

Minería de textos en la red social Twitter

Índice de contenidos

| | |
|--|------------|
| AGRADECIMIENTOS | III |
| RESUMEN | V |
| 1 INTRODUCCIÓN..... | 1 |
| 1.1 MOTIVACIÓN | 1 |
| 1.2 OBJETIVOS | 2 |
| 1.3 LÍMITES DE LA TESIS | 3 |
| 1.4 VISTA GENERAL DE LA TESIS | 4 |
| 2 PANORAMA GENERAL..... | 7 |
| 2.1 MINERÍA DE TEXTOS..... | 7 |
| 2.2 MINERÍA WEB | 7 |
| 2.3 REDES SOCIALES..... | 8 |
| 2.4 ACERCA DE TWITTER..... | 9 |
| 3 MODELO DE ESPACIOS VECTORIALES | 13 |
| 3.1 CONSTRUCCIÓN | 14 |
| 3.2 PESO LOCAL..... | 14 |
| 3.2.1 Binaria..... | 15 |
| 3.2.2 Frecuencia del término..... | 15 |
| 3.2.3 Frecuencia aumentada de términos normalizados | 15 |
| 3.2.4 Logarítmico | 16 |
| 3.3 PESO GLOBAL..... | 16 |
| 3.3.1 Sin cambios | 17 |
| 3.3.2 Frecuencia inversa de documentos (IDF) | 17 |
| 3.3.3 Otros esquemas IDF..... | 17 |
| 3.3.4 Entropía normalizada | 18 |
| 3.4 NORMALIZACIÓN | 18 |
| 3.4.1 Sin cambios | 19 |
| 3.4.2 Normalización de coseno | 19 |
| 3.4.3 Otros esquemas de normalización de coseno..... | 19 |
| 3.4.4 Normalización del peso máximo..... | 19 |
| 3.4.5 Normalización de pivote único | 19 |
| 3.5 MÉTODOS MÁS UTILIZADOS..... | 20 |

| | | |
|----------|---|-----------|
| 4 | ANÁLISIS DE GRUPOS (CLUSTERING) | 21 |
| 4.1 | DISTANCIAS Y SIMILITUDES..... | 21 |
| 4.1.1 | Distancias para variables continuas | 23 |
| 4.1.2 | Similitudes para variables binarias | 24 |
| 4.2 | MÉTODOS JERÁRQUICOS..... | 26 |
| 4.2.1 | Dendograma y jerarquía indexada | 26 |
| 4.2.2 | Método del mínimo..... | 27 |
| 5 | APLICACIONES EMPRESARIALES CON TECNOLOGÍA JAVA EE..... | 31 |
| 5.1 | INTRODUCCIÓN A LA TECNOLOGÍA JAVA EE..... | 33 |
| 5.1.1 | Arquitectura | 33 |
| 5.1.2 | Componentes de aplicación | 35 |
| 5.1.3 | Los API de Java EE | 36 |
| 5.1.4 | Tecnologías de comunicación..... | 38 |
| 5.1.5 | ¿Java EE para cualquier aplicación?..... | 39 |
| 6 | IMPLEMENTACIÓN Y RESULTADOS..... | 40 |
| 6.1 | PRESENTACIÓN GENERAL DEL SISTEMA | 40 |
| 6.2 | OBTENCIÓN DE LOS GORJEOS Y PREPROCESAMIENTO | 41 |
| 6.2.1 | Obtención de gorjeos | 42 |
| 6.2.2 | Preprocesamiento | 43 |
| 6.2.3 | Clasificación..... | 44 |
| 6.3 | PROCESAMIENTO DE LOS GORJEOS | 45 |
| 6.3.1 | Construcción del espacio vectorial | 45 |
| 6.3.2 | Cálculo de la energía textual | 46 |
| 6.3.3 | Agrupamiento de gorjeos | 48 |
| 6.4 | PRESENTACIÓN DE DATOS | 50 |
| 6.5 | CONTROL DE CRECIMIENTO | 55 |
| 7 | ANÁLISIS DE RESULTADOS..... | 56 |
| 8 | CONCLUSIONES Y TRABAJO FUTURO | 66 |
| 9 | REFERENCIAS..... | 69 |
| | APÉNDICE A | 71 |
| | APÉNDICE B..... | 72 |
| | APÉNDICE C | 73 |

Índice de Diagramas

| | |
|--|----|
| Figura 1 – Matriz documento-termino simple | 14 |
| Figura 2 – Dendograma correspondiente al ejemplo del vecino más próximo..... | 30 |
| Figura 3 – Arquitectura de Java EE | 34 |
| Figura 4 – Arquitectura del sistema propuesto | 40 |
| Figura 5 – Ejemplo de gorjeos | 42 |
| Figura 6 – Resultado de aplicar las transformaciones a los gorjeos | 44 |
| Figura 7 – Palabras tomadas en cuenta para el espacio vectorial | 45 |
| Figura 8 – Grupos generados para gorjeos de ejemplo..... | 49 |
| Figura 9 – Página de inicio | 51 |
| Figura 10 – Presentación de datos para el tema <i>Homicidios</i> | 52 |
| Figura 11 – Continuación de presentación de datos para el tema <i>Homicidios</i> | 53 |
| Figura 12 – Presentación de gorjeo original | 53 |
| Figura 13 – Presentación de gorjeo procesado..... | 54 |
| Figura 14 – Presentación de gorjeo vectorizado | 54 |
| Figura 15 – Resultados de los agrupamientos para los temas Tráfico, Homicidios y Asaltos | 62 |
| Figura 16 – Ejemplo del cálculo de una matriz cofenética. | 64 |

Índice de Tablas

| | |
|--|----|
| Tabla 1 – Fórmulas de pesos locales..... | 15 |
| Tabla 2 – Fórmulas de pesos globales | 16 |
| Tabla 3 – Fórmulas de normalización..... | 18 |
| Tabla 4 – Recuento de las coincidencias de n variables binarias definidas para dos casos i y j con $n = a+b+c+d$ | 25 |
| Tabla 5 – Espacio vectorial para el ejemplo de 5 gorjeos..... | 46 |
| Tabla 6 – Temas y gorjeos recuperados para el análisis..... | 56 |
| Tabla 7 – Resultados de coeficiente de correlación cofenético para los términos tráfico, homicidios y asaltos..... | 65 |