

Clasificación de opiniones provenientes de la web considerando el uso de información de tipo personal

Opinions's clasification from the web considering the using of personal information

C. A. Cázares-Pérez ^a, A. Franco-Árcega ^{a,*}, R. M. Ortega-Mendoza ^b, H. Castillejos-Fernández ^a, J. Suárez-Cansino ^a,
V. López-Morales ^a

^aÁrea Académica de Computación y Electrónica, Universidad Autónoma del Estado de Hidalgo, 42184, Pachuca, Hidalgo, México.

^bInvestigación y Posgrado, Universidad Politécnica de Tulancingo, 43629, Tulancingo de Bravo, Hidalgo, México.

Resumen

Los engaños han estado en la sociedad desde hace tiempo y han llegado a converger más, debido a las capacidades tecnológicas que actualmente tienen los dispositivos y el uso generalizado de la web que hacemos. Esta situación ha ocasionado muchos efectos negativos, como la *desinformación* entre usuarios, afectando la perspectiva o pensamiento ante actividades cotidianas. Recientemente, se han realizado diversas investigaciones se han propuesto para detectar engaños en publicaciones en línea. Este trabajo propone contemplar un elemento importante para apoyar la detección de engaños: explorar los pronombres personales en las publicaciones (u opiniones), ya que su uso tiende a mostrar honestidad entre las personas. La metodología propuesta separa las opiniones en oraciones que usan pronombres personales, para analizar su valor en la tarea. Se utilizan dos conjuntos de opiniones para evaluar la propuesta: *Op Spam* y *Amazon*. Los resultados son alentadores, dado que muestran que los pronombres personales son relevantes para identificar esta tarea.

Palabras Clave: Minería de datos, Detección de engaños, Procesamiento de lenguaje natural

Abstract

Deception has been in society since time ago, converging more nowadays due to the current technological capabilities of the devices and the widespread usage of the web. This situation has caused many adverse effects, such as misinformation between users, affecting society's perspective and thinking about daily activities. Recently, different researches have been proposed to detect the deception in online opinions. This work proposes an important element to face the automatic deception detection task: exploring personal pronouns in opinions (or reviews) because their use is related to honesty among the persons. The proposed methodology divides the opinions into sentences using personal pronouns to analyze their value for the task. Two benchmark datasets are used to evaluate the proposal and the deception detection degree: *Op Spam* and *Amazon*. The results are encouraged; they show that information stated in sentences with personal pronouns is relevant for the task.

Keywords: Data mining, Detection deception, Natural language processing

1. Introducción

Anteriormente, los instrumentos de comunicación eran diversos, y tenían sólo como objetivo transmitir información, tales como los teléfonos locales, el correo, telegramas, vídeo conferencias, etc. En la actualidad, todas esas vías de comunicación se pueden encontrar juntas, por ejemplo en los teléfonos inteligentes. Estos dispositivos se han vuelto indispensables y comunes, debido a que ofrecen la capacidad de procesamiento de

las computadoras que están en el hogar, además de la capacidad de movilidad y la accesibilidad para adquirir alguno. Por estas razones, han aparecido muchas herramientas de comunicación que puedan ser usadas en estos dispositivos, como las *Redes Sociales*, las cuales son de acceso gratuito y permiten generar círculos sociales, agrupando personas con características en común, como parentesco, trabajo, pasatiempos, gustos, etc. Debido a las herramientas de comunicación que están apareciendo,

*Autor para correspondencia: afranco@uaeh.edu.mx

Correo electrónico: carlos.cazares.89@gmail.com(Carlos Andrés Cázares-Pérez), afranco@uaeh.edu.mx(Anilú Franco-Árcega), rosa.ortega@upt.edu.mx(Rosa María Ortega-Mendoza), heydy_castillejos@uaeh.edu.mx(Heydy Castillejos-Fernández), jsuarez@uaeh.edu.mx(Joel Suárez-Cansino), virgilio@uaeh.edu.mx(Virgilio López-Morales)

