingüísticos como indicadores de estados psicológicos y cambios después de un trauma.

El estudio identifica características lingüísticas comúnmente asociadas con el trastorno de estrés postraumático, como un mayor uso de palabras con emociones negativas, una mayor frecuencia de pronombres en primera persona del singular y una menor complejidad en la estructura de la oración. También señala cómo las intervenciones terapéuticas influyen en el uso del lenguaje entre los pacientes con trastorno de estrés postraumático. En sus resultados señala que el trastorno de estrés postraumático se correlacionó positivamente con una perspectiva auto-inmersa, una sensación de amenaza de muerte, y formas verbales en tiempo pasado, pero se correlacionó negativamente con el procesamiento cognitivo, emociones positivas y formas verbales en tiempo presente y futuro.

3.23. Tabla comparativa de los trabajos relacionados

En este apartado se muestra una comparativa de las herramientas y resultados obtenidos en la literatura revisada para el desarrollo de este trabajo de investigación.

Trabajo	Objetivo	Herramientas	Resultados	Año
Linguistic Inquiry and Word Count (LIWC) (Pennebaker, et al., 2015)	Este trabajo busca identificar patrones lingüísticos que reflejen emociones, autoreferencias y otros aspectos psicológicos.	Linguistic Inquiry and Word Count (LIWC)	Variabes cualitativas como el pensamiento analítico, la influencia, la autenticidad, el tono emocional, dimensiones estándar como pronombres, verbos, etc., y categorías psicológicas como el afecto.	2015
Coh-Metrix (McNamara, et al., 2017; Graesser, et al., 2004)	En este trabajo se habla del desarrollo del sistema Coh-Metrix, que es un sistema que analiza varias características de los textos, haciendo especial énfasis en la coherencia.	Coh-Metrix	Coh-Metrix es un sistema que da resultados detallados en varias dimensiones del lenguaje, incluyendo: Medidas de Coherencia y Cohesión.	2017
Uso del procesamiento del lenguaje y el análisis del habla para la identificación de psicosis y otros trastornos (Cecchi & Corcoran, 2020)	Se usaron técnicas automatizadas para analizar el habla transcrita y evaluar alteraciones en la estructura del lenguaje.	LSA, Coh-Metrix	Se identificaron deterioros en la coherencia y cohesión semántica del discurso en pacientes con esquizofrenia.	2020
Análisis del habla mediante técnicas de procesamiento del lenguaje natural: ¿una posible herramienta para la detección temprana del deterioro cognitivo? (Beltrami, et al., 2018)	El objetivo de este trabajo fue desarrollar biomarcadores tempranos y no invasivos para la identificación de la enfermedad de Alzheimer en etapas tempranas.	Turin University Linguistic Environment (TULE)	Las pruebas mostraron diferencias significativas entre el grupo de control y los pacientes con deterioro cognitivo.	2018

Tabla 6 Comparativa de trabajos relacionados, parte 1

Trabajo	Objetivo	Herramientas	Resultados	Año
Red neuronal convolucional superficial para el reconocimiento implícito de la relación del discurso (Zhang, et al., 2015).	El objetivo fue desarrollar una Red Neuronal Convolucional Superficial para el reconocimiento implícito de relaciones del discurso.	Red Neuronal Convolucional Superficial	El modelo SCNN propuesto logra un rendimiento comparable e incluso superior a los sistemas de última generación para el reconocimiento implícito de relaciones del discurso.	2015
Exploración de métodos neuronales para analizar estructuras de representación del discurso (Noord, et al., 2018)	El enfoque se centra en comparar métodos neuronales propuestos con modelos tradicionales y evaluar su eficacia en generar estructuras de representación del discurso.	Modelos Secuencia a Secuencia (Seq2Seq), DRS (Discourse Representation Structures)	Se concluyó que el modelo neuronal seq2seq implementado es capaz de producir DRS con alta precisión.	2018
Clasificación automatizada de marcadores discursivos (Robledo & Nazar, 2018)	En este trabajo se propone un método de clasificación de marcadores del discurso utilizando una técnica de clustering.	Matriz de asociación que representa marcadores discursivos.	Este trabajo tiene aplicaciones prácticas como la segmentación discursiva.	2018
Un detector de la unidad central de un texto basado en técnicas de aprendizaje automático en textos científicos para el euskera (Bengoetxea, et al., 2017)	En este trabajo se propuso construir un detector automático de unidades centrales (UC) en textos científicos escritos en euskera.	Multivariate Bernoulli Naive Bayes	La metodología aplicada demuestra que es posible construir un detector automático efectivo para el euskera.	2017

Tabla 7 Comparativa de trabajos relacionados, parte 2

Trabajo	Objetivo	Herramientas	Resultados	Año
Un método de análisis de dos etapas para el análisis del discurso a nivel de texto (Yizhong Wang, 2017)	Diseñar un método de análisis sintáctico de dos etapas para generar un árbol que utiliza la Teoría de la Estructura Retórica para analizar Unidades de Discurso Elementales.	Árbol de discurso jerárquico, Máquina de soporte vectorial (SVM)	El modelado de unidades del discurso logra un resultado similar a otros modelos en el estado del arte.	2017
El procesamiento en lenguaje natural de las notas clínicas de salud mental puede agregar valor predictivo a los modelos de riesgo de suicidio existentes (Levis, et al., 2020)	Encontrar en notas clínicas indicadores que puedan ayudar a modelos de riesgo de suicidio ya existentes.	LASSO, LIWC y SEANCE	Se concluye que la PNL es un método novedoso para medir el riesgo de suicidio a lo largo del tiempo.	2020
Uso del procesamiento del lenguaje natural para identificar síntomas obsesivo-compulsivos en pacientes con esquizofrenia, trastorno esquizoafectivo o trastorno bipolar (Chandran, et al., 2019)	. En este trabajo se desarrolla un algoritmo de PLN para extraer información de SOC de un recurso de datos de RSE de salud mental.	Algoritmo basado en reglas,	Se demostró el potencial de extraer datos sintomáticos complejos de los RSE de salud mental utilizando PLN.	2019
Descripción general de la tarea de detección de cambios de estilo en PAN4 2020 (Zangerle, et al., 2020)	Resolver la tarea de detección de cambios de estilo en textos para determinar si el texto fue escrito por varios autores o no.	BERT, Bosques aleatorios y clustering.	BERT y bosques aleatorios ofrecen el mejor desempeño para esta tarea sobre el Clustering.	2020

Tabla 8 Comparativa de trabajos relacionados, parte 3

⁴ PAN es una serie de eventos científicos y tareas compartidas sobre estilometría y textos digitales.

Trabajo	Objetivo	Herramientas	Resultados	Año
Análisis de la caracterización discursiva de los relatos migratorios en Twitter. El caso Aquarius. (Fernández, et al., 2020)	Analizar las representaciones construidas en Twitter alrededor de la migración a partir del estudio del caso Aquarius.	Vader Sentiment, Natural Language Toolkit	Se demuestra mediante el análisis de sentimientos que la mayor parte de los tuits publicados no plantean un sentimiento ni positivo ni negativo, sin embargo, los usuarios suelen anteponer ideas religiosas y políticas a la información factual.	2020
¿Hablamos? Análisis del discurso y estrategias empleadas en WhatsApp por estudiantes universitarios (García, 2020)	Detectar los hábitos, estrategias y características lingüísticas utilizados en el sistema comunicativo de WhatsApp por estudiantes de la Universidad de Granada.	Parametrizador Morfológico de Textos (ParamText TIP)	En los resultados se obtuvo la frecuencia de categorías gramaticales utilizadas por cada sexo.	2020
Adaptación de BERT a la clasificación de relaciones implícitas del discurso con un enfoque en los conectivos del discurso (Kishimoto, et al., 2020)	Examinar tres métodos de adaptación para el modelo BERT, explotando datos sin etiquetar, creando pares de argumentos explícitos y explotando las conectivas implícitas.	BERT	Se concluye que BERT logró una puntuación F1 superior al 70%, mientras que muchos modelos anteriores lograron menos del 50%.	2020
DisSent: Aprendiendo las representaciones de oraciones a partir de relaciones discursivas explícitas (Nie, et al., 2019)	Se propone estudiar la relación entre oraciones y el discurso mediante la identificación de relaciones adyacentes por medio de los marcadores del discurso.	DiSent	Finalmente se compara el modelo con otros en el Estado del Arte, concluyendo que la propuesta consigue un rendimiento comparable a ellos.	2019

Tabla 9 Comparativa de trabajos relacionados, parte 4

Trabajo	Objetivo	Herramientas	Resultados	Año
Desenmascarando la conversación sobre cubrebocas: procesamiento del lenguaje natural para el análisis de sentimientos en los discursos de COVID-19 en Twitter (Sanders, et al., 2021)	Analizar una base de datos de más de un millón de tweets que ilustra la postura del público hacia el uso de cubrebocas durante la pandemia de COVID-19.	DistilBART, K-means, Dirichlet Latente (LDA), TF-IDF	La agrupación temática y basada en datos de Twitter pueden ofrecer conocimientos distintos sobre las percepciones sociales de COVID-19.	2021
El impacto del discurso científico en Twitter (Denia, 2020)	Identificar y clasificar el impacto social que tiene el discurso científico en la red de Twitter a través de su categoría (ciencia, cultura, político-social, creencias, medios y emocional) y popularidad (likes y retweets).	Algoritmo en Swift, notación manual	Se concluye que ligar la información científica con cuestiones sociopolíticas o transmitirla de forma emocional puede ayudar a promover la divulgación científica, ya que palabras asociadas a este rasgo resultaron ser más populares.	2020
Mecanismos lingüísticos de coherencia en el discurso afásico y no afásico (Levis, et al., 2020)	Realizar una investigación cualitativa y manual sobre la coherencia en el discurso de hablantes nativos de ruso con y sin afasia.	Teoría de la Estructura Retórica (RST)	Se concluye que diferentes combinaciones de variables microlingüísticas y de estructura del discurso juegan un papel en el establecimiento de cada uno de los aspectos de coherencia.	2020
Discurso y sentimiento públicos durante la pandemia de COVID 19: uso de la Latent Dirichlet allocation para modelar temas en Twitter (XueI, et al., 2020)	El objetivo de este trabajo es obtener información respecto a los usuarios de Twitter para ayudar a comprender la pandemia de COVID-19.	Latent Dirichlet allocation (LDA)	Se obtienen bigramas por temas agrupados en información de COVID-19 y muertes oír COVID.	2020

Tabla 10 Comparativa de trabajos relacionados, parte 5

Trabajo	Objetivo	Herramientas	Resultados	Año
Senicidio moderno frente a una pandemia: un examen del discurso público y el sentimiento sobre los adultos mayores y el COVID-19 mediante el aprendizaje automático (Xiang, et al., 2020)	Examinar el discurso público y los sentimientos respecto a los adultos mayores y COVID-19 en las redes sociales.	TF-IDF, Regresión logística, Linear Support Vector Classifier (SVC) y Random Forest, Latent Dirichlet allocation (LDA)	Se identificaron en términos de porcentaje aquellos twitts que expresan desprecio por la vida de los adultos mayores y aquellos que apoyan la idea de aislarlos.	2020
¿La resiliencia media la asociación entre los síntomas de salud mental y los marcadores lingüísticos del procesamiento del trauma? Analizando las narrativas de mujeres sobrevivientes de violencia de pareja (Castiglioni, et al., 2023)	Explorar la relación entre el trastorno de estrés postraumático y el uso del lenguaje.	Linguistic Inquiry Word Count (LIWC)	El trastorno de estrés postraumático se correlacionó positivamente con una perspectiva auto-inmersa, una sensación de amenaza de muerte, y formas verbales en tiempo pasado, pero se correlacionó negativamente con el procesamiento cognitivo, emociones positivas y formas verbales en tiempo presente y futuro.	2023

Tabla 11 Comparativa de trabajos relacionados, parte 6

Capítulo IV

Metodología de solución

En el desarrollo de este trabajo se experimentó con diferentes modelos de aprendizaje automático (Anexo 2 Pruebas utilizando modelos de aprendizaje automático). Sin embargo, debido a que los valores en las métricas que resultaron relevantes para trabajos de este tipo en el estudio del estado del arte (F1-score, Precision y Recall), fueron inferiores a 82 % (Tabla 26), se llegó a la conclusión de adoptar el enfoque de un modelo basado en conocimiento. La aplicación de este sistema se muestra a continuación.

4.1. Sistemas basados en conocimiento

Un sistema experto o sistema basado en conocimiento se puede definir como un sistema que resuelve problemas utilizando una representación simbólica del conocimiento humano (Badaró, et al., 2013) (Figura 8).

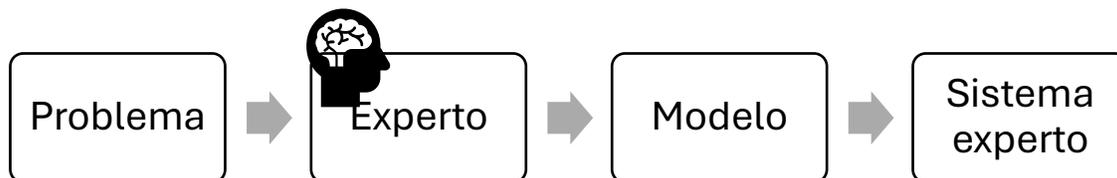


Figura 8 Diseño de sistema experto

- En este caso el problema es el análisis de los textos generados por la Escritura Emocional Autorreflexiva.
- El experto es la persona que elabora el trabajo de tesis y que ha realizado el análisis del problema.
- El modelo lo conforman las reglas establecidas por el experto.
- El sistema que resuelve el problema.

