
Presentación Tarea 1



Integrantes:

Fernando Riveros

Víctor San Martín

Alejandro Vasquez

Pablo Vergara

Profesores:

Juan Velasquez

Felipe Vildoso

IN5528

Introducción al Big Data

Agenda

- Introduccion a Twitter
- Codificación
- Resultados
- Problemas y Conclusiones



Introducción: Twitter

What is Twitter?

Twitter is a service for friends, family, and coworkers to communicate and stay connected through the exchange of quick, frequent messages. People post Tweets, which may contain photos, videos, links and up to 140 characters of text. These messages are posted to your profile, sent to your [followers](#), and are searchable on Twitter search. Learn more about [how to use Twitter](#).

310M

Monthly
active users

1B

Unique visits
monthly

3,8k

Employees



El problema: implementar el Batch Layer en el contexto de la Arquitectura Lambda


1. Top 10 de usuarios que mencionan @cooperativa
2. Días con más menciones @cooperativa
3. Palabras más nombradas junto a @cooperativa

Velocity


Variety

Volume

Apache Thrift Schema



2 nodos: un Tweet y un Usuario.



Estructura del Esquema

Instalar



**Estandarizar
Estructura de
Proyectos**



**Creación del
Proyecto**



Pasos del Proyecto

Browse Directory

Permission	Owner	Group	Size	Last Modified	Replication	Block Size	Name
drwxr-xr-x	Alejandro	supergroup	0 B	9/6/2016 12:15:12	0	0 B	1
drwxr-xr-x	Alejandro	supergroup	0 B	9/6/2016 12:16:01	0	0 B	2
-rw-r--r--	Alejandro	supergroup	79 B	9/6/2016 12:15:12	1	128 MB	pail.meta

Hadoop, 2015.

Guardado de Datos

Pregunta 1

Top 10 de usuarios que mencionan
@cooperativa

Pasos

1

Obtener lista con tweets
que mencionan
@cooperativa

2

Obtener lista UserIds y
TweetsIds

3

TWEETS		
"?time"	"?t_id"	"?text"

TWEETEOS	
"?t_id"	"?u_id"



JOIN



"?t_id"	"?u_id"
---------	---------

Top 10 de usuarios que mencionan @cooperativa

```

public static void getJoin(){
    PailTap source = getDataTap("/tareafinal/1");
    Subquery tweets = new Subquery("?time", "?text", "?tid")
        .predicate(source, "_", "?data")
        .predicate(new ExtractText(), "?data").out("?time", "?text", "?tid")
        .predicate(new FText(), "?text");

    PailTap source2 = getDataTap("/tareafinal/2");
    Subquery ids = new Subquery("?time", "?uid", "?tid")
        .predicate(source2, "_", "?data")
        .predicate(new ExtractText2(), "?data").out("?time", "?uid", "?tid");

    Subquery algo = new Subquery("?uid", "?tid")
        .predicate(ids, "_", "?uid", "?tid")
        .predicate(tweets, "_", "_", "?tid");

    Subquery algo2 = new Subquery("?uid", "?c")
        .predicate(algo, "?uid", "_")
        .predicate(Option.DISTINCT, true)
        .predicate(new Count(), "?c");

    Api.execute(new StdoutTap(),
        new Subquery("?uid1", "?count1")
            .predicate(algo2, "?uid", "?c")
            .predicate(Option.SORT, "?c")
            .predicate(Option.REVERSE, "?c")
            .predicate(new Limit(10), "?uid", "?c").out("?word1", "?count1")
    );
}

```

Query

User ID	Numero menciones	Ranking
938296908	23	1
171913028	22	2
1705850354	15	3
2161635434	15	4
2196448152	15	5
2196493872	15	6
1681742905	12	7
1861391822	12	8
1912255273	12	9
1912375015	12	10
1968897702	12	11
2161614498	12	12
2221952394	12	13
2332158937	12	14
2895803727	12	15

Resultados



Ayuda por Favor

@FavorAyuda

La unión hace la fuerza. Ayudemonos !!
¿Le darías RT a nuestros twiits?

📍 Chile

📅 Joined November 2014

TWEETS
102K

FOLLOWING
2,249

FOLLOWERS
7,085

Tweets

Tweets & replies

Media



Ayuda por Favor Retweeted

Vínculo.cl @VinculoCL · May 27



¿Necesitas un Servidor?

VPS - Servidor Privado Virtual

>> v.c1.cl/?c=fc328

Pregunta 2

Menciones de @cooperativa por día

Pasos

1

Obtener lista con tweets que mencionan @cooperativa

TWEETS		
"?time"	"?t_id"	"?text"

2

Sobre esa lista, contar los elementos únicos

CONTEO	
"?time"	"?count"

Menciones de @cooperativa por día

```
// menciones por dia /P2
public static void getTuits2(){
    PailTap source = getDataTap("/tareafinal/1");
    Subquery q = new Subquery("?time", "?text", "?id")
        .predicate(source, "_", "?data")
        .predicate(new ExtractText(), "?data").out("?time","?text","?id")
        .predicate(new FText(), "?text");

    Api.execute(new StdoutTap(), new Subquery("?tiempo","?c")
        .predicate(q, "?tiempo", "_", "_")
        .predicate(Option.DISTINCT,true)
        .predicate(new Count(),"?c")
    );
}
```

```
public static class FText extends CascalogFilter {
    public boolean isKeep(FlowProcess process, FilterCall call){
        String text = (String) call.getArguments().getString(0);
        return text.contains("@cooperativa");
    }
}

public static class ExtractText extends CascalogFunction {
    public void operate(FlowProcess process, FunctionCall call){
        Data data = ((Data) call.getArguments().getObject(0));
        long time = data.getPedigree().getDate();
        String text = data.getData_unit().getTwit_property().getProperty().getTexto();
        long id = data.getData_unit().getTwit_property().getTwit_id().getTwit_id();
        call.getOutputCollector().add(new Tuple(time,text,id));
    }
}
```

Query

Fecha	Numero menciones	Fecha	Numero menciones
21-04-2016	8	03-05-2016	13
22-04-2016	13	04-05-2016	28
23-04-2016	8	05-05-2016	25
24-04-2016	7	06-05-2016	241
25-04-2016	39	07-05-2016	29
26-04-2016	27	08-05-2016	7
27-04-2016	15	09-05-2016	59
28-04-2016	35	10-05-2016	10
29-04-2016	31	11-05-2016	36
30-04-2016	55	12-05-2016	6
01-05-2016	45	13-05-2016	3
02-05-2016	11	14-05-2016	1

Cantidad de menciones de @cooperativa por día : días con más menciones: 6 de Mayo y 9 de Mayo.



Gabriela Infante
@gabinfanti



Follow

Manifestantes de Chiloé lanzaron salmones a la pileta de La Moneda. Cerca de 10 detenidos
[@cooperativa](#)

View translation



RETWEETS

215

LIKES

76



11:49 AM - 6 May 2016

Principales Problemas

1. Creación de nodos
2. Identificar las dependencias de Maven
3. Familiarización con Java
4. Comprensión del guardado de datos con Pail
5. Creación de consultas con JCascalog

Conclusiones

1. Hadoop es una potente herramienta para procesar Big Data en una computador común y corriente
 2. Se necesita más preparación a la hora de realizar un proyecto como este, el cual necesita conocimientos en múltiples idiomas.
-

Presentación Tarea 1