cualquier persona puede tener acceso a la información y conocimiento, tales como noticias, artículos, recomendaciones, etc. Sin embargo, a causa de que hay muchas facilidades en la consulta de información, surgen ciertos enigmas: ¿La información que se divulga es fidedigna? y ¿Quiénes son los encargados de determinarlo? Al principio se pensaría que la información que se encuentra es 100% confiable, sin embargo en distintos medios se ha encontrado que lo que se comparte es engañoso (Ahmed et al., 2018). Un ejemplo muy sonado fue el esparcimiento de *Noticias Falsas* o *Fake News* durante las elecciones presidenciales de Estados Unidos de Norte América del año 2016, donde las principales vías de comunicación fueron las redes sociales de Facebook y Twitter (Krishnamurthy et al., 2018), pero este tipo de situaciones no sólo logra afectar en el aspecto política, si no también puede llegar a perjudicar la integridad de una persona, como el caso de un suicidio generado por divulgar información falsa (Fuller et al., 2011). El engaño y la mentira a menudo son confundidos como sinónimos, no obstante estos están relacionados. La mentira se puede definir como un *estado falso* (Holland and Quinn, 1995), mientras que el engaño *es el acto que trata de fomentar a alguien en creer algo que es falso* (Zuckerman et al., 1981; Rill García et al., 2019). Un engaño ocurre cuando el que comunica tiende a manipular la información que contienen sus mensajes, con el fin de transmitir un mensaje apartado de la verdad (Buller and Burgoon, 1996). Para resolver el caso de identificación de engaños, se han realizado varios estudios, algunos desde el enfoque psicosocial, donde se ha tratado de determinar si un engaño está presente o no en algún texto (Fuller et al., 2011; G., 2007), y otros desde un enfoque computacional, donde se estudia el contenido de publicaciones en redes sociales (Altunbey Ozbay and Alatas, 2020; Cabrejas et al., 2019; Mbaziira and Jones, 2016), algunos más considerando un enfoque lingüístico, donde se extrae el contenido y se analiza con ciertos patrones que pueden tener los mensajes engañosos (Song et al., 2005; Sánchez Junquera et al., 2017; Rill García et al., 2019). Este trabajo tiene el objetivo de proponer una metodología que permita llevar a cabo la detección de engaños. Esta metodología permite integrar conocimiento de dos áreas importantes. Por un lado, la *Minería de Datos (MD)* la cual permite analizar grandes cantidades de datos y que ha sido usada para detectar actividades delictivas cómo: violaciones de tráfico, crimen sexual, robo, fraude, daños a inmuebles, narcóticos, crímenes de violencia y ciber delincuencia (Fuller et al., 2011; Wanumen Silva, 2010; Ruiz, 2006). Por otro lado, el *Procesamiento de Lenguaje Natural (PLN)*, permite realizar un análisis de textos para identificar características léxicas y sintácticas. tal como dice Gelbukh (Gelbukh, 2010), el *PLN* es una disciplina que estudia la habilidad que tiene la máquina para procesar la información comunicada, no solo en letras, sino también en los sonidos del lenguaje. Adicional a lo anterior, estudios recientes demuestran que el uso de pronombres personales en tareas relacionadas al *PLN* obtiene buenos resultados, tal es el caso de la tarea de Identificación del perfil de autores y en detección de depresión (Ortega Mendoza et al., 2007, 2018, 2022). En estos trabajos se ha observado que tomar en cuenta estos elementos del lenguaje permite obtener buenos resultados de clasificación, dado que los pronombres personales en los textos suelen referir a la personalidad de quien escribe.

2. Metodología

Se propone una metodología que permite la identificación de publicaciones engañosas en medios sociales mediante una perspectiva de clasificación de textos, donde se tienen dos clases: positiva y negativa, representando un mensaje con engaño y sin engaño, respectivamente. El proceso general que se lleva a cabo se muestra en la Figura 1. Se inicia con la lectura de alguna colección de documentos. Estos mensajes reciben un preprocesamiento, para crear una representación estructurada que alimentará algoritmos de aprendizaje automático. Este procesamiento consiste en la separación de los términos que componen a los mensajes, para proceder a la construcción del vocabulario de datos. Una vez que se haya realizado esta identificación, cada término en cada mensaje será representado por una estrategia de pesado de términos. Dado que en este tipo de problemáticas existe siempre una alta dimensionalidad, por la gran cantidad de elementos que se pueden encontrar en los mensajes, el siguiente paso es realizar una selección de términos. Por esta razón, es necesario llevar a cabo esta selección. Posterior a este paso se aplicarán diversos algoritmos de clasificación supervisada, los cuales permitirán crear modelos de clasificación y por lo tanto, identificar el tipo de mensaje que se introduzca en el modelo.