4.1.1. Definición de las categorías

Para este trabajo se han definido cinco categorías de textos: evasivo, descriptivo, emocional, analítico y analítico emocional. Estas categorías describen diferentes circunstancias en el enfoque del texto; para el caso de textos con énfasis en un trauma por violencia, se describen a continuación:

- 1) Evasivo. Escritos que no abordan la situación
- 2) Descriptivo. Escritos donde el individuo sólo se limita a describir los detalles que rodearon el suceso, sin mencionar la hora o lugar
- 3) Emocional. La persona se enfoca en las emociones que sintió sin hacer reflexión al respecto
- 4) Analítico. El individuo se avoca a realizar un análisis sobre el porqué de la situación
- 5) Analítico-emocional. La comprensión y asimilación de la situación traumática (Sidorov, 2005)

4.2. Descripción del corpus

Para este trabajo se aplicó la terapia EEA a mujeres víctimas de violencia a través del portal web de Escritura Emocional (Ortiz, et al., 2022). La violencia que estas mujeres han sufrido ha atentado contra su vida, por lo que se han refugiado en centros especiales en el estado de Morelos. En total se contó con 10 participantes. Antes de iniciar, se les aplicó un cuestionario de ansiedad y estrés posttraumático (Tabla 12).

Usuaría	Ansiedad	EPT
1	Grave	Positivo
2	Grave	Positivo
3	Moderada	Positivo
4	Grave	Positivo
5	Leve	Negativo
6	Moderada	Negativo
7	Leve	Riesgo
8	Leve	Probable
9	Moderada	Positivo
10	Baja	Negativo

Tabla 12 Resumen de cuestionarios de mujeres víctimas de violencia

De las 10 participantes, sólo 5 concluyeron la terapia, lo que concluyó con un total de 31 documentos. La Tabla 13 muestra un resumen del corpus obtenido.

Participantes	10
Documentos	31
Total de palabras	4252
Promedio de palabras por documento	141.7

Tabla 13 Resumen del corpus obtenido

En la Tabla 14 se muestra la cantidad de textos por cada uno de los ejercicios de la EEA (Escritura Emocional Autorreflexiva (EEA)).

Ejercicio 1	Ejercicio 2	Ejercicio 3	Ejercicio 4
10	9	7	5

Tabla 14 Cantidad de textos por

4.3. Análisis exploratorio manual / Caracterización del fenómeno

Se realizó un análisis utilizando el sistema MaxQDA, un programa de análisis cualitativo de textos. Esta tarea tuvo la finalidad de generar conocimiento a través de la lectura y etiquetado de cada uno de los textos, conocimiento que será utilizado en el sistema que será generado como resultado de esta tesis.

Los pasos seguidos en esta tarea se describen a continuación.

4.3.1. Obtención de frecuencias de palabras

El primer paso consistió en obtener un listado de las palabras más utilizadas en el corpus. Primero se hizo la tabla de palabras sin lematizar, y posteriormente, en otro ejercicio, se realizó la tabla con las palabras considerando aquellas que aparecieran al menos 8 veces (más de 20 conceptos).

4.3.2. Etiquetado de las partes del texto

Se usaron los valores lematizados y agrupados por afinidad semántica (p. ej. "bebé", "hija", "hijo" se agrupó como "Hijos") y para los segmentos de violencia fueron seleccionados aquellos términos que englobaran los temas tratados por cada una de las usuarias.

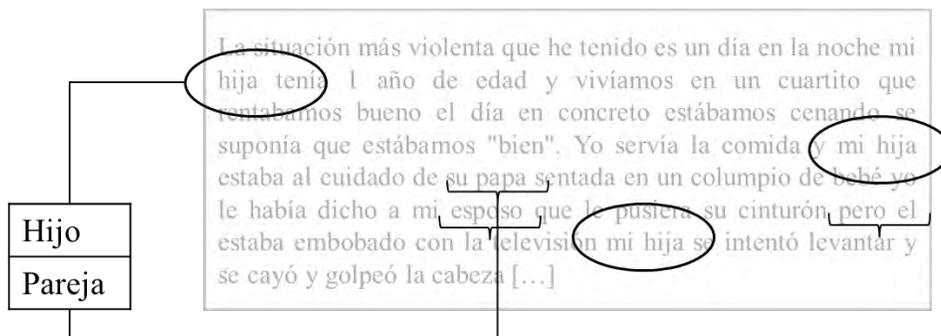


Figura 9 Etiquetado de las partes del texto

La Figura 9 muestra la manera en que se etiqueta el texto, asignándole términos relevantes a diferentes secciones (palabras, oraciones o párrafos).

4.3.3. Mapa de correlación y agrupamiento

Después de hacer el etiquetado de los segmentos del texto se genera un mapa de correlación de los diferentes términos. Los cuadrados rojos y un mayor tamaño indican relaciones entre los términos.



Figura 10 Matriz de correlación de términos

Posteriormente a la generación de la matriz se generó un mapa de agrupamiento. En él se muestran los diferentes términos separados por código de color y distancias. El sistema identifica aquellos términos relacionados. Cabe señalar que se hicieron pruebas con más grupos, pero los resultados más óptimos se dieron con 3.

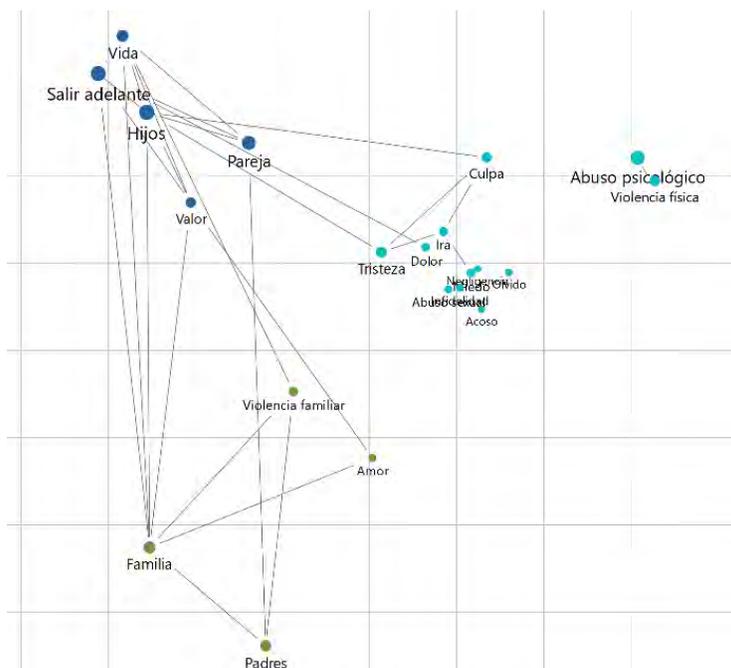


Figura 11 Agrupamiento

Siguiendo el código de colores y con base en los significados de los términos se optó por realizar el agrupamiento según los siguientes términos:

- Expresión de sentimientos negativos
- Familia
- Violencia

4.3.4. Generación de áreas temáticas

Con base en la agrupación obtenida al realizar el etiquetado de los segmentos del texto, los códigos fueron agrupados como se observa en la tabla siguiente.

Grupo	Términos
Familia	Amor

	Familia
	Padres
	Violencia familiar
Violencia	Abuso psicológico
	Abuso sexual
	Acoso
	Culpa
	Dolor
	Infidelidad
	Ira
	Miedo
	Negligencia
	Olvido
	Tristeza
	Violencia física
	Salir adelante
Pareja	
Salir adelante	
Valor	
Vida	

Tabla 15 Áreas temáticas y códigos

4.4. Generación y recopilación de diccionarios

Una tarea importante en el desarrollo de esta investigación fue la recopilación de diccionarios que fueran relevantes para la investigación. Así se reunieron los diccionarios listados en Tabla 16.

Tipo	Nombre	Cantidad de palabras	Cita
------	--------	----------------------	------

Marcadores del discurso		219	(Rodríguez, 2009) (Chile, 2021) (Rosario, 2020)
Léxico afectivo	Spanish Emotion Lexicon (SEL)	2,036	(Sidorov, et al., 2012) (Rangel, Sidorov, & Suárez- Guerra, 2014)
Polaridad de opinión	ISOL	8,135	(Molina-González, Martínez-Cámara, Martín-Valdivia, & Perea-Ortega, 2013)

Tabla 16 Resumen de los diccionarios recolectados

Diccionarios generados

Una vez realizado el análisis exploratorio se identificaron cualidades léxicas que pueden resultar de utilidad para modelar el fenómeno del discurso en el caso de mujeres víctimas de violencia. El resumen de los diccionarios generados se muestra en la Tabla 17 y se describen a continuación.

Nombre del diccionario	Total de instancias
Herramientas	73
Agresiones	55
Escenarios y actores	102
Léxico reflexivo	128

Tabla 17 resumen de diccionarios generados

Diccionario de herramientas

Tiene la finalidad de identificar aquellos instrumentos que podrían ser utilizados como arma en el desarrollo del discurso. Se construyó recurriendo a diferentes diccionarios de herramientas e instrumentos (Inglés, 2021) (Londres, 2021) (inglés, 2021) y consta de 73

palabras.

Diccionario de escenarios y actores

Tiene la finalidad de identificar a los diferentes actores que se mencionan en el discurso, así como el escenario al que pertenecen. Se agruparon en tres grandes categorías de escenarios: Familiar, Laboral y Social. Para construirlo se recurrió a diferentes vocabularios en la web, concluyendo con un vocabulario de 55 instancias.

Diccionario de agresiones

Tiene la finalidad de identificar las agresiones y su categoría. Se agruparon en tres grandes categorías de escenarios: Psicológica, Física y Sexual. Para construirlo se recurrió al (García, et al., 2016) (Judicatura, 2016). Se concluyó con un vocabulario de 102 palabras.

Diccionario de léxico reflexivo

Tiene como finalidad identificar aquellas palabras que semánticamente tienen que ver con la capacidad de autoconciencia del paciente, quien adquiere un sentido de autorreflexión hacia el final de la terapia (Escritura Emocional Autorreflexiva (EEA)).

4.5.Descripción de los atributos

Para la construcción de este modelo se utilizó el conocimiento generado en Generación de áreas temáticas y Generación y recopilación de diccionarios. Esto implica la etapa de análisis de contenido de los textos y la generación de diferentes diccionarios que resultaron semánticamente relevantes durante la lectura de los textos. Estos diccionarios se muestran en la Figura 12.

Asimismo, se utilizan otras variables (Tabla 23, Tabla 24, Tabla 25). Estos implican: categorías gramaticales, cantidad de palabras, cantidad de oraciones, promedio de palabras por oración, índice de coherencia, legibilidad, entre otras.

En conjunto se tiene un total de 53 variables.

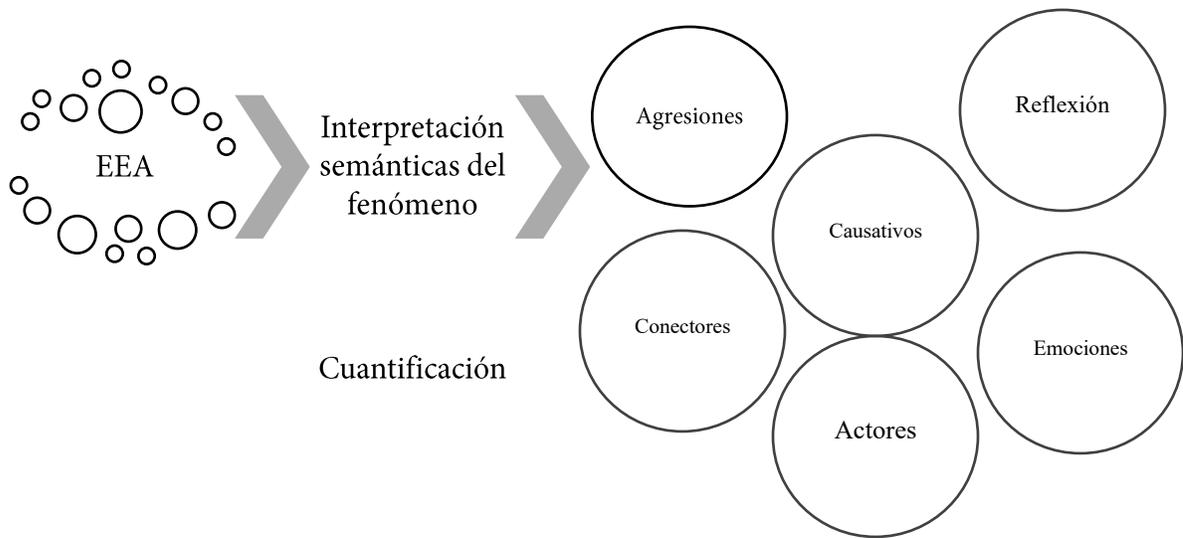


Figura 12 Dicionarios generados

4.6. Selección de atributos

Debido a la gran cantidad de variables se hizo un estudio de Info Gain (Tabla 18) para determinar aquellas variables que fueran relevantes para este fenómeno. Se tomó en cuenta aquellas que superaran un 0.4 en el valor de Info gain.

