

Estudos de Caso em Big Data na SEFAZ-MT

Guilherme Falcão da Silva Campos

SEFAZ
SECRETARIA DE
ESTADO DE FAZENDA



GOVERNO DE
MATO GROSSO
ESTADO DE TRANSFORMAÇÃO

Por que Big Data?

- Criação de relatórios transacionais
- Hoje existem 1.143 relatórios
- Dificuldade na criação de modelos tradicionais de BI
- Alguns relatórios não executam em tempo hábil

Ambiente Transacional

ORACLE
EXADATA



X2-2 1/2

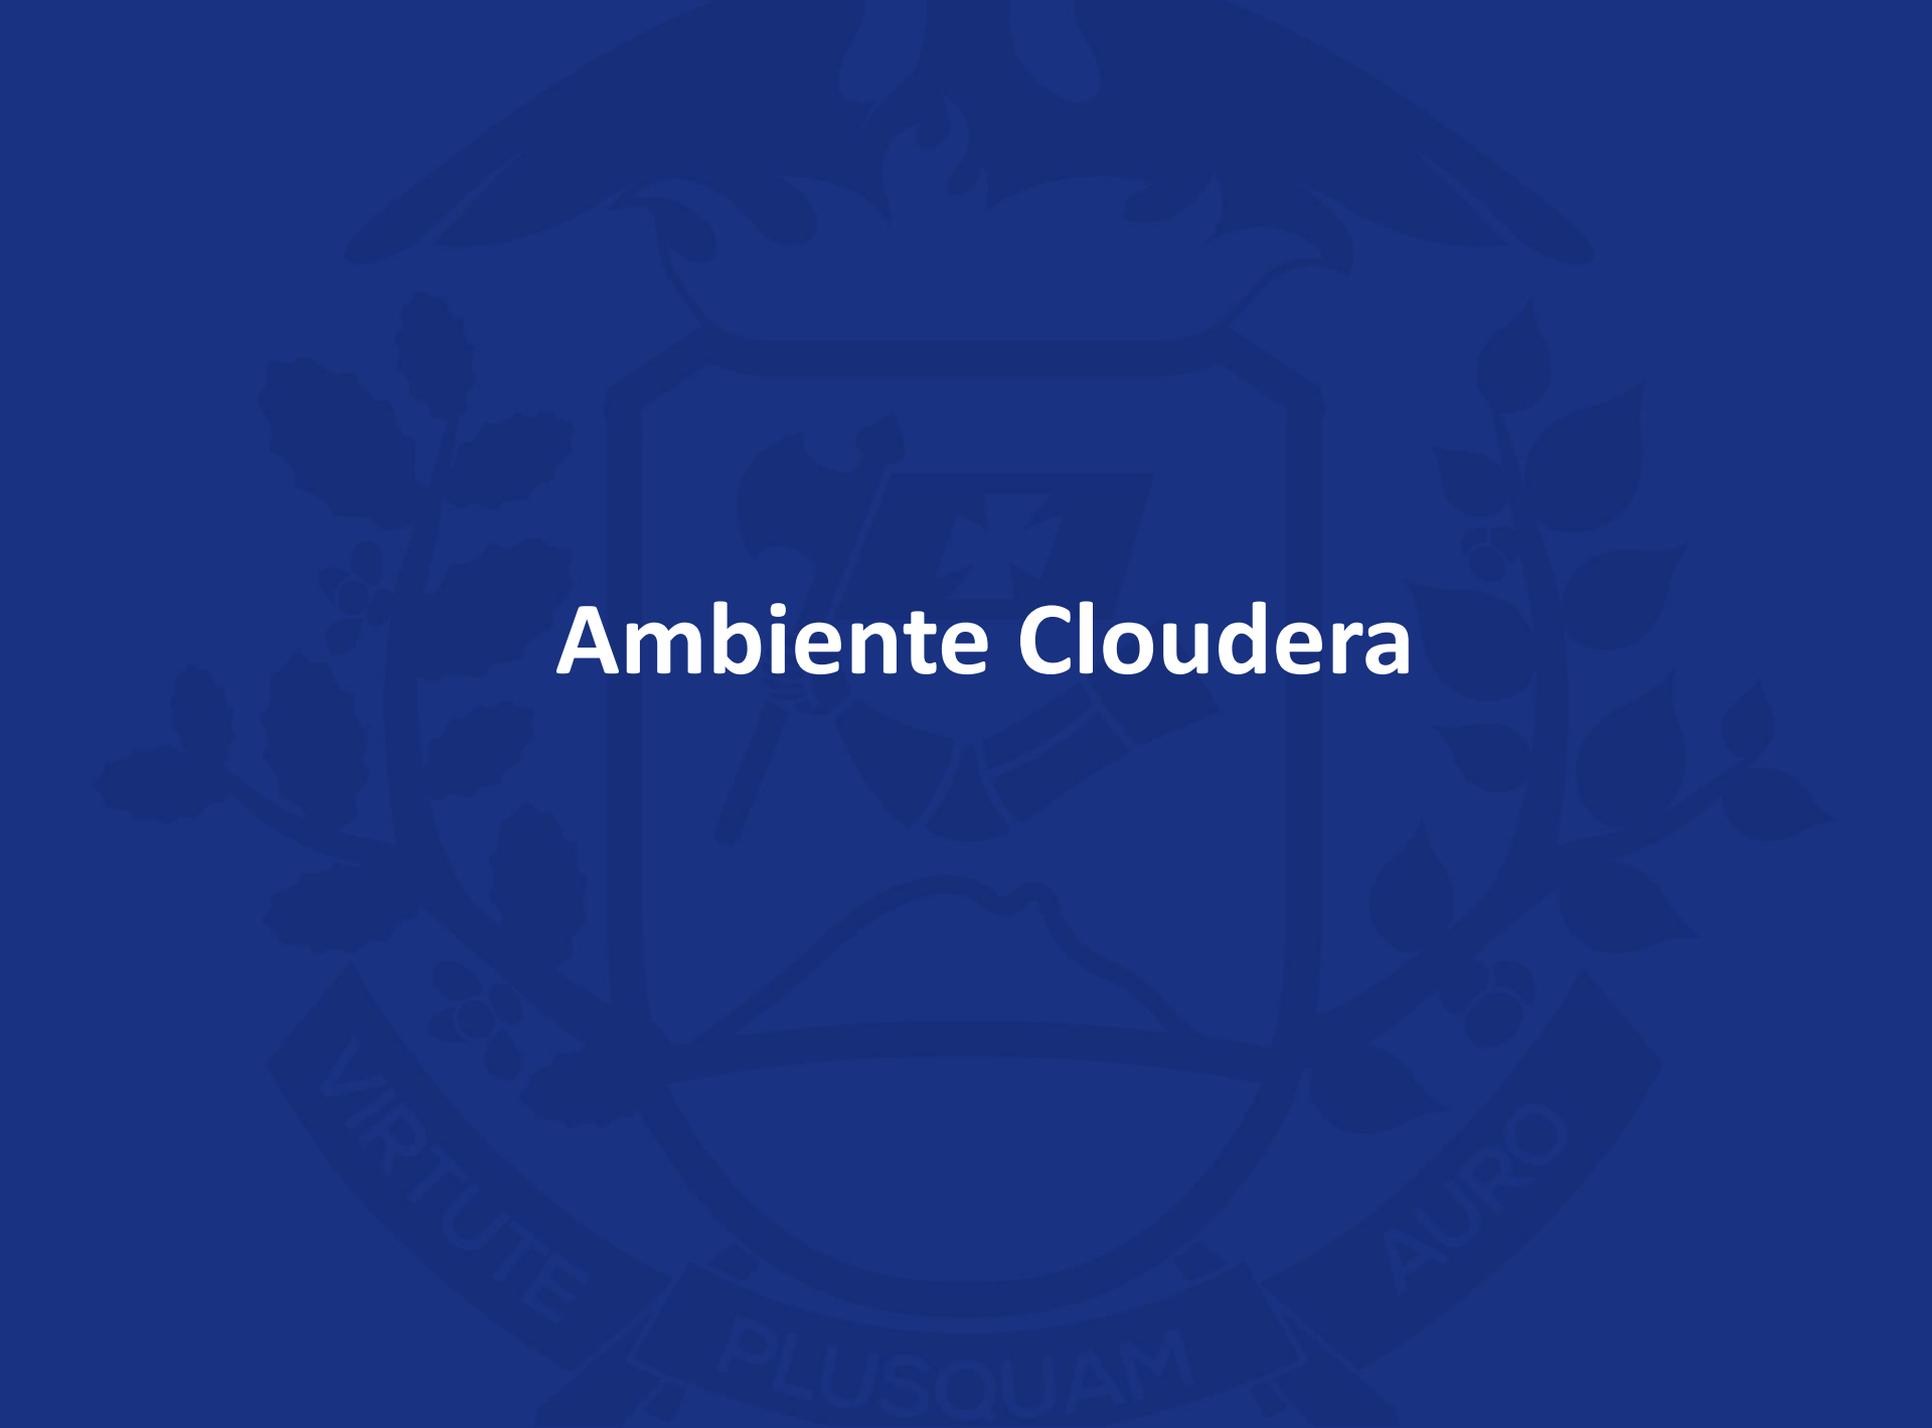
**Storage
X5 1/4**

X

DELL
cloudera



10x R730

The background of the slide features a large, faint watermark of the University of Padua seal. The seal is circular and contains a central shield with a book and a quill. Below the shield is a banner with the Latin motto "VIRTUTE PLUSQUAM AURO".