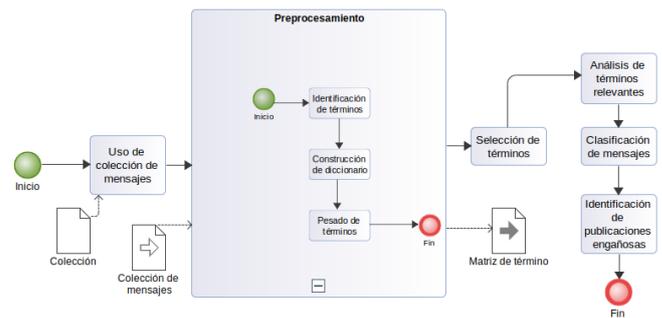


Figura 1: Proceso general para la clasificación.

3. Construcción del vocabulario

Para realizar la creación del vocabulario de términos que permitirán representar a los mensajes a procesar, se ha planteado un preprocesamiento que incluye cinco fases: (i) tokenización y transformación de palabras a minúsculas, (ii) retiro de símbolos y puntuaciones, (iii) retiro de palabras repetidas, (iv) retiro de stopwords y (v) aplicación del proceso de stemming. Considerando estos procesos y para poder analizar la identificación de publicaciones engañosas, se propone la creación de diferentes vocabularios de datos. Estos fueron creados considerando las siguientes especificaciones:

- Vocabulario *ALL*: Se usan todos los términos encontrados en la identificación de palabras usadas en las opiniones.
- Vocabulario *STW*: Se retiran términos considerados como palabras vacías (conocidos como stopwords) las cuales no tienen un significado importante en el contexto de la opinión.

- Vocabulario *STE*: Se aplica el proceso de stemming, en donde se considera la reducción de términos que comparten raíz gramatical.
- Vocabulario *STESTW*: Se retiran los stopwords y se aplica el proceso de stemming.

4. Uso de pronombres personales

El uso de pronombres personales, puede ser una característica que pueda definir los engaños escritos, ya que se omiten por que el autor no quiere relacionarse (Zuckerman et al., 1981), sin embargo se han encontrado el uso de pronombres para hacer más creíbles (Fuller et al., 2014), ya que el uso de pronombres personales tiende hacia la honestidad (Newman et al., 2003). Para determinar si el uso de pronombres personales ayuda en la tarea de detección de publicaciones engañosas, se propone identificar la aparición de este tipo de términos en las publicaciones a procesar. Para este trabajo, se tomarán en cuenta tanto los pronombres personales en su forma singular como en su forma plural, aquellos considerados para esta revisión son:

- Singulares: “I”, “me”, “mine”, “my”, “myself”, “im” y “I’m”
- Plurales: “we”, “us”, “our”, “ours”, “ourselves”

Se propone que la identificación de estos términos se realice de manera independiente. En cada opinión del conjunto de datos, se realiza la búsqueda de la existencia de alguno de los pronombres y si se encuentra, la opinión es separada por oraciones. Este proceso implica que la opinión resultará en dos fragmentos de texto. El primero será aquel que contenga las oraciones en donde los pronombres están presentes, y el segundo, aquel que sólo integre oraciones sin pronombres. Un ejemplo de esta separación sería de la siguiente forma:

Resultado:

- Opinión con pronombres: *In January, I was looking for a spot for quiet leisure and relaxation. My choice turned out to be a 100 % hit. I had a great rest!*
- Opinión sin pronombres: *A wonderful neighbourhood. Amazing hotel conditions, perfect cuisine and very nice staff.*

El proceso de separación propuesto se puede visualizar en el diagrama de la Figura 2, donde se puede observar la forma en cómo se obtienen los dos conjuntos de datos diferentes a partir de uno solo, los cuales serán procesados de manera independiente.