Variable:	Info. gain
Legibilidad	0.64
Vocabulario de Reflexión	0.62
Alegría	0.62
Conjunciones	0.56
Adjetivos	0.54
Pronombres	0.53
Sorpresa	0.53
Tristeza	0.53
Adposiciones	0.52
Verbos	0.52
Total de palabras	0.51

Alegría ponderada	0.45
-------------------	------

Tabla 18 Resultados de Info Gain y Anova

Capítulo V

Desarrollo de la solución

5.1. Etiquetado de los textos

Se recurrió a tres psicólogas que etiquetaron los textos con base en las características de las clases nombradas en la página 58, **Definición de las categorías**. A ellas se les proporcionó una muestra de los textos y la definición de las clases con la finalidad de que realizaran el etiquetado correspondiente.

Para validar la viabilidad de esta anotación se realizó un ejercicio de Fleiss Kappa utilizando la herramienta IBM SPSS Statistics. Este arrojó un valor de Kappa de 0.355, que según la Tabla 19, es un coeficiente aceptable para continuar con el experimento.

0	Pobre
0.1-0.2	Leve
0.21-0.4	Aceptable
0.41-0.6	Moderada
0.61-0.8	Considerable
0.81-1	Casi perfecta

Tabla 19 Valoración del coeficiente de Kappa (Landis y Koch)

El estudio implementado por las psicólogas ayudó a separar los textos e identificar el comportamiento de sus atributos. Además de este estudio, el modelo se complementó con el conocimiento obtenido durante la exploración manual de los textos.

5.1. Modelo

Para la construcción de este modelo se partió de la etapa de análisis de contenido de los textos y la generación de diferentes diccionarios que resultaron semánticamente relevantes durante la lectura de los textos (evasivo, descriptivo, emocional, analítico o analítico emocional).

En la Figura 13 y la Figura 14 se ilustran algunas de estas características y sus comportamientos estadísticos según las diferentes clases establecidas.

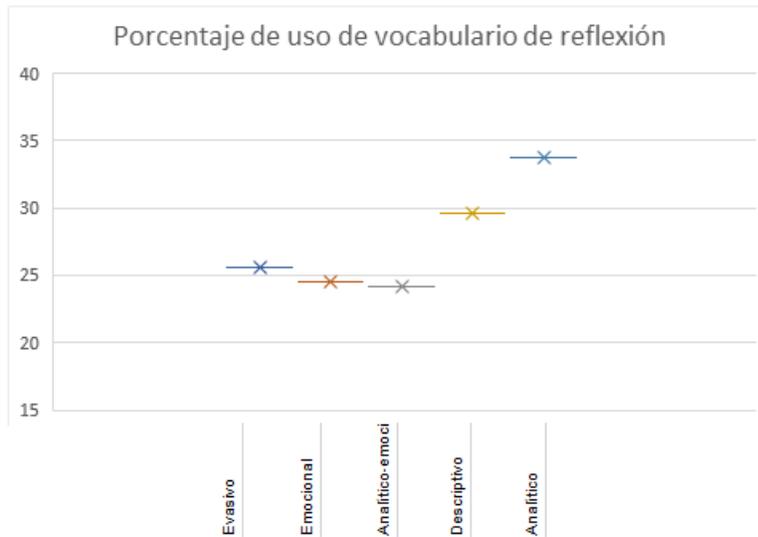


Figura 13 Usos de vocabulario de reflexión

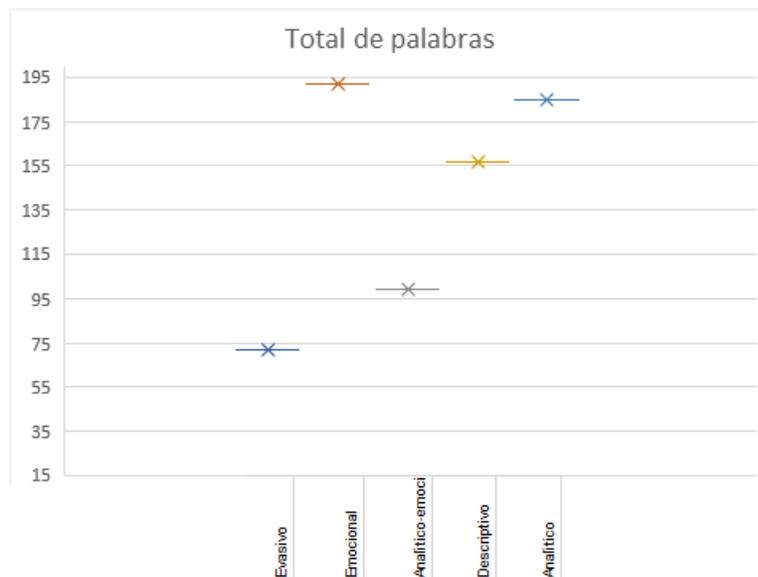


Figura 14 Gráfico de total de palabras

Con ello en mente se procedió a generar una serie de reglas que ayudaran a clasificar los textos. Se consideran umbrales en los valores de las diferentes variables, y mediante un proceso de ponderación que considera el estudio de Info Gain y Anova, se establecen valores que se van sumando hasta obtener una serie de índices que indican hacia qué categoría el texto tiene mayor afinidad. Este proceso se ilustra para una variable en Figura 15.

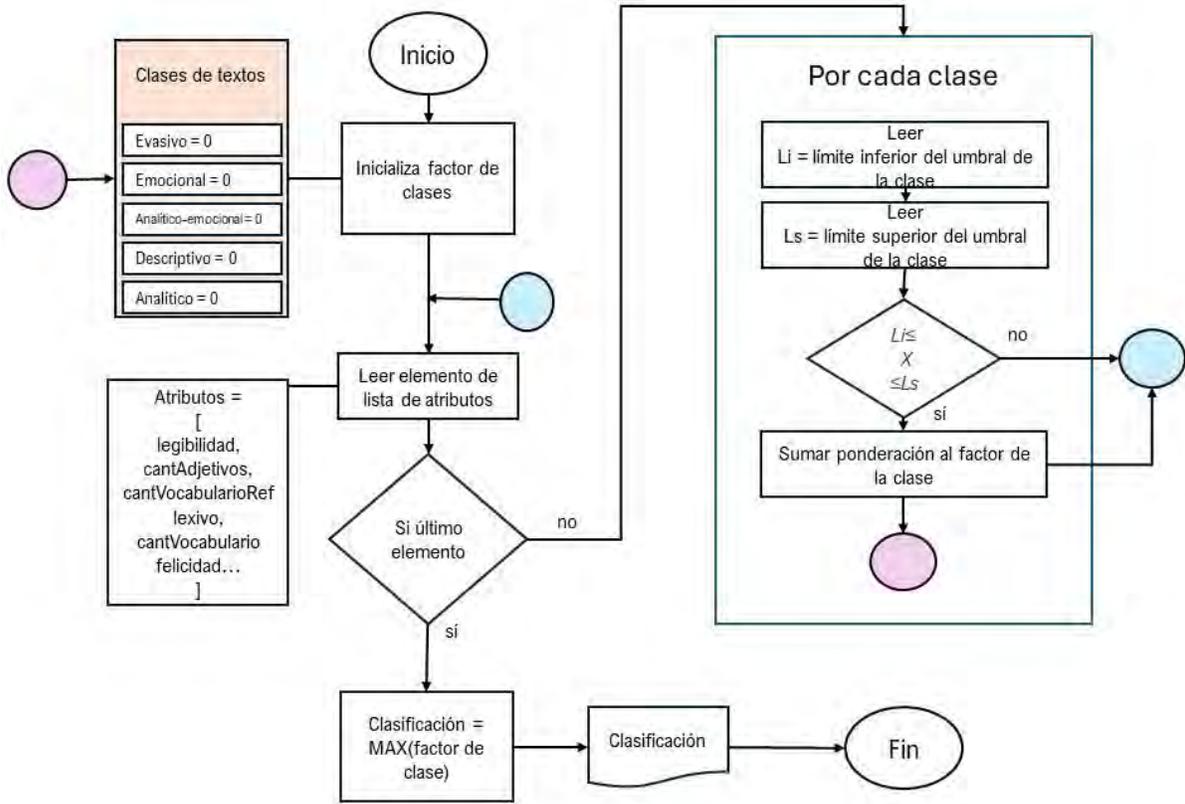


Figura 15 En este diagrama se ilustra el funcionamiento de la clasificación a través del análisis de las variables relevantes (legibilidad, en este caso).

El siguiente segmento de código corresponde al clasificador e ilustra la variable de Legibilidad, determinando el valor ponderado de la clase para el texto analizado. Cuando el valor aparece dentro del umbral correspondiente a la clase, se devolverá ésta. Existen casos

en los que umbrales de diferentes clases pueden abarcar un mismo valor, para no excluir a alguna clase en favor de otra, las ponderaciones se asignan para cada clase para la que el valor tenga afinidad.

```
def devuelveClasificacionLegibilidad (valor):
    respuesta = []
    if valor is None:
        return respuesta
    if valor <= 0.03:
        respuesta.append("Evasivo")
    if valor >= 0.02 and valor <= 0.06:
        respuesta.append("Emocional")
    if valor >= 0.03 and valor <= 0.05:
        respuesta.append("Analítico-emocional")
    if valor >= 0.02 and valor <= 0.06:
        respuesta.append("Descriptivo")
    if valor >= 0.06:
        respuesta.append("Analítico")
    return respuesta;
```

Por ejemplo: en el caso de Legibilidad el valor de ponderación es de 0.65 (basado en el estudio de Info gain); digamos que para este caso el valor del Texto N es de 0.06, el programa sumará la ponderación de 0.65 a una variable numérica que indica la afinidad del texto a ser “Evasivo” y a aquella que lo indica a ser “Analítico-emocional”. Al recorrer las diferentes variables consideradas, estas sumas proveen un resultado respecto a la afinidad del texto.

5.1.1. Evaluación del modelo

Tras haber codificado las reglas (Anexo 3 Formalización de reglas) en un script de Python, se realizó la validación para los textos etiquetados, obteniendo la matriz de confusión que se muestra en la Tabla 20.

	Analítico	Analítico-emocional	Descriptivo	Emocional	Evasivo
Analítico	2	0	0	0	0

Analítico-emocional	0	3	0	0	1
Descriptivo	0	1	4	0	3
Emocional	0	2	0	3	4
Evasivo	0	0	0	0	7

Tabla 20 Matriz de confusión del modelo generado

Con base en esta matriz de confusión se calcularon las métricas que resultaron relevantes para este tipo de trabajo durante el estudio del estado del arte.

- Accuracy: Para medir la frecuencia con la que el modelo predice correctamente el resultado. La fórmula utilizada para calcular esta métrica se muestra a continuación:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

- Precision: Con esta métrica se midió la calidad del modelo en la tarea de clasificación. La fórmula utilizada para calcular esta métrica se muestra a continuación:

$$Precision = \frac{TP}{TP + FP}$$

- Recall: Medida utilizada para determinar la cantidad de valores que el modelo es capaz de identificar. La fórmula utilizada para calcular esta métrica se muestra a continuación:

$$Recall = \frac{TP}{TP + FN}$$

- F1-score: Métrica utilizada para combinar las medidas de precision y recall en un sólo valor. La fórmula utilizada para calcular esta métrica se muestra a continuación:

$$F1 = \frac{2 * Precision * Recall}{TPrecision + Recall}$$

Los valores de las métricas obtenidas para este modelo se muestran en la Tabla 21.

Accuracy	0.633
F1-score	0.622
Recall	0.63
Precision	0.808

Tabla 21 Métricas del modelo

El modelo presentó rendimiento moderado con una precisión de 0.633 y un F1-score de 0.622. El valor de F1-score indica que el modelo puede ser mejorado.

5.2.Sistema TerapiaEscritura

Se diseñó un módulo web que permitiera a los terapeutas acceder a la información generada por el sistema de procesamiento de textos. La arquitectura del sistema se muestra en la Figura 16.

