

SENTIMENT ANALYSIS & CRAWLING CON SOFTWARE LIBRE

Christian López - [@christianlrcalo](https://twitter.com/christianlrcalo) - info@christianlr.es



//Codery_

SOBRE CHRISTIAN

- Ingeniero Informático - USC
- Master of Applied Data Science - Michigan University
- Desarrollador Drupal en [Codery_](#) desde 2017
- Devops - SysAdmin



CONTEXTO/ORIGEN PROYECTO

"Tenemos que montar algo para recuperar datos de las redes y que lo vean..."

... y tenemos sobre un mes!



BUENO, VAMOH A ELLO!

PRIMEROS PASOS

- Análisis - Diseño - Desarrollo - Pruebas => NOP!
- Java - Php - Python? => Python - [Tweepy](#)
- Facebook - Twitter - Instagram? => Twitter
- SQL - NoSQL? => PostgreSQL
- Entrega? => PgAdmin con consultas pre-cargadas

FASE1 - PRIMERA ENTREGA

Crawler de datos (cuenta gratuita - límites)

Relación Tweet - Usuario

Búsqueda según hashtags y palabras clave (crontab)

Acceso a PgAdmin con consultas precargadas

FEEDBACK?



Quiero más!

Y podemos?, y podemos?, y si?

FASE2 - MÁS DIMENSIONES

Geolocalización de los datos

Datos macro y socioeconómicos

Datos meteorológicos

Datos de género

Configuración de búsqueda dinámica

Diferentes grupos de búsqueda

GIPD (Gráficas - Informes - Pdfs y Dashboard)



VENGA CHAO!

PROBLEMAS

- Ejecución estática con crontab
- Servidor por grupo de búsqueda => gestión de recursos (APIs)
- Relación/fusión de datos de todas las dimensiones
- Actualización versiones Tweepy - Api Twitter
- Generador informes + estadísticas + API + Dashboard
- Búsqueda/análisis de servicios (ubicación, geo, etc...)

ENTREGA/SOLUCIÓN

Geolocalización -> [locationIQ](#)

Datos macro -> La propia entidad

Meteorología -> [weatherapi](#)

Género -> [genderApi.io](#)

Búsqueda dinámicas -> ficheros yaml

Grupos de búsqueda -> varias máquinas (de 1 a 4)

Aumento sustancia de datos -> Sistema interno de
generación de estadísticas

GIPD (Gráficas - Informes - Pdfs y Dashboard) ->

Wkhtmltopdf + VueJs + PHP + SlimAPI



101894730

TWEETS

29038

AVERAGE LAST WEEK



18042650

USERS

8839

AVERAGE LAST WEEK



22462455


GENDERS

201

AVERAGE LAST WEEK


% of languages

% of top3 languages stored



% of genders

% of genders stored



Languages

0

User places

12510135

Keywords


18

Hashtags

27


Top 10 user places

Top 10 of tweets by user location



Top 10 tweet places

Top 10 of tweets by tweet location



FASE3 - SENTIMENTANALYSIS

"Quiero saber el sentimiento o preocupación sobre un
X en este dataset"

Si puede ser tanto en inglés como en español

Y además, si puede ser, dividido en regiones/países

Y claro está, envíame todas las dimensiones

Tenéis 1 mes!, como mucho mes y medio que tenemos
que publicar el estudio



NOOP!, ESTA VEZ NOP!

NO!, PORQUÉ?

- No hay nada formateado/limpio
- Máquinas de crawler sin conexión entre ellas
- Desconocimiento de los datos actuales. Las estadísticas son básicas
- Gran dispersidad de datos (culturas, idiomas, contextos, etc...)
- Diccionarios/corpus orientados a felicidad (+/-)

ENTREGA

- Reunificación de todas las máquinas en una sola
- Reorganización de las ddbb a una misma
- Reconfiguración de los accesos a Twitter y métodos de búsqueda
- Limpieza de datos duplicados (ubicación, género, etc..)
- Mejora del generador de estadísticas

- Restricción de países a los que tengan más información
- Restricción a 2 idiomas. ES/EN
- Necesidad de Traducir ES a EN. [OpenNMT](#)
- Reorientación de preocupación hacia felicidad por preocupación
- Apoyar el proceso mediante datos estadísticos