5. Conjunto de datos: *Op Spammy Amazon*

Se utilizaron dos conjuntos de opiniones para observar el comportamiento de la propuesta realizada en este trabajo, los cuales son mostrados en la Tabla 1. El primer conjunto está

constituido por opiniones hacia hoteles y se denomina *Op Spam* (Ott et al., 2013), el cual está compuesto de 800 opiniones falsas (clase F) y 800 opiniones verdaderas (clase V), por lo que se aprecia un balance entre las dos clases. La construcción de este conjunto de datos obtuvo las opiniones falsas a través de la plataforma *Amazon Mechanical Turk*, diseñada por Amazon. Para obtener las opiniones verdaderas se empleó un proceso más sencillo, ya que se obtuvieron a través de distintas fuentes, entre las que destacan *Expedia*, *Hotels.com*, *Orbitz*, *Priceline*, *TripAdvisor* y *Yelp*, plataformas cuya función es evaluar por medio de opiniones de distintos usuarios todo lo relacionado al tema turístico. El segundo conjunto de datos utilizado es *Amazon*, el cual fue obtenido de un repositorio público de *Github*². Está construido por opiniones de usuarios hacia los productos que ofrece Amazon. El conjunto de datos está compuesto de 21,000 opiniones de productos, de manera que se desconoce la cantidad de opiniones verdaderas y falsas que hay, por ello, se toman aleatoriamente 1,000 opiniones verdaderas y 1,000 opiniones falsas, haciendo un conjunto balanceado.

Tabla 1: Conjuntos de datos empleados en la experimentación.

Conjunto	Opiniones totales	Opiniones Verdaderas	Opiniones Falsas
<i>Op-Spam</i>	1600	800	800
<i>Amazon</i>	2000	1000	1000

6. Configuración

Los conjuntos de datos son procesados por la metodología mencionada. Se construyen los cuatro vocabularios correspondientes (*ALL*, *STW*, *STE*, *STESTW*), para que posteriormente se aplique el pesado de términos, usando el método *TF*.

$$TF = \frac{n_{ij}}{|d_i|}, \quad (1)$$

donde $|d_i|$ es la suma de todos los pesos de los términos en el documento i y n_{ij} es el número de veces que aparece la palabra j en el documento i .

Al obtener las matrices de cada uno de los vocabularios, se les aplicarán distintos métodos de selección de atributos, con la finalidad de reducir la dimensionalidad de los conjuntos, en cuestión de términos. Los selectores que se aplicaron fueron *Ganancia de Información (Info Gain)*, *Proporción de Ganancia de Información (Gain Ratio)* y *Selección de Subconjuntos de Características basada en Correlación (CfsSubsetEval)*. Para realizar la clasificación de las opiniones se aplicaron cuatro clasificadores, empleando la herramienta Weka: *Naive Bayes (NB)*, Máquinas de vectores de soporte usando el algoritmo *Lib Linear (LL)*, *Random Forest (RF)* y *Naive Bayes Multinomial Updateable (NBMU)* utilizando una validación cruzada de 10 pliegues. La métrica reportada y considerada en estos resultados es *F-Measure* o *F-1 score*, la cual involucra las medidas de *Precision* y *Recall*. La primera parte de la sección de experimentación ayudó a detectar cuál es la mejor configuración