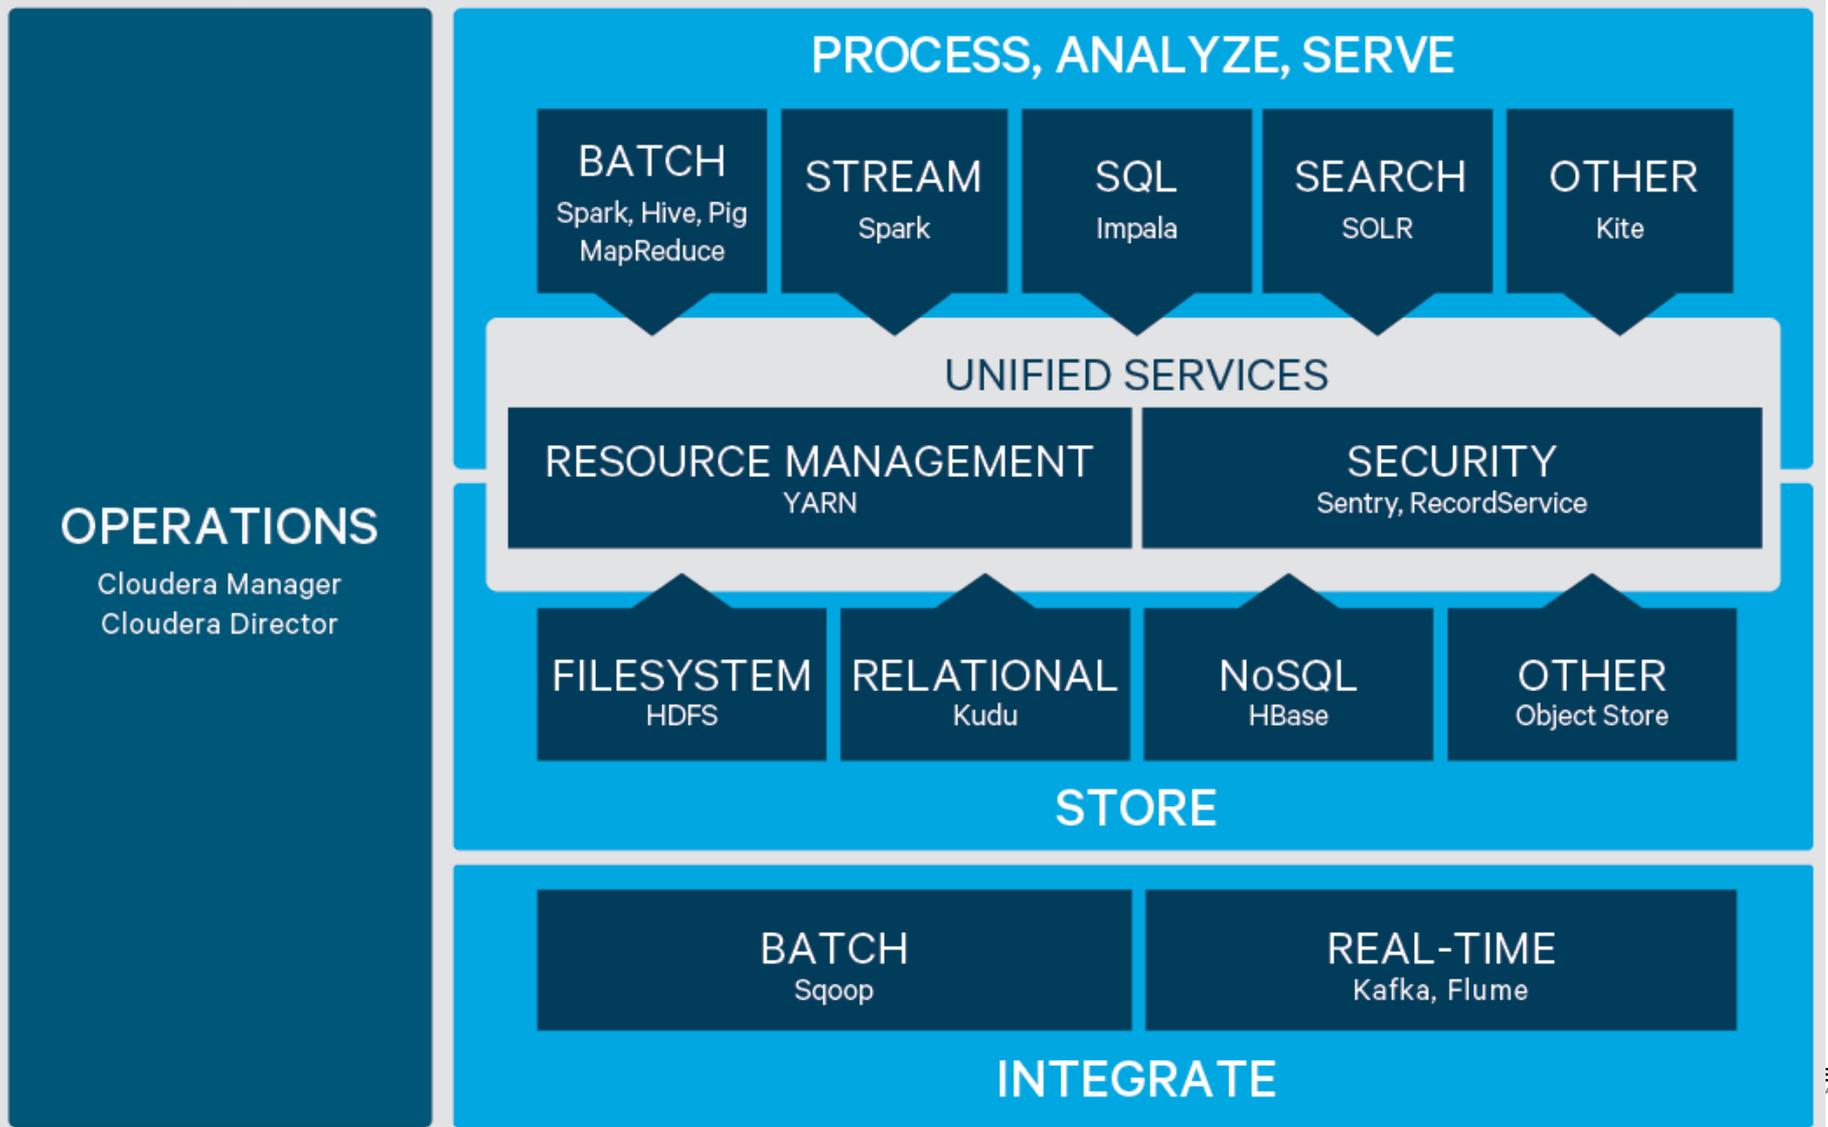
Ambiente Cloudera

Ambiente Cloudera



- 10x Dell R730:**
- 2 processadores octa core;**
- 128GB de Memória RAM;**
- 06 Discos SAS de 4TB;**
- Dual Port 10GB e 1GB.**

Ambiente Cloudera



Ambiente Cloudera

cloudera MANAGER

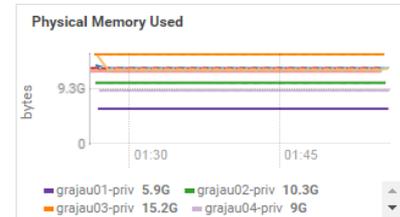
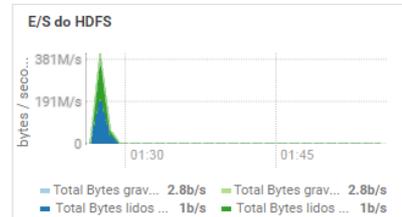
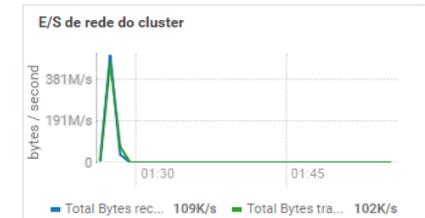
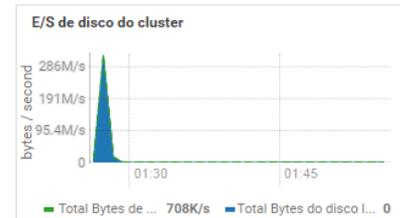
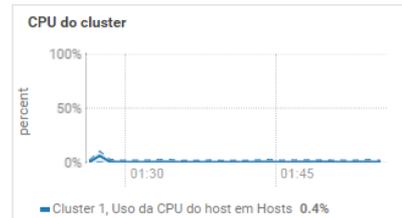