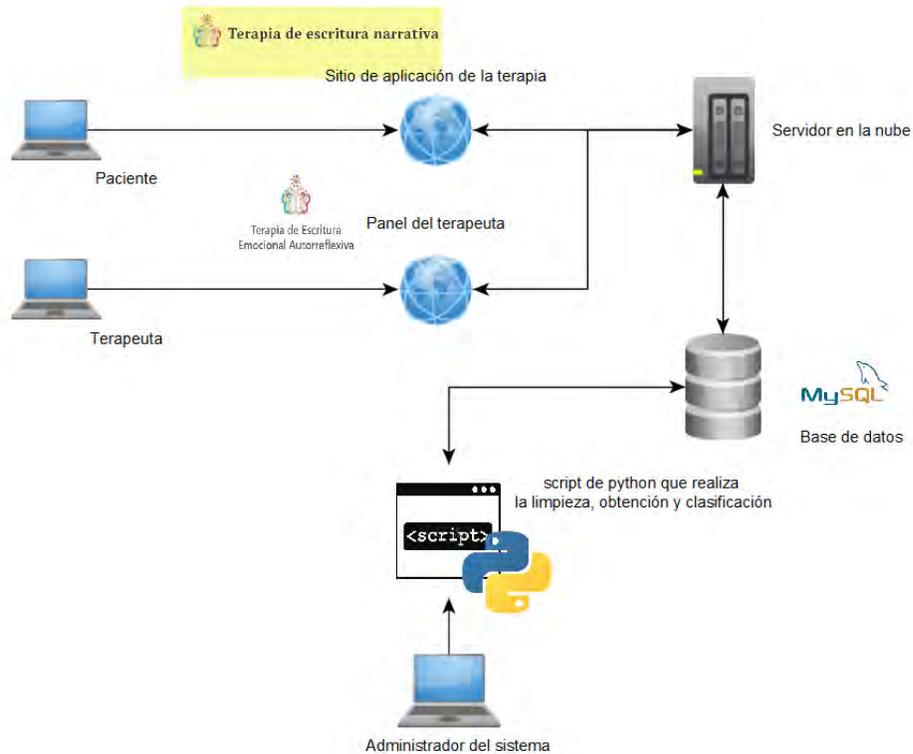


Figura 16 Arquitectura del sistema

5.2.1. Sistema “Terapiaescritura”

El diseño del sistema presentado anteriormente (Figura 16 Arquitectura del sistema) proporciona una visión general de los elementos que se desarrollaron para integrar el sistema. A su vez, el sistema está integrado por dos subsistemas: el sistema de clasificación y el sistema Web del terapeuta (Figura 17)

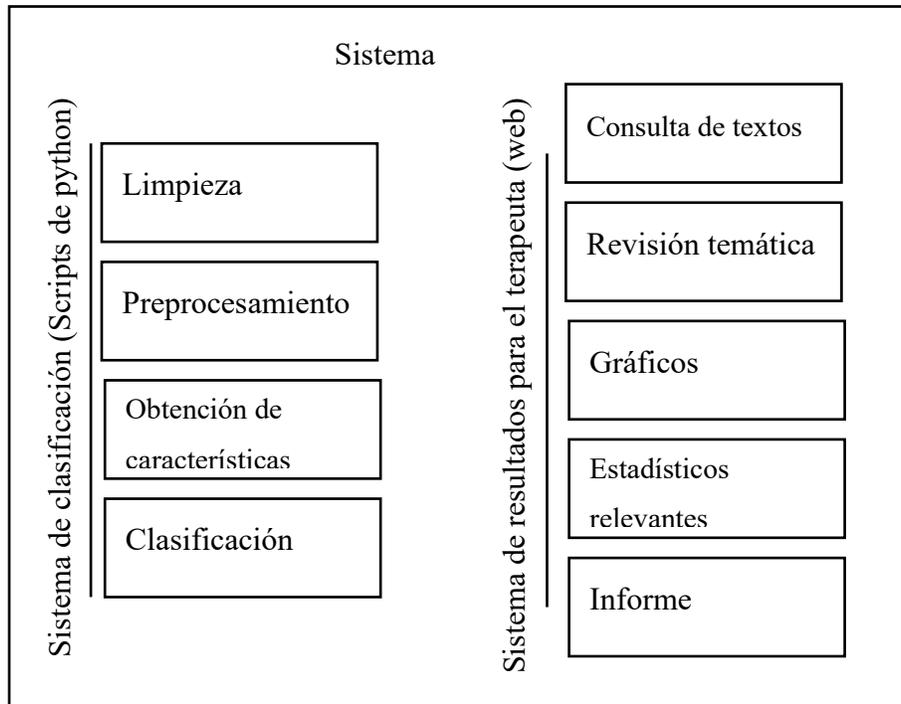


Figura 17 Sistema TerapiaEscritura y sus subsistemas

A continuación, se listan los módulos que integran el módulo de clasificación.

5.2.2. Sistema de clasificación

Este sistema está integrado por diferentes módulos encargados de realizar tareas de limpieza, preprocesamiento y obtención de características con la finalidad de realizar una clasificación de textos.

Base de datos y diccionarios semánticos

Se diseñó y se implementó una base de datos en el repositorio TerapiaEscritura.com. Se utilizó MySQL para desarrollar las siguientes tablas:

- Diccionario de Marcadores del discurso
- Diccionario de Léxico afectivo

- Diccionario de Polaridad de opinión
- Diccionario de Herramientas
- Diccionario de Agresiones
- Diccionario de Escenarios y actores
- Atributos
- Texto procesado
- Clasificación

El diagrama de la base de datos se muestra en Figura 18.

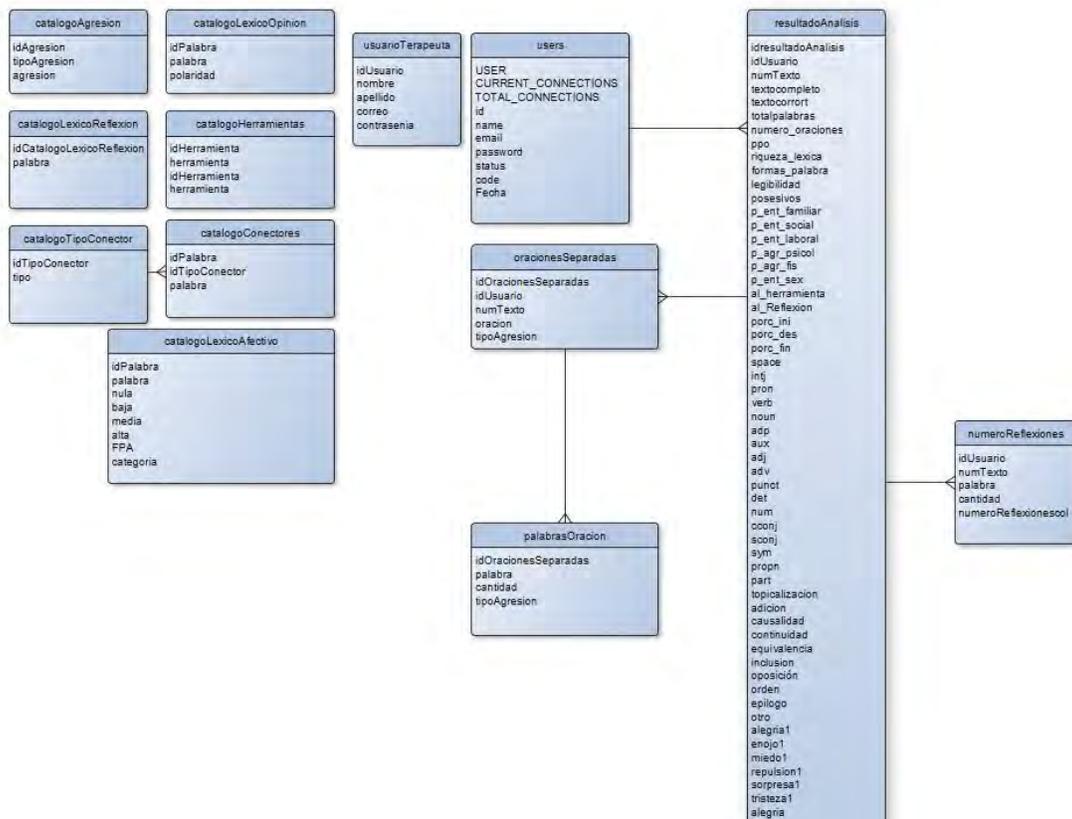


Figura 18 Diagrama de entidad-relación de la Base de datos desarrollada para el análisis de los textos

Módulo de limpieza de corpus y Módulo de preprocesamiento

- **Módulo de limpieza:**

Este módulo consiste en un script de Python. En él se realiza la limpieza del corpus. Esta tarea consiste en los siguientes pasos:

- Eliminación de múltiples espacios y saltos de línea
- Eliminación de palabras repetidas
- Eliminación de acentos

- **Módulo de preprocesamiento:**

Realiza la normalización de los textos, que consiste en los siguientes pasos:

- Conversión de palabras a minúsculas
- Eliminación de palabras vacías (como ante, antes, aún, aunque, aquí, así.)
- Tokenización (separación de palabras)
- Lematización (proceso lingüístico de hallar el lema correspondiente de una palabra flexionada —conjugada, plural—. Por ejemplo, el lema de “diré”, “dijo” es “decir”)

Ambos módulos utilizan Python y Spacy para realizar sus respectivas tareas. Adicionalmente se conectan con la Base de datos para consultar la información de los textos.

Módulo de obtención de características

En este módulo se utilizan herramientas de Python, Spacy y Gensim para obtener características gramaticales tales como la cantidad de adjetivos, adverbios, entre muchos otros índices (Anexo 1 Listado de variables). Durante este proceso también se utilizan los diccionarios generados en Análisis exploratorio manual / Caracterización del fenómeno para contabilizar la frecuencia de uso de estas palabras. Las características son almacenadas como atributos en una tabla de la Base de datos que posteriormente es consultada para realizar la clasificación de los textos.

Modelo de clasificación de textos basado en reglas

Este es el script que se encarga de realizar la clasificación de los textos en alguna de las categorías establecidas en Sistemas basados en conocimiento. La información detallada de este proceso se encuentra en Modelo de clasificación de textos basado en reglas.

5.2.3. Sistema de resultados para el terapeuta

Para resolver el problema que representa el análisis de los textos se optó por diseñar el sistema que a continuación se presenta. Este sistema web ha sido incorporado al sistema actual de aplicación de la terapia (www.terapiaviolencia.com.mx), sistema desarrollado en una colaboración entre CENIDET y el Instituto Nacional de Salud Pública (INSP).

Este módulo será de uso exclusivo para los terapeutas; las usuarias que hacen la terapia no tendrán acceso a él.

A continuación, se listan los diferentes elementos que constituyen el panel del terapeuta.

Inicio de sesión

En primer lugar, se tiene una pantalla de inicio de sesión (Figura 19) en donde el terapeuta deberá validar sus credenciales de acceso al panel del terapeuta. El usuario y la contraseña deberán ser creados por un administrador del sistema.

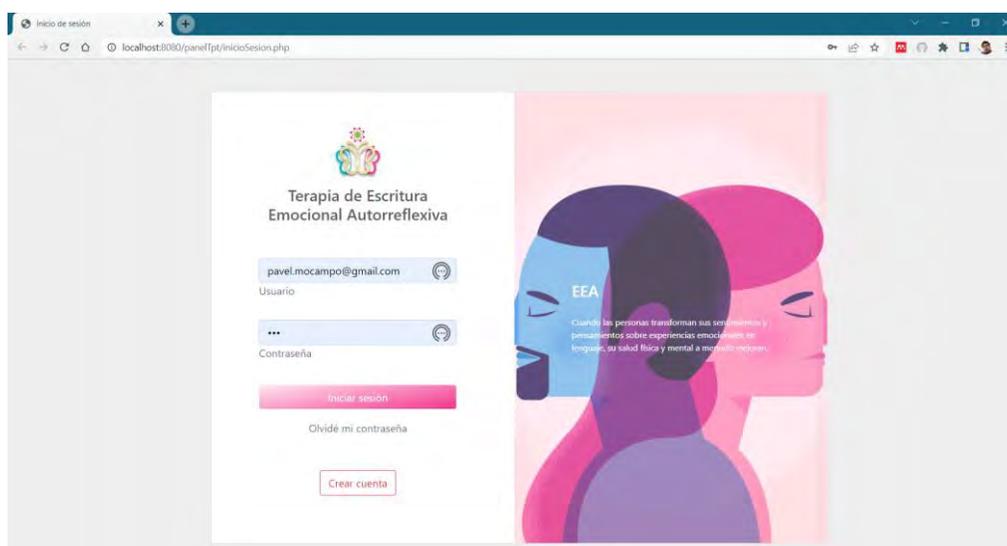


Figura 19 Inicio de sesión del terapeuta

Selección de usuario

A continuación, se tiene una pantalla inicial en donde el terapeuta puede seleccionar a cualquiera de las usuarias que hayan realizado la terapia de entre un listado (Figura 20).

