

Tabla de Contenido

Índice de Tablas	ix
Índice de Ilustraciones	x
1. Introducción	1
1.1. Antecedentes generales	1
1.1.1. Caracterización del problema	2
1.1.2. Justificación de este trabajo	2
1.2. Objetivos	3
1.2.1. Obejtivo general	3
1.2.2. Objetivos específicos	3
1.3. Hipótesis del trabajo	4
1.4. Metodología	4
1.4.1. CRISP-DM	5
1.5. Resultados esperados	6
1.6. Alcance	7
1.7. Estructura del documento	7
2. Comprensión del delito, el actuar criminal y su aprehensión	9
2.1. Interpretación económica del delito	9
2.2. La criminología y el comportamiento antisocial	10
2.2.1. Triángulo del delito	12
2.3. Interpretación jurídica del delito y su castigo	13
2.3.1. La importancia de la pena y su función	13
2.4. La vinculación criminal y el uso de la tecnología	14
2.4.1. Modelos de vinculación criminal	15
3. Modelos y conceptos de text mining	16
3.1. Conceptos básicos	16
3.1.1. Preprocesamiento de texto	16
3.1.2. Term-Document Matrix	17
3.1.3. Neural Networks	17
3.1.4. Deep Learning	19
3.2. Recuperación de documentos	21
3.2.1. Latent Semantic Indexing	22
3.3. Word embeddings	24
3.3.1. Word2Vec	24

3.3.2. GloVe	26
3.3.3. FastText	28
3.3.4. Comparación Word Embeddings	30
3.4. Modelos de similitud semántica textual	30
3.4.1. Doc2Vec	30
3.4.2. Word Mover's Distance	32
3.4.3. WMD vs Doc2vec	33
3.5. Latent Dirichlet Allocation	33
3.6. Métricas de desempeño	34
3.6.1. Similitud Coseno	34
3.6.2. Precision	35
3.6.3. Recall	36
3.6.4. F1-Measure	36
3.6.5. Perplexity	36
3.6.6. Topic Coherence	37
4. Desarrollo metodológico	38
4.1. Entendimiento del contexto	38
4.1.1. Estadísticas	40
4.2. Comprensión los datos	40
4.2.1. Registro de robos en lugar habitado Macrozona San Antonio	41
4.2.2. Foco de investigación Fiscalía Local San Antonio	42
4.2.3. Discusión	45
4.3. Preparación de los datos	45
4.4. Modelamiento	45
4.4.1. Recuperación de documentos	47
4.4.2. Computo de similitud semántica textual	48
4.4.3. Implementación Word Mover's Distance	48
4.4.4. Implementación Word embeddings	48
4.4.5. Implementación Doc2Vec	49
4.4.6. Implementación Latent Dirichlet Allocation	49
4.5. Evaluación de resultados	50
4.5.1. Implementación de visualizaciones y resumen de contenido	50
4.5.2. Representación de los documentos a través de grafos	50
4.5.3. Tablas de resumen de contenido	51
4.5.4. Implementación de una visualización interactiva para tópicos	51
4.5.5. Juicio de expertos	52
5. Resultados	54
5.1. Asociación de causas por similitud semántica textual	55
5.1.1. Análisis exploratorio de los datos	55
5.1.2. Elección de los términos de búsqueda	57
5.1.3. Recuperación de documentos	58
5.1.4. Computo de similitud semántica textual: Word Mover's Distance	60
5.1.5. Computo de similitud semántica textual: Doc2Vec	60
5.1.6. Interpretación de los resultados	63
5.2. Seguimiento del Foco de Investigación	70

5.2.1. Selección de la muestra	70
5.2.2. Resultados del seguimiento al Foco de Investigación	71
5.2.3. Visualización de los resultados	71
6. Conclusiones	74
6.1. Recomendaciones para trabajos futuros	75
Bibliografía	77
Anexos	82