



escola  
britânica de  
artes criativas  
& tecnologia

# SQL para análise de dados



# TÉCNICAS AVANÇADAS



## GUIA DA AULA 3



# Faça agregação por particionamento – Teoria

● Introdução



Acompanhe aqui  
os temas que  
serão tratados  
na videoaula



## Introdução

Esse é um aspecto do AWS Athena utilizado para organizar e gerar as queries de maneira mais eficiente no *framework*. É uma organização hierárquica onde cada pasta contém **subpastas** com o rótulo e valores. É utilizado para economizar dados carregados no AWS Athena, aumentando a performance e reduzindo custos. Para fazer isso, siga as etapas:

- No S3, crie uma pasta no AWS com o nome do seu **dataset**.
- Vamos supor que queremos separar as lojas na nossa partição. Para isso criamos subpastas:
  - transacoes\_partition/id\_loja=magalu
  - transacoes\_partition/id\_loja=giraffas
  - transacoes\_partition/id\_loja=postoshell



- transacoes\_partition/id\_loja=subway
- transacoes\_partition/id\_loja=seveneleven
- transacoes\_partition/id\_loja=extra
- transacoes\_partition/id\_loja=shopee

Dentro de cada uma das subpastas, colocamos apenas aquelas informações referentes a id\_loja dedicada. A geração da partição é indicada na hora da **CRIAÇÃO** da tabela com o comando **PARTITIONED by** id\_loja (no exemplo).



Depois da criação, é necessário carregar as partições como o comando:

```

CREATE EXTERNAL TABLE transacoes_part(
  id_cliente BIGINT,
  id_transacoes BIGINT,
  valor DOUBLE)
PARTITIONED BY (id_loja string)
ROW FORMAT SERDE 'org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe'
WITH SERDEPROPERTIES (
  'serialization.format' = ',',
  'field.delim' = ''
)
LOCATION 's3://transacoes-partition/'
MSCK REPAIR TABLE transacoes_part
  
```



Você pode verificar pela contagem de linhas na tabela completa:

```
select count(*) from transacoes_part
```

A partir disso, nós podemos seguir com os comandos de SELECT que aprendemos.