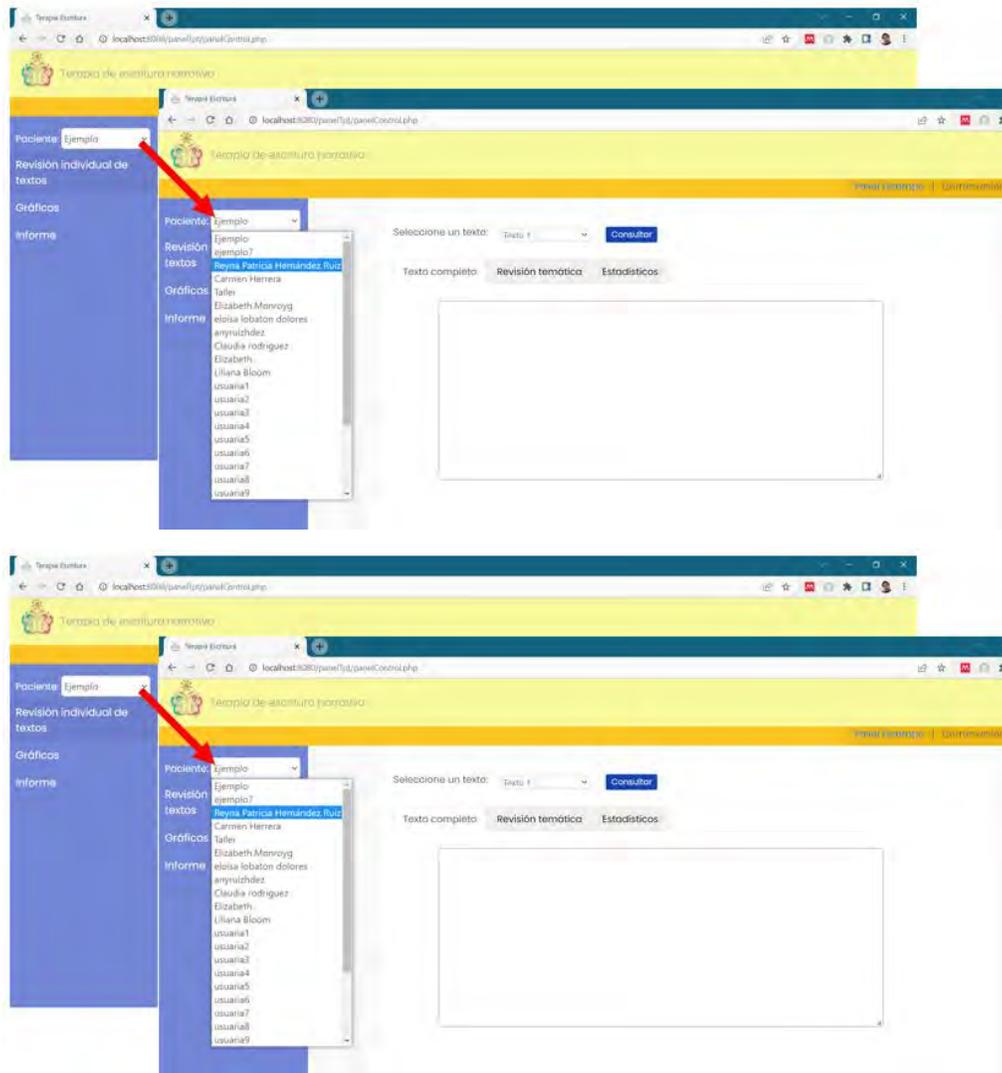


Figura 20 Pantalla de selección de la usuaria y texto

Selección del texto

También podrá seleccionar alguno de los textos para leerlos (Figura 21) o revisar estadísticos individuales.

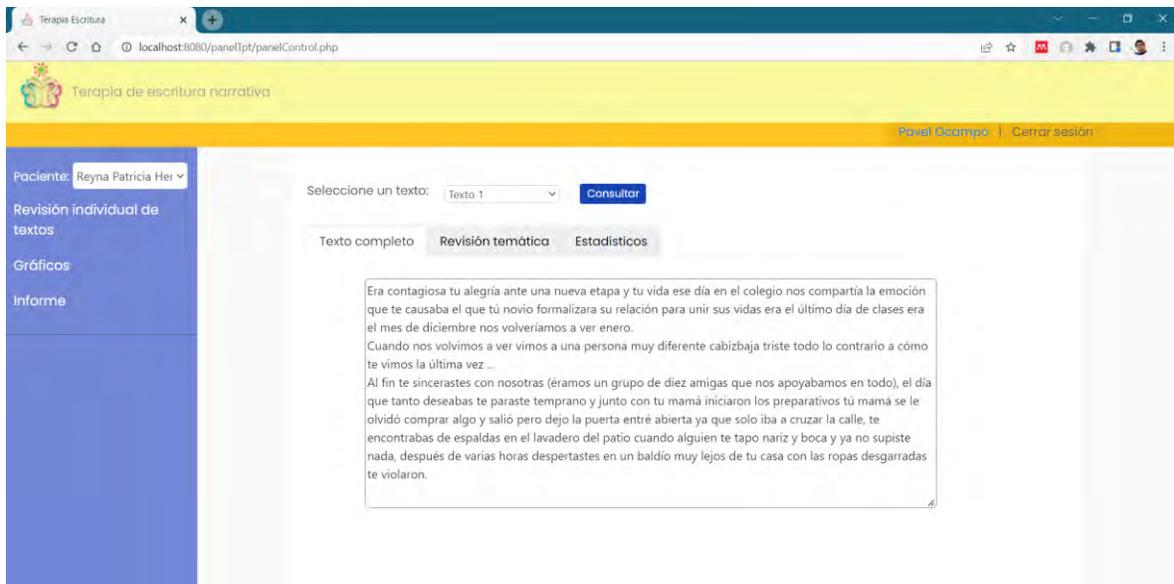


Figura 21 El texto seleccionado aparecerá en el textarea

Revisión de las oraciones y áreas temáticas

La Figura 22 muestra la segunda pestaña del proceso de análisis del texto. En ella se muestra un resumen de segmentos (oraciones) de donde han sido extraídas las palabras clave que ayudan a determinar el área temática (tipo de agresión) a que refiere el texto. Estas palabras clave son las recolectadas en los diferentes vocabularios de agresiones. Con la finalidad de que el terapeuta pueda interactuar y hacer ajustes al análisis, el área temática podrá ser modificada a través de un botón de tipo select. Al final de la pantalla, se muestra un resumen del ejercicio, donde se establece el tipo de violencia según porcentajes de aparición de términos (mostrados en un gráfico).

Figura 22 Pantalla de revisión temática. En ella se muestra la tabla de segmentación del texto con sus correspondientes palabras claves y tipo de agresión; en la parte inferior se muestra un gráfico que explica el porcentaje de violencia a que refiere el texto según la revisión del terapeuta.

Estadísticos

(Figura 23) Esta pestaña muestra al terapeuta diferentes estadísticos. En primer lugar, se tienen los valores de ansiedad y estrés postraumático reportados por la usuaria; en segundo lugar, se presenta un resumen de diferentes variables dentro del texto: sustantivos, verbos, pronombre, interjecciones, riqueza léxica y legibilidad. Los últimos dos acompañados por un semáforo que indique si los valores bajos según las escalas utilizadas (Fernández Huerta y

MASS). Recordemos que bajos valores en estas variables indican pobreza lingüística en los textos.

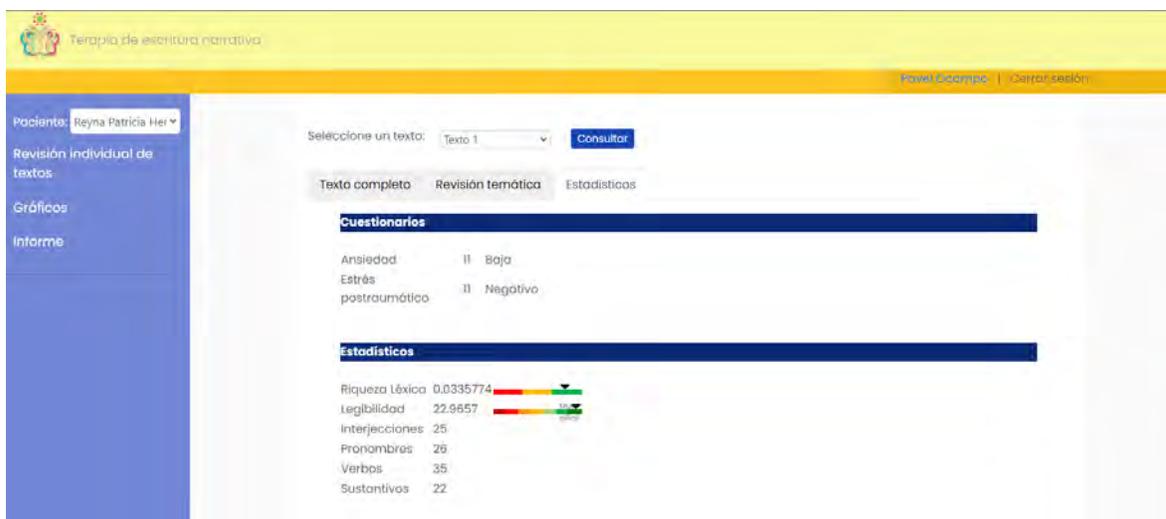


Figura 23 Estadística individual de los textos. El semáforo servirá de apoyo al terapeuta como indicador de que el índice es pobre (rojo) o bueno (verde). Esto considerando que estas características están asociadas a un texto bien escrito (Coromina, 2014).

Gráficos

Los gráficos incluidos en la Figura 24 ilustran los diferentes vocabularios generados en esta tesis (léxico afectivo, de superación, conectores discursivos y términos de reflexión). Estos gráficos tienen el objetivo de mostrar la variación en el uso del vocabulario a través de la terapia (ver Generación de reportes/gráficos en el sistema).

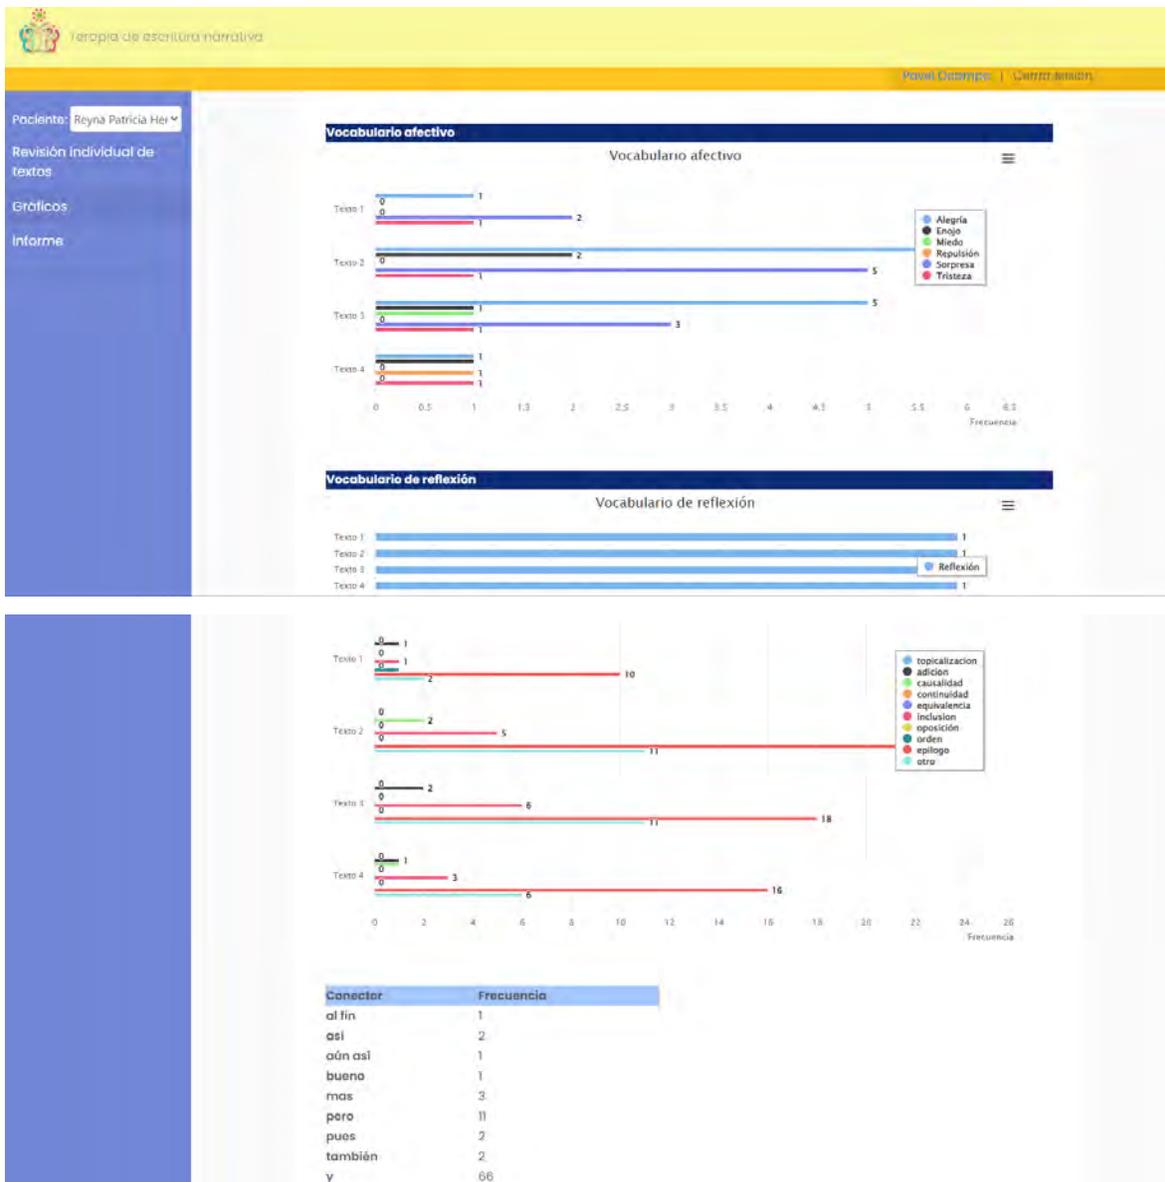


Figura 24 Gráficos de vocabularios. En esta pantalla contiene gráficos que muestra la cantidad de palabras usadas en el texto que pertenecen a alguno de los vocabularios obtenidos en el desarrollo de este trabajo. Estos son los vocabularios: afectivo, de reflexión, y de conectores discursivos.

Informe

La última pantalla tiene la finalidad de mostrar un informe tipo resumen acerca de los ejercicios realizados. Se muestran las áreas de ansiedad y estrés y se indica si éstas disminuyeron, se mantuvieron o aumentaron tras la aplicación de la terapia. Asimismo, se muestran las áreas temáticas del texto y el tipo del mismo, cuya clasificación está dada por

el uso de conectores discursivos. El tipo de texto puede ser: evasivo, descriptivo, emocional, analítico o analítico emocional.



Figura 25 Informe general

5.3. Generación de reportes/gráficas en el sistema

Como parte del sistema para el terapeuta se diseñó una serie de pantallas que mostraran diferentes gráficos (ver 5.2.3, Gráficos) con información relevante de los textos al terapeuta. Estos gráficos se describen a continuación:

5.3.1. Gráfico de vocabulario afectivo

Existen estudios donde se evidencia que el mayor uso de palabras emocionales positivas y palabras cognitivas se asoció con mayores beneficios para la salud que un uso intermedio de palabras negativas (Martino, et al., 2015). Este gráfico tiene la finalidad de mostrar la frecuencia de palabras usadas en cada uno de los textos de la paciente.

5.3.2. Gráfico de vocabulario de reflexión

Para este gráfico se utiliza el diccionario generado en el tercer semestre asociado con palabras que demuestran una capacidad cognitiva (del latín “conocer”). El léxico de reflexión consta de 128 palabras. El diccionario contiene palabras como “notar”, “darse cuenta”, “percatarse”, denotan un estado actividad intelectual o estado consciente.

Ya que el uso de palabras cognitivas está relacionado con la mejora de la salud (Pennebaker, 1993), el terapeuta puede encontrar útil esta representación visual de la frecuencia de su uso en los textos.

5.3.3. Gráfico de conectores discursivos

Según (Pardo & Buscaglia, 2008) la ausencia de conectores que se produce en el discurso del paciente puede ser una señal importante de deterioro cognitivo, es por ello que este gráfico tiene la finalidad de presentar la frecuencia de uso de estos elementos.

Capítulo VI

Pruebas

Para esta tarea se realizó un proceso completo que consta de los pasos representados en la Figura 26.

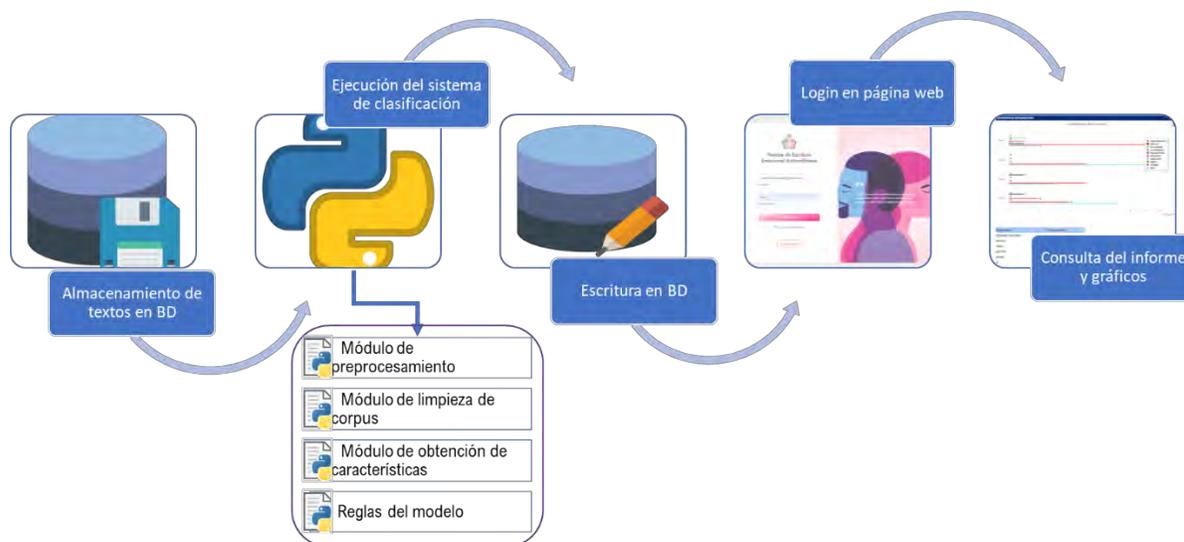


Figura 26 Proceso de pruebas del sistema

Los pasos se describen a continuación:

6.1. Almacenamiento de textos en la base de Datos

Se cuenta con 31 textos generados por mujeres víctimas de violencia a través del portal web de Escritura Emocional (Ortiz, et al., 2022), además de los catálogos de los diccionarios descritos en Generación y recopilación de diccionarios.

6.2. Ejecución del sistema clasificador

El proceso de ejecución del sistema incluye la consulta de los textos, la limpieza, el preprocesamiento, la obtención de características y grabado en la Base de datos y el almacenamiento del resultado de clasificación en la tabla “resultadoAnálisis”.

6.3. Login en la página web

Una vez ejecutado el sistema clasificador se puede consultar la información correspondiente a los textos. Para ello es necesario que el terapeuta acceda con sus credenciales al sistema.

6.4.Exploración y consulta de gráficos, textos e informes

En 5.2.3 Sistema de resultados para el terapeuta, se describen las ventanas y elementos que conforman el sistema. El terapeuta podrá navegar a través de las pestañas consultando la información de los textos, así como los gráficos de los vocabularios que se encontraron relevantes durante el estudio del estado del arte de este trabajo.

Capítulo VII

Resultados y conclusiones

7.1.Resultados obtenidos

En este apartado se listan las actividades científicas y los logros obtenidos durante el desarrollo de este trabajo.

7.1.1. Material generado

En este apartado se lista el material que ha sido generado durante este trabajo. Esto incluye los diferentes scripts que integran el módulo de clasificación, el proyecto web integrado en el proyecto “terapiaescritura”, así como el listado de diccionarios que fueron recolectados y generados durante el desarrollo de este trabajo.

	Módulo de preprocesamiento
	Módulo de limpieza de corpus
	Módulo de obtención de características
	Módulo de resultados para el terapeuta
	Reglas del modelo
	Diccionarios: Herramientas, Escenarios y actores, Léxico de reflexión, Agresiones y tipos de agresión

Figura 27 Listado de material generado

7.2. Conclusiones

Este trabajo tuvo como objetivo la propuesta e implementación de un método de análisis de discurso para textos producidos por mujeres víctimas de violencia y que han sido tratadas por la técnica de Escritura Emocional Autorreflexiva (EEA).

Esta tesis consiguió generar un corpus de textos producidos por mujeres víctimas de violencia en situación de refugio, mismos que pudieron ser analizados y caracterizados mediante la lectura manual y la exploración de características lingüísticas a través de técnicas de Procesamiento de Lenguaje Natural.

A través de múltiples métodos, como la cuantificación semántica y la contabilización de atributos gramaticales, se realizó un estudio donde se obtuvieron variables relevantes para modelar un algoritmo que permite realizar la clasificación de textos, culminando con un modelo de clasificación basado en reglas. Adicionalmente, se desarrolló una interfaz web que tiene la finalidad de apoyar al terapeuta en su labor clínica.

Los resultados obtenidos demuestran que aún queda mucho trabajo por hacer en el análisis del discurso para textos producidos mediante la EEA, y sobre todo en el ámbito de los textos producidos por mujeres víctimas de violencia. El tema es de una complejidad social enorme, sobre el que habría que reflexionar y dialogar a profundidad con personas expertas, es decir, aquellas que se dedican a brindar apoyo en los refugios de mujeres. Finalmente, el presente trabajo contribuye con un conocimiento específico del área que esperamos sea de utilidad para próximos estudios.

La Tabla 22 muestra el listado de los objetivos que se plantearon en este trabajo de tesis y en la columna Descripciones se desarrolla cómo fueron alcanzados estos objetivos.

Objetivos	Descripciones
Proponer e implementar un método de análisis del discurso utilizando técnicas de Procesamiento de Lenguaje Natural.	Varias técnicas fueron utilizadas en el desarrollo de un Sistema Experto.
Generar un corpus de narraciones	31 documentos.

emocionales.	
Identificar las unidades lingüísticas más representativas al medir el discurso.	Se identificaron unidades semánticas, además de unidades de variables relevantes. En este caso se identificaron atributos relevantes para la clasificación de los documentos (Tabla 18).
Identificar qué unidades lingüísticas están correlacionadas con la mejora de un paciente.	<p>Algunas unidades semánticas son una clara señal mejora, y éstas han sido agregadas al panel del terapeuta como parte del informe del paciente y sus gráficos.</p> <p>VARIABLES COMO LA FRECUENCIA DE CONECTORES DISCURSIVOS, EL USO DE VOCABULARIO AFECTIVO Y DE REFLEXIÓN SON ALGUNAS UNIDADES SEMÁNTICAS IDENTIFICADAS COMO RELEVANTES PARA LA MEJORA.</p> <p>Ver. 5.2.3 Sistema de resultados para el terapeuta</p> <p>Además de estas variables, se identificó un diccionario de áreas temáticas con palabras utilizadas en el contexto de la violencia contra las mujeres(semántica).</p> <p>Ver Generación de áreas temáticas.</p>
Proponer un método de análisis que permita medir cuantitativamente el	La cuantificación de variables relevantes puede ser de utilidad al

cambio cognitivo según los atributos del discurso.	terapeuta.
--	------------

Tabla 22 Tabla de objetivos alcanzados en este trabajo

7.3.Trabajos futuros

En esta sección se proponen actividades derivadas de este trabajo de investigación.

- Aplicar la terapia a una población mayor.

En este trabajo se aplicó la terapia a diez mujeres, población pequeña para la caracterización de un fenómeno tan complejo como la violencia. Además, sólo cinco mujeres concluyeron exitosamente la terapia, por lo que las variaciones entre los textos de un ejercicio a otro podrían variar de forma considerable dependiendo de la población.

- Aplicar técnicas de reducción de dimensionalidades.

La exploración de nuevos textos puede arrojar luz respecto a correlaciones que puedan resultar interesantes y puedan ser disminuidos en términos de cantidad de variables.

- Realizar un etiquetado más específico.

En este trabajo se recurrió a tres psicólogas, que realizaron un etiquetado según las especificaciones proporcionadas. El índice de Fleiss Kapa y la exploración de los textos mostró una discordancia que podría representar dificultades para el algoritmo y la selección de características importantes. Es posible que si la clasificación es realizada por personal especialista en el ámbito de mujeres víctimas de violencia se pueda obtener un etiquetado más pertinente.

7.4. Aportaciones y productos académicos

En este apartado se presentan las aportaciones realizadas a lo largo del desarrollo de este trabajo.

X Coloquio de Lingüística Computacional en la UNAM

Ponencia en el Coloquio de Lingüística Computacional con el trabajo “Análisis de discurso en narraciones emocionales de pacientes tratados por una técnica terapéutica”. Se participó de manera virtual presentando la metodología de obtención de características y un breve resumen de la caracterización del fenómeno discursivo en el contexto de la EEA aplicada a mujeres víctimas de violencia.

URL: https://www.facebook.com/watch/live/?ref=watch_permalink&v=1010127453122078

7a Jornada de Ciencia y Tecnología Aplicada

Participación en la Jornada de Ciencia y Tecnología Aplicada del Tecnológico Nacional de México campus CENIDET con el trabajo “La influencia del léxico afectivo en los discursos políticos y su relación con los resultados de las elecciones”. Se presentó de manera virtual los resultados de un trabajo experimental en donde se extrajeron características relacionadas con el léxico afectivo en una muestra de discursos políticos emitidos durante los periodos de elección en 2018, 2012 y 2006. El trabajo demostró que parece existir una correlación entre el uso de léxico afectivo y los resultados de las elecciones.