Clusters ▾ Hosts ▾ Diagnóstico ▾ Auditorias Gráficos ▾ Backup ▾ Administração ▾

Raiz Status Todos os problemas de integridade Configuração  4 ▾ Nenhum comando recente

Cluster 1 (CDH 5.14.2, Parcelas) ▾

- 10 hosts
- Flume
- HBase
- HDFS
- Hive
- Hue
- Impala
- Kafka
- Kudu
- Oozie
- Solr
- Spark
- Sqoop 1 Client
- YARN (MR2 I...)
- ZooKeeper

Gráficos



Cloudera Management Service

- Cloudera Ma...  4 ▾

Ambiente Cloudera

- Diferenças entre versão open source e subscrição:
 - Serviço de suporte 8x5 ou 24x7;
 - Atualizações periódicas;
 - Segurança e Integração com AD;
 - Gerenciar múltiplos clusters;

Ambiente Cloudera

- Aquisição:
 - PROFISCO no modelo de Pregão Eletrônico
 - Data do contrato: 01/02/2018

Item	Descrição	Unidade	Quantidade	Valor Unitário	Valor Total
1	Subscrição de software de ferramentas de BIG DATA por 24 meses - Cloudera Enterprise Data Hub Edition - Suporte 8x5	Nós	10	134.800,00	1.348.000,00
2	Serviço