²<https://github.com/aayush210789/Deception-Detection-on-Amazon-reviews-dataset>

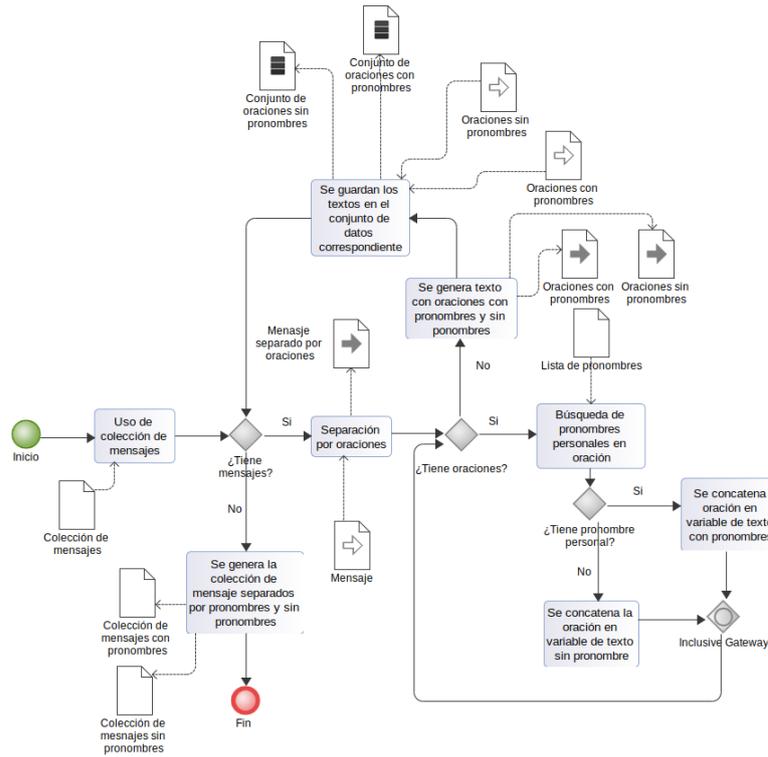


Figura 2: Proceso de búsqueda de pronombres personales por oraciones.

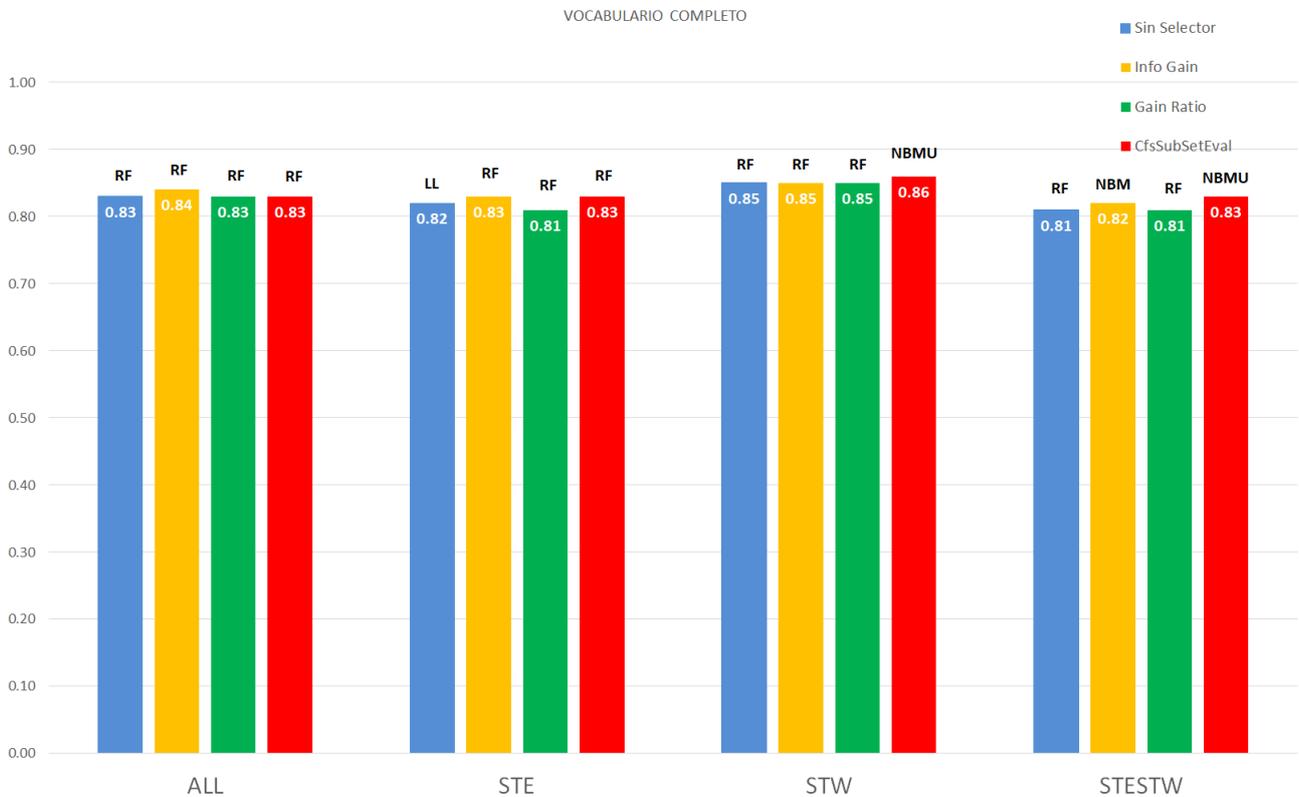


Figura 3: Resultados de cada estrategia con el vocabulario completo para *Op Spam*