Jornada de Ciencia y Tecnología Aplicada VOLUMEN 4, NÚMERO 2, JULIO - DICIEMBRE 2021

URL: https://www.jcyta.cenidet.tecnm.mx/revistas/jcyta/07-Revista_JCyTA_Vol-4-Num-2_Jul-Dic_2021.pdf

Referencias

- Badaró, S., Ibañez, L. J. & Agüero, M. J., 2013. Sistemas Expertos: Fundamentos, Metodologías y Aplicaciones. *Ciencia y Tecnología*, pp. 349-363.
- Bearden, C. E., Wu, K. N., Caplan, R. & Cannon, T. D., 2011. *Thought Disorder and Communication Deviance as Predictors of Outcome in Youth at Clinical High Risk for Psychosis*. s.l.:Journal of the American Academy of Child & Adolescent Psychiatry.
- Beltrami, D. et al., 2018. Speech analysis by natural language processing techniques: A possible tool for very early detection of cognitive decline?. *Frontiers in Aging Neuroscience*.
- Bengoetxea, K., Atutxa, A. & Iruskieta, M., 2017. Un detector de la unidad central de un texto basado en técnicas de aprendizaje automático en textos científicos para el euskera. *Procesamiento del Lenguaje Natural*, pp. 37-44.
- Cabrera, E., 2006. Efectos terapéuticos de la escritura emocional o expresiva. *sociación Canaria de Psicoterapia Post-Racionalista*, Volume 89, pp. 9-12.
- Castiglioni, M., Caldiroli, C. L., Manzoni, G. M. & Procaccia, R., 2023. Does resilience mediate the association between mental health symptoms and linguistic markers of trauma processing? Analyzing the narratives of women survivors of intimate partner violence. *Psychology for Clinical Settings*, Volume 14.
- Castro-Castro, D., Rodríguez-Losada, C. A. & Muñoz, a. R., 2020. Mixed Style Feature Representation and B0-maximal Clustering for Style Change Detection. *CLEF* , pp. 22-25.
- Cecchi, G. A. & Corcoran, C. M., 2020. Using Language Processing and Speech Analysis for the Identification of Psychosis and Other Disorders. *Biological Psychiatry: Cognitive Neuroscience and Neuroimaging*, pp. 770-779.
- Chandran, D. et al., 2019. Use of natural Language processing to identify obsessive compulsive Symptoms in patients with schizophrenia, schizoaffective disorder or bipolar disorder. *Scientific Reports*, pp. 1-7.
- Chowdhary, K. R., 2020. Natural Language Processing. In: *Fundamentals of Artificial Intelligence*. New Delhi: Springer, p. 603–649.
- Clark, D. A., 2014. *The Wiley Handbook of Cognitive Behavioral Therapy*. Fredericton,

- Canada: John Wiley & Sons, Ltd.
- Coromina, E., 2014. El lenguaje eficaz en la escritura. *Lenguaje y Educación*, pp. 67-74.
- Denia, E., 2020. El impacto del discurso científico en Twitter. *Comunicar: Revista Científica de Educomunicación*, 65, pp. 21-30.
- Dijk, T. A. v., 1997. *El Discurso como estructura y proceso*. London: Sage Publications.
- Dzib Aguilar, J. P., Moo Estrella, J. & Chan Coob, J. G., 2010. Técnicas psicoterapéuticas para proteger la confidencialidad y la responsabilidad legal: implicaciones. *Diversitas: Perspectivas en Psicología*, pp. pp. 441-448.
- E., H. R., S., S. & C., A. N., 1986. *A Comparative Study of Manic vs Schizophrenic Speech Disorganization*. New York: Arch Gen Psychiatry.
- Fernández, Á. F., Guijarro, A. R. & Antón, L. A., 2020. Análisis de la caracterización discursiva de los relatos migratorios en Twitter. El caso Aquarius.. *Revista Latina de Comunicación Social*, pp. 1-18.
- García, M. Á., Alías, A. M. S. & Ballester, P. B., 2016. *Manual De Atención Psicológica A Víctimas De Maltrato Machista*. s.l.:Colegio oficial de la psicología de Gipuzkoa.
- García, M. J. M., 2020. ¿Hablamos? Análisis del discurso y estrategias empleadas en WhatsApp por estudiantes universitarios. *Onomázein, Revista de lingüística, filología y traducción*, pp. 274-294.
- Género, M. d. l. m. y. e. y. d., 2020. Guía de prevención de la violencia contra la mujer. *SERNAMEG*, pp. 1-2.
- Hickman, L. et al., 2022. Text Preprocessing for Text Mining in Organizational Research: Review and Recommendations. *Organizational Research Methods*, 25(1), pp. 114-146.
- INEGI, 2022. *inegi.org.mx*. [Online]
Available at: <https://www.inegi.org.mx/tablerosestadisticos/vcmm/>
[Accessed 26 05 2024].
- Inglés, L. M. d., 2021. *mansioningles*. [Online]
Available at: <https://www.mansioningles.com/vocabulario52.htm>
- inglés, Z., 2021. *Herramientas*. [Online]
Available at: <https://www.zonaingles.com/vocabulario/herramientas-en-ingles/>
- Jacob, K. L., Christopher, M. S. & Neuhaus, E. C., 2011. *Development and validation of the Cognitive-Behavioral Therapy Skills Questionary*, s.l.: Sage.

- Judicatura, C. d. l., 2016. *Manual sobre qué hacer y cómo actuar frente a situaciones de violencia de género*. Guerrero: s.n.
- Kishimoto, Y., Murawaki, Y. & Kurohashi, S., 2020. *Adapting BERT to Implicit Discourse Relation Classification with a Focus on Discourse Connectives*. Marseille, European Language Resources Association, p. 1152–1158.
- Levis, M. et al., 2020. Natural language processing of clinical mental health notes may add predictive value to existing suicide risk models. *Cambridge University Press*.
- Li, J., Li, R. & Hovy, E., 2014. *Recursive Deep Models for Discourse Parsing*. Doha, Qatar, Association for Computational Linguistics, pp. 2061-2069.
- Londres, T., 2021. *Vocabulario de herramientas*. [Online] Available at: <https://trucoslondres.com/aprender-ingles/vocabulario/herramientas-ingles/>
- Martino, M., Onorato, R. & Freda, M., 2015. Linguistic Markers of Processing Trauma Experience in Women's Written Narratives During Different Breast Cancer Phases. *Eur J Psychol*, p. 11.
- Maxwell Levis, C. L. W. J. G. B. V. W. B. S., 2020. Natural language processing of clinical mental health notes may add predictive value to existing suicide risk models. *Cambridge University Press*.
- Mujeres, O., 2012. *Manual de legislación sobre la violencia contra la mujer*. s.l., ONU Mujeres, pp. 17-19.
- Naciones Unidas, 1993. Declaración sobre la eliminación de la violencia contra la mujer. *ONU Mujeres*, 20 Diciembre.
- Nie, A., Bennett, E. D. & Goodman, N. D., 2019. *DisSent: Learning Sentence Representations from Explicit Discourse*. Florence, Italy, Association for Computational Linguistics, p. 4497–4510.
- Noord, R. v., Abzianidze, L., Toral, A. & Bos, J., 2018. *Exploring Neural Methods for Parsing Discourse Representation Structures*, Groningen: Center for Language and Cognition.
- Olvera, Y. et al., 2002. Evaluación de la escritura emocional autorreflexiva en estudiantes de ingeniería del Instituto Politécnico Nacional. *Enseñanza e Investigación en Psicología*, pp. 71-92.
- Organization, W. H., 2023. PTSD. *World Health Organization*, p. 2.

- Ortiz-Velázquez, M. I., Castro-Sánchez, N. A. & Rivera-Rivera, L., 2022. *Procesamiento de Lenguaje Natural para el Análisis de la Escritura Emocional Autorreflexiva (EEA) en mujeres víctimas de violencia*. s.l.:Tecnológico Nacional de México.
- Ortiz, V. M. I., Castro-Sánchez, N. A. & Rivera, R. L., 2022. Procesamiento de Lenguaje Natural para el Análisis de la Escritura Emocional Autorreflexiva (EEA) en mujeres víctimas de violencia. In: Cuernavaca: TECNM, pp. 20-21.
- Pardo, M. L. & Buscaglia, V., 2008. Pobreza y salud mental desde el Análisis Crítico del Discurso. *Discurso y sociedad*, pp. 357-393.
- Pennebaker, J., Boyd, R., Jordan, K. & Blackburn, K., 2015. The development and psychometric properties of LIWC2015.. *Austin, TX: University of Texas at Austin.*
- Pennebaker, J. W., 1993. Putting stress into words: Health, linguistic, and therapeutic implications. *Behaviour Research and Therapy*, pp. 539-548.
- Pitler, E. et al., 2008. *Easily Identifiable Discourse Relations*, Pennsylvania: Department of Computer Science & Institute for Research in Cognitive Science.
- PTSD, N. C. f., 2015. Tratamientos eficaces para el TEPT. *National Center for PTSD*, Enero.
- Rebeca Pardo Cebrián, A. C. E., 2017. Applying cognitive restructuring in therapy: The clinical reality in Spain. *Psychotherapy Research*.
- Robledo, H., Nazar, R. & Renau, I., 2017. *Un enfoque inductivo y de corpus para la categorización de los marcadores del discurso en español*. Begium, Université Catholique de Louvain, pp. 91-93.
- Salud, O. M. d. l., 2002. Informe mundial sobre la violencia y la salud. *Organización Panamericana de la Salud*, p. 5.
- Sanders, A. C. et al., 2021. Unmasking the conversation on masks: Natural language processing for topical sentiment analysis of COVID-19 Twitter discourse. *medRxiv and bioRxiv*.
- Sidorov, G. C.-S. N., 2005. *Sistema de análisis automático de textos en español para la detección de perfiles lingüísticos*. Ciudad de México: IPN: Laboratorio de Lenguaje Natural y Procesamiento de Texto.
- Valderrama, P., Dominguez, B. & Aguilar, L., n.d. Criterios psicofisiológicos del cambio. *UNAM*.
- Warner, L. J. et al., 2006. Health Effects of Written Emotional Disclosure in Adolescents

- with Asthma: A Randomized, Controlled Trial. *Journal of Pediatric Psychology*, p. pp. 557–568.
- Xiang, X. et al., 2020. Modern Senicide in the Face of a Pandemic: An Examination of Public Discourse and Sentiment About Older Adults and COVID-19 Using Machine Learning. *J Gerontol B Psychol Sci Soc Sci*, pp. 190-200.
- XueI, J. et al., 2020. Public discourse and sentiment during the COVID 19 pandemic: Using Latent Dirichlet Allocation for topic modeling on Twitter. *PLoS ONE*, pp. 1-12.
- Yizhong Wang, S. L. H. W., 2017. *A Two-Stage Parsing Method for Text-Level Discourse Analysis*. Vancouver, Canadá, Association for Computational Linguistics <https://doi.org/10.18653/v1/P17-2029>, p. 184–188.
- Zangerle, E. et al., 2020. Overview of the Style Change Detection Task at PAN 2020. *CEUR Workshop Proceedings*, pp. 22-25.
- Zhang, B. et al., 2015. *Shallow Convolutional Neural Network for Implicit Discourse Relation Recognition*. Portugal, Association for Computational Linguistics, p. 2230–2235.

Anexos

Anexo 1 Listado de variables

Categorías	Variable	Descripción
Estadísticos	Total de palabras	Total de palabras en el texto
	Numero de oraciones	Número de oraciones en el texto
	PPO	Promedio de palabras por oración
	Riqueza lexica	Índice de riqueza léxica en el texto (MASS)
	Formas de palabra	Formas diferentes de palabras en el texto
	Legibilidad	Índice de legibilidad del texto (escala de lecturabilidad de Fernández Huerta)
Léxicos	p_ent_Familiar	Frecuencia de palabras del vocabulario de entorno familiar
	p_ent_Social	Frecuencia de palabras del vocabulario de entorno social
	p_ent_Laboral	Frecuencia de palabras del vocabulario de entorno laboral
	p_agr_Psicol	Frecuencia de palabras del vocabulario de agresión psicológica
	p_agr_Fis	Frecuencia de palabras del vocabulario de agresión física
	p_ent_Sex	Frecuencia de palabras del vocabulario agresión sexual
	al_Herramienta	Frecuencia de palabras que aluden a herramientas

Tabla 23 Lista de variables obtenidas (1/3)

Categorías	Variable	Descripción
Partes del discurso	porc_Ini	Porcentaje del texto que compone el inicio (partes del discurso)
	porc_Des	Porcentaje del texto que compone el desarrollo (partes del discurso)
	porc_Fin	Porcentaje del texto que compone la conclusión (partes del discurso)
Etiquetado gramatical	SPACE	Número de espacios en el texto
	INTJ	Número de interjecciones en el texto
	PRON	Número de pronombres en el texto
	VERB	Número de verbos en el texto
	NOUN	Número de sustantivos en el texto
	ADP	Adposición
	AUX	Número de auxiliares en el texto
	ADJ	Número de adjetivos en el texto
	ADV	Número de adverbios en el texto
	PUNCT	Número de signos de puntuación
	DET	Número de determinantes en el texto
	NUM	Numerales
	CCONJ	Conjunción coordinante
	SCONJ	Conjunción subcoordinante
	SYM	Símbolo
	PROPN	Nombre propio
PART	Partícula	
Posesivos	Cantidad de posesivos usados en el texto	

Tabla 24 Lista de variables obtenidas (2/3)

Categorías	Variable	Descripción
Conectores del discurso	Adicion	Conectores del discurso (Adicion)
	Causalidad	Conectores del discurso (Causalidad)
	Continuidad	Conectores del discurso (Continuidad)
	Epilogo	Conectores del discurso (Epilogo)
	Equivalencia	Conectores del discurso (Equivalencia)
	Inclusion	Conectores del discurso (Inclusion)
	Oposicion	Conectores del discurso (Oposicion)
	Orden	Conectores del discurso (Orden)
	Otro	Conectores del discurso (Otro)
	Topicalizacion	Conectores del discurso (Topicalizacion)
Léxico de opinión	Opinionpositiva	Frecuencia de palabras que expresan opinión positiva
	Opinionnegativa	Frecuencia de palabras que expresan opinión negativa
Léxico afectivo	Alegría	Frecuencia de palabras que expresan Alegría
	Enojo	Frecuencia de palabras que expresan Enojo
	Tristeza	Frecuencia de palabras que expresan Tristeza
	Sorpresa	Frecuencia de palabras que expresan Sorpresa
	Repulsión	Frecuencia de palabras que expresan Repulsión
	Miedo	Frecuencia de palabras que expresan Miedo
Léxico de reflexión	Frecuencia	Frecuencia de uso de palabras que indican actividad cognitiva

Tabla 25 Lista de variables obtenidas (3/3)

Anexo 2 Pruebas utilizando modelos de aprendizaje automático

Una de las primeras tareas desarrolladas durante el desarrollo de este trabajo fue la exploración de modelos de aprendizaje automático para modelar el fenómeno discursivo de los textos escritos con EEA. En este apartado se muestran los resultados obtenidos en esta etapa del trabajo

Los modelos seleccionados fueron Máquina de Soporte Vectorial, Random Forest, Redes Neuronales y Naive Bayes, de los cuales el modelo de Redes Neuronales fue el que arrojó mejores resultados. La Tabla 26 muestra el resumen de las métricas seleccionadas durante el estudio del estado del arte para la evaluación de los modelos.

Modelo	F1	Precision	Recall
SVM	0.5704	0.7906	0.5667
Random Forest	0.7329	0.7391	0.7333
Neural Network	0.8024	0.8105	0.8
Naive Bayes	0.4909	0.5292	0.5167

Tabla 26 Métricas de los modelos entrenados

Anexo 3 Formalización de reglas

En este apartado se muestra la formalización de las reglas utilizadas en el proceso de clasificación de textos.

```
**Regla 1 (Coherencia):**
```

```
IF: Coherencia es Nulo:
```

```
THEN: No sumar
```

```
IF: Coherencia es menor a 1:
```

```
THEN: sumar índice a Resultado["Analítico-emocional"]
```

```
IF: Coherencia es menor a 0.8:
```

```
THEN: sumar índice a Resultado["Analítico"]
```

```
IF: Coherencia es menor a 0.6:
```

```
THEN: sumar índice a Resultado["Emocional"]
```

```
IF: Coherencia es menor a 0.4:
```

```
THEN: sumar índice a Resultado["Descriptivo"]
```

```
IF: Coherencia es menor a 0.2:
```

```
THEN: sumar índice a Resultado["Evasivo"]
```

```
IF: Coherencia es menor a 0:
```

```
**Regla 2 (Legibilidad):**
```

```
IF: Legibilidad es Nulo:
```

```
THEN: No sumar
```

```
IF: Legibilidad es mayor a 0 y Legibilidad es menor o igual a 30:
```

```
THEN: sumar índice a Resultado["Evasivo", "Descriptivo", "Emocional", "Analítico-emocional"]
```

```
IF: Legibilidad es mayor a 30:
```

```
THEN: sumar índice a Resultado["Analítico"]
```

```
**Regla 3 (Vocabulario Reflexión):**
```

```
IF: Vocabulario Reflexión es Nulo:
```

```
THEN: No sumar

IF: Vocabulario Reflexión es mayor o igual a 0.020377326 y
Vocabulario Reflexión es menor o igual a 0.040377326:

THEN: sumar índice a Resultado["Evasivo"]

IF: Vocabulario Reflexión es mayor o igual a 0.035066469 y
Vocabulario Reflexión es menor o igual a 0.055066469:

THEN: sumar índice a Resultado["Emocional"]

IF: Vocabulario Reflexión es mayor a 0.036676121 y Vocabulario
Reflexión es menor o igual a 0.056676121:

THEN: sumar índice a Resultado["Analítico-emocional"]

IF: Vocabulario Reflexión es mayor o igual a 0.011954768 y
Vocabulario Reflexión es menor o igual a 0.031954768:

THEN: sumar índice a Resultado["Descriptivo"]

IF: Vocabulario Reflexión es mayor o igual a 0.008247463 y
Vocabulario Reflexión es menor a 0.028247463:

THEN: sumar índice a Resultado["Analítico"]

**Regla 4 (Vocabulario Alegría ponderado):**

IF: Vocabulario Alegría ponderado es Nulo:

THEN: No sumar

IF: Vocabulario Alegría ponderado es mayor o igual a
0.382915584 y Vocabulario Alegría ponderado es menor o igual a
0.582915584:

THEN: sumar índice a Resultado["Evasivo"]

IF: Vocabulario Alegría ponderado es mayor o igual a
0.470992063 y Vocabulario Alegría ponderado es menor o igual a
0.670992063:

THEN: sumar índice a Resultado["Emocional"]

IF: Vocabulario Alegría ponderado es mayor a 0.5549:

THEN: sumar índice a Resultado["Analítico-emocional"]

IF: Vocabulario Alegría ponderado es menor o igual a
0.47634375:

THEN: sumar índice a Resultado["Descriptivo"]

IF: Vocabulario Alegría ponderado es mayor o igual a
```

0.518666667 y Vocabulario Alegría ponderado es menor o igual a 0.718666667:

THEN: sumar índice a Resultado["Analítico"]

****Regla 5 (Conjunciones):****

IF: Conjunciones es Nulo:

THEN: No sumar

IF: Conjunciones es mayor o igual a 0 y Conjunciones es menor o igual a 4.857142857:

THEN: sumar índice a Resultado["Evasivo"]

IF: Conjunciones es mayor o igual a 8.333333333 y Conjunciones es menor o igual a 12.33333333:

THEN: sumar índice a Resultado["Emocional"]

IF: Conjunciones es mayor o igual a 4.5 y Conjunciones es menor o igual a 8.5:

THEN: sumar índice a Resultado["Analítico-emocional"]

IF: Conjunciones es mayor o igual a 7 y Conjunciones es menor o igual a 11:

THEN: sumar índice a Resultado["Descriptivo"]

IF: Conjunciones es mayor o igual a 3 y Conjunciones es menor o igual a 7:

THEN: sumar índice a Resultado["Analítico"]

****Regla 6 (Adjetivos):****

IF: Adjetivos es Nulo:

THEN: No sumar

IF: Adjetivos es mayor o igual a 4.285714286:

THEN: sumar índice a Resultado["Evasivo"]

IF: Adjetivos es mayor o igual a 10.666666667:

THEN: sumar índice a Resultado["Emocional"]

IF: Adjetivos es mayor o igual a 5.25 y Adjetivos es menor o igual a 7.25:

```
THEN: sumar índice a Resultado["Analítico-emocional"]

IF: Adjetivos es mayor o igual a 5.125 y Adjetivos es menor o
igual a 7.125:

THEN: sumar índice a Resultado["Descriptivo"]

IF: Adjetivos es mayor o igual a 8 y Adjetivos es menor o igual
a 10.6666666666:

THEN: sumar índice a Resultado["Analítico"]
```

****Regla 7 (Pronombres):****

```
IF: Pronombres es Nulo:

THEN: No sumar

IF: Pronombres es mayor o igual a 9.714285714:

THEN: sumar índice a Resultado["Evasivo"]

IF: Pronombres es mayor o igual a 21.77777778 y Pronombres es
menor o igual a 31.77777778:

THEN: sumar índice a Resultado["Emocional"]

IF: Pronombres es mayor o igual a 5.5 y Pronombres es menor o
igual a 15.9:

THEN: sumar índice a Resultado["Analítico-emocional"]

IF: Pronombres es mayor o igual a 16 y Pronombres es menor o
igual a 26.5:

THEN: sumar índice a Resultado["Descriptivo"]

IF: Pronombres es mayor o igual a 29:

THEN: sumar índice a Resultado["Analítico"]
```

****Regla 8 (Vocabulario Alegría):****

```
IF: Vocabulario Alegría es Nulo:

THEN: No sumar

IF: Vocabulario Alegría es mayor o igual a 1.928571429 y
Vocabulario Alegría es menor o igual a 2.928571429:

THEN: sumar índice a Resultado["Evasivo"]

IF: Vocabulario Alegría es mayor o igual a 4.388888889:
```

```
THEN: sumar índice a Resultado["Emocional"]

IF: Vocabulario Alegría es mayor o igual a 3 y Vocabulario
Alegría es menor o igual a 4:

THEN: sumar índice a Resultado["Analítico-emocional"]

IF: Vocabulario Alegría es mayor a 1.75:

THEN: sumar índice a Resultado["Descriptivo"]

IF: Vocabulario Alegría es mayor o igual a 2.5 y Vocabulario
Alegría es menor o igual a 3.5:

THEN: sumar índice a Resultado["Analítico"]
```

****Regla 9 (Sorpresa):****

```
IF: Sorpresa es Nulo:

THEN: No sumar

IF: Sorpresa es mayor o igual a 0.013571429 y Sorpresa es
menor o igual a 0.213571429:

THEN: sumar índice a Resultado["Evasivo"]

IF: Sorpresa es mayor o igual a 0.017777778 y Sorpresa es
menor o igual a 0.217777778:

THEN: sumar índice a Resultado["Emocional"]

IF: Sorpresa es mayor a 0.066:

THEN: sumar índice a Resultado["Analítico-emocional"]

IF: Sorpresa es mayor o igual a 0.15409375 y Sorpresa es
menor o igual a 0.35409375:

THEN: sumar índice a Resultado["Descriptivo"]

IF: Sorpresa es mayor o igual a 0.264:

THEN: sumar índice a Resultado["Analítico"]
```

****Regla 10 (Vocabulario Tristeza Ponderado):****

```
IF: Vocabulario Tristeza Ponderado es Nulo:

THEN: No sumar

IF: Vocabulario Tristeza Ponderado es mayor o igual a
0.188118812 y Vocabulario Tristeza Ponderado es menor o igual a
```

2.388118812:

THEN: sumar índice a Resultado["Evasivo"]

IF: Vocabulario Tristeza Ponderado es mayor o igual a 3.696369637:

THEN: sumar índice a Resultado["Emocional"]

IF: Vocabulario Tristeza Ponderado es menor o igual a 1.03960396:

THEN: sumar índice a Resultado["Analítico-emocional"]

IF: Vocabulario Tristeza Ponderado es mayor o igual a 1.079207921 y Vocabulario Tristeza Ponderado es menor o igual a 3.079207921:

THEN: sumar índice a Resultado["Descriptivo"]

IF: Vocabulario Tristeza Ponderado es mayor o igual a 2.388118813 y Vocabulario Tristeza Ponderado es menor o igual a 4.465346535:

THEN: sumar índice a Resultado["Analítico"]

Regla 11 (Adposiciones):

IF: Adposiciones es Nulo:

THEN: No sumar

IF: Adposiciones es mayor o igual a 9.257425743 y Adposiciones es menor o igual a 19.25742574:

THEN: sumar índice a Resultado["Evasivo"]

IF: Adposiciones es mayor o igual a 33.42134213:

THEN: sumar índice a Resultado["Emocional"]

IF: Adposiciones es menor o igual a 13.861386139:

THEN: sumar índice a Resultado["Analítico-emocional"]

IF: Adposiciones es mayor o igual a 20.2970297 y Adposiciones es menor o igual a 30.2970297:

THEN: sumar índice a Resultado["Descriptivo"]

IF: Adposiciones es mayor o igual a 26.18811881 y Adposiciones es menor o igual a 36.18811881:

THEN: sumar índice a Resultado["Analítico"]

****Regla 12 (Verbos):****

IF: Verbos es Nulo:

THEN: No sumar

IF: Verbos es menor o igual a 15.84158416:

THEN: sumar índice a Resultado["Evasivo"]

IF: Verbos es mayor o igual a 52:

THEN: sumar índice a Resultado["Emocional"]

IF: Verbos es mayor o igual a 15.83168317 y Verbos es menor o igual a 31.7:

THEN: sumar índice a Resultado["Analítico-emocional"]

IF: Verbos es mayor o igual a 31.8 y Verbos es menor o igual a 46.41089109:

THEN: sumar índice a Resultado["Descriptivo"]

IF: Verbos es mayor o igual a 39.35643564 y Verbos es menor a 52:

THEN: sumar índice a Resultado["Analítico"]

****Regla 13 (Total de palabras):****

IF: Total de palabras es Nulo:

THEN: No sumar

IF: Total de palabras es mayor o igual a 0 y Total de palabras es menor o igual a 102:

THEN: sumar índice a Resultado["Evasivo"]

IF: Total de palabras es mayor o igual a 192:

THEN: sumar índice a Resultado["Emocional"]

IF: Total de palabras es mayor o igual a 69 y Total de palabras es menor o igual a 129:

THEN: sumar índice a Resultado["Analítico-emocional"]

IF: Total de palabras es mayor o igual a 127.125 y Total de palabras es menor o igual a 187.125:

THEN: sumar índice a Resultado["Descriptivo"]

IF: Total de palabras es mayor o igual a 155 y Total de palabras es menor o igual a 215:

THEN: sumar índice a Resultado["Analítico"]

****Regla 14 (Uso de Vocabulario):****

IF: adjetivos es mayor a emociones:

THEN: sumar índice a Resultado["Descriptivo"]

IF: emociones es menor a reflexión:

THEN: sumar índice a Resultado["Emocional"]

IF: reflexión es mayor a opinión:

THEN: sumar índice a Resultado["Analítico"]

IF: opinión es mayor a adjetivo:

THEN: sumar índice a Resultado["Evasivo"]

IF: Valor absoluto de (emoción - reflexión) es menor a 0.5:

THEN: sumar índice a Resultado["Analítico-emocional"]