ENTREGA TÉCNICA

PostgreSQL de + 300GB (800M registros)

Creación de índices y varias vistas

Automatización en las estadísticas con
systemD/servicios

Instalación de [Jupyter Notebook](#)

MODELOS/LEXICONS DE SENTIMENT ANALYSIS

VADER

LabMT

Afinn

Data: 24-10-2022

Totais

- Tweets: 180728089.00
- Tweets Rts: 2011476.00
- Tweets non Rts: 178716613
- Tweets onte: 332796.00
- Media de tweets última semana por día: 316259
- Tweets de contas verificadas: 3926304.00
- Tweets de contas verificadas: 3926304.00
- Tweets de contas non verificadas: 176665993.00
- Usuarios: 42362785.00
- Tweets xeoreferenciados: 3693619.00
- Tweets con localización de país: 3689945.00
- Tweets con localización de país e NON RT: 3689887.00

```
In [3]: # Load models and instances of labMT
lang = 'spanish'
#labMT_dic, labMT_matrix, labMTwordList = emotionFileReader(stopval=0.0, lang=lang, returnVector=True)
labMT_dic, labMT_matrix, labMTwordList = emotionFileReader(stopval=1.0, lang=lang, returnVector=True)
```

```
In [4]: # Testing main operations
print("--- EJEMPLOS CON EL DICCIONARIO DIRECTAMENTE ---")
print("Ejemplo con la palabra risa")
print(labMT_dic['risa'])
print("Ejemplo con la palabra mal")
print(labMT_dic['mal'])
```

```
--- EJEMPLOS CON EL DICCIONARIO DIRECTAMENTE ---
Ejemplo con la palabra risa
['61', '8.14', '0.9691', '5060', '531', '--', 'laughter\n']
Ejemplo con la palabra mal
['9749', '3.02', '1.6349', '678', '130', '438', 'wrong\n']
```

```
In [5]: # More examples to see working modes
print("EJEMPLOS DE LAS PALABRAS CON MEJOR PUNTUACION")
print(labMT_matrix[0:5])
print(labMTwordList[0:5])
```

```
EJEMPLOS DE LAS PALABRAS CON MEJOR PUNTUACION
[8.68, 8.6, 8.48, 8.42, 8.42]
['amor', 'felicidad', 'felicidades', 'paz', 'jajajajajajajaja']
```

```
In [6]: # More examples to see working modes
print("EJEMPLOS DE LAS PALABRAS CON PEOR PUNTUACION")
print(labMT_matrix[-5:])
print(labMTwordList[-5:])
```

```
EJEMPLOS DE LAS PALABRAS CON PEOR PUNTUACION
[1.66, 1.66, 1.64, 1.62, 1.54]
['cáncer', 'matar', 'matando', 'murió', 'muerte']
```

```
In [7]: # EXAMPLE
# 1. BASIC EMOTION (INCLUDING STOPWORDS)
sentmient, matrix = emotion('Hola muy bien que tal todo bien?', labMT_dic, shift=True, happsList=labMT_matrix)
print(sentmient)
```

```
7.196
```

```
In [8]: # 2. Get matrix of stop words
stopWords_matrix = stopper(matrix, labMT_matrix, labMTwordList, stopVal=1.0)
#print(stopWords_matrix)
```

```
In [9]: # 3. EXECUTE NEW EMOTION WITH STOPWORDS MATIRX
sentmient_no_stopwords = emotionV(stopWords_matrix, labMT_matrix)
print(sentmient_no_stopwords)
```

```
7.1960000000000001
```


¿CONCLUSIONES?

- Hay demasiado humo y sobredimensión en internet
- La planificación es imposible
- El rendimiento siempre queda en 2º plano
- Lo que importa es la visualización
- Nunca vas a tener tiempo a hacerlo cómo te quieres (limpieza, formateo, etc...)
- SIEMPRE FALTAN DATOS

¡GRACIÑAS!

Dudas, ideas, mejoras, etc..

info@christianlr.es

[@christianlrcalo](#)