Tabla 5: Resultados de los conjuntos de datos *Op Spam* y *Amazon*, con y sin pronombres personales del singular, aplicando el clasificador Random Forest y el selector Proporción de Ganancia Información con la métrica F-Measure.

Vocabulario	Pronombres Personales del Singular						Sin Pronombres Personales del Singular					
	<i>Op Spam</i>			<i>Amazon</i>			<i>Op Spam</i>			<i>Amazon</i>		
	V	F	G	V	F	G	V	F	G	V	F	G
<i>ALL</i>	.69	.76	.72	.61	.57	.59	.79	.79	.79	.68	.37	.53
<i>STE</i>	.69	.76	.73	.62	.56	.59	.79	.79	.79	.68	.35	.52
<i>STW</i>	.72	.77	.74	.68	.47	.57	.79	.79	.79	.68	.36	.53
<i>STESTW</i>	.69	.76	.72	.49	.69	.59	.79	.80	.80	.69	.31	.50

Tabla 6: Estadísticas con pronombres personales del singular con los conjuntos *Op Spam (O.S.)* y *Amazon (A)*

	Máx. de palabras		Mín. de palabras		Prom. de palabras		Máx. de oraciones		Mín. de oraciones		Prom. de oraciones	
	<i>O.S.</i>	<i>A.</i>	<i>O.S.</i>	<i>A.</i>	<i>O.S.</i>	<i>A.</i>	<i>O.S.</i>	<i>A.</i>	<i>O.S.</i>	<i>A.</i>	<i>O.S.</i>	<i>A.</i>
	Opiniones completas	784	1612	25	5	147.27	62.01	58	97	1	1	9.53
Oraciones con primera persona singulares	519	903	4	2	77.02	44.84	28	40	1	1	4.16	2.41
Oraciones sin primera persona singulares	468	1183	1	1	85	30.62	30	57	1	1	6.11	2.62

Tabla 7: Resultados de los conjuntos de datos *Op Spam* y *Amazon*, con y sin pronombres personales del singular + plural, aplicando el clasificador Random Forest y el selector Proporción de Ganancia Información con la métrica F-Measure

Vocabulario	Pronombres Personales del Singular + Plural						Sin Pronombres Personales del Singular + Plural					
	<i>Op Spam</i>			<i>Amazon</i>			<i>Op Spam</i>			<i>Amazon</i>		
	V	F	G	V	F	G	V	F	G	V	F	G
<i>ALL</i>	.76	.77	.76	.55	.59	.57	.74	.75	.74	.68	.37	.53
<i>STE</i>	.77	.77	.77	.57	.57	.57	.74	.75	.74	.69	.31	.50
<i>STW</i>	.76	.77	.76	.65	.49	.57	.75	.75	.75	.69	.29	.50
<i>STESTW</i>	.77	.78	.77	.48	.68	.58	.75	.74	.75	.69	.29	.50

Tabla 8: Estadísticas con pronombres personales del singular y plural con los conjuntos *Op Spam (O.S.)* y *Amazon (A.)*.

	Máx. de palabras		Mín. de palabras		Prom. de palabras		Máx. de oraciones		Mín. de oraciones		Prom. de oraciones	
	O.S.	A.	O.S.	A.	O.S.	A.	O.S.	A.	O.S.	A.	O.S.	A.
Opiniones completas	784	1612	25	5	147.27	62.01	58	97	1	1	9.53	4.1
Oraciones con primera persona singulares + plurales	642	976	4	2	103.06	45.65	30	46	1	1	5.69	2.47
Oraciones sin primera persona singulares + plurales	389	1121	1	1	52.03	28.87	28	54	1	1	4.4	2.53

está experimentando, mientras que las que no contienen pronombres, tienden a relacionarse a cuestiones interpersonales, es decir todo lo que se involucre en cuestión de espacio e interacciones. Como trabajo futuro, se plantea explorar estas observaciones con el fin de mejorar la detección de engaños.

Referencias

- Ahmed, H., Traore, I., and Saad, S. (2018). Detecting opinion spams and fake news using text classification. *Security and Privacy*, 1(1):e9.
- Altunbey Ozbay, F. and Alatas, B. (2020). Fake news detection within online social media using supervised artificial intelligence algorithms. *Physica A: Statistical Mechanics and its Applications*.
- Buller, D. B. and Burgoon, J. K. (1996). Interpersonal deception theory. *Communication Theory*, pages 203–242.
- Cabrejas, C., Martí, J. V., Pajares, A., and V., S. (2019). Deception detection in arabic texts using n-grams text mining. In *FIRE (Working Notes)*.
- Fuller, M. C., Biros, P. D., and Delen, D. (2011). An investigation of data and text mining methods for real world deception detection. *Expert Systems with Applications*, 38:8392–8398.
- Fuller, M. C., Biros, P. D., and Delen, D. (2014). Automated deception detection of 911 call transcripts. *Security informatics*, 8(7).
- G., D. B. (2007). Deception detection expertise. *American Psychology-Law Society*, pages 339–351.
- Gelbukh, A. (2010). Procesamiento de lenguaje natural y sus aplicaciones. *komputer. Pattern recognition and information forensics*, pages 6–11.
- Holland, D. and Quinn, N. (1995). *Cultural models in language and thought*. Cambridge University Press.
- Krishnamurthy, G., Majumder, N., Poria, S., and Cambria, E. (2018). A deep learning approach form multimodal deception detection. *arXiv preprint arXiv:1803.00344*.
- Mbaziira, A. and Jones, J. (2016). A text-based deception detection model for cybercrime. In *Int. Conf. Technol. Manag.*, pages 1–8.
- Newman, L. M., Pennebaker, J. W., Berry, D. S., and Richards, J. M. (2003). Lying words: Predicting deception from linguistic styles. *PSPB*, 29.
- Ortega Mendoza, R. M., Hernández Fariás, D. I., Montes y Gómez, M., and Villaseñor Pineda, L. (2022). Revealing traces of depression through personal statements analysis in social media. *Artificial Intelligence in Medicine*, 123:102202.
- Ortega Mendoza, R. M., López Monroy, A. P., Franco Arcega, A., and Montes y Gómez, M. (2018). Peimex at erisk2018: Emphasizing personal information for depression and anorexia detection. In *CLEF (Working Notes)*.
- Ortega Mendoza, R. M., Villaseñor Pineda, L., and Montes y Gómez, M. (2007). Using lexical patterns for extracting hyponyms from the web. In *Mexican International Conference on Artificial Intelligence*, pages 904–911. Springer.
- Ott, M., Cardie, C., and Hancock, J. (2013). Negative deceptive opinion spam. *NAACL HLT 2013 - 2013 Conference of the North American chapter of the association for computational linguistics: Human language technologies, proceedings of the main conference*, pages 497–501.
- Rill García, R., Villaseñor Pineda, L., Reyes Meza, V., and Escalante, H. (2019). From text to speech: A multimodal cross-domain approach for deception detection. *Lecture notes in computer science (including subseries lecture notes in artificial intelligence and lecture notes in bioinformatics)*, pages 164–177.
- Ruiz, W. (2006). Técnicas de minería de datos aplicadas en la detección de fraude. pages 1–9.
- Sánchez Junquera, J., Villaseñor Pineda, L., Escalante, H., Montes, and Gómez, M. (2017). Detección del engaño en notas de opinión a través de técnicas tradicionales de clasificación automática de textos. *Res. Comput. Sci.*, 134:141–150.
- Song, F., Liu, S., and Yang, J. (2005). A comparative study on text representation schemes in text categorization. *Pattern analysis and applications*, 8:199–209.
- Wanumen Silva, L. F. (2010). Minería de datos para la predicción de fraudes en tarjetas de crédito. pages 44–57.
- Zuckerman, M., DePaulo, B. M., and Rosenthal, R. (1981). Verbal and non verbal communication of deception. *Advances in experimental social psychology*, 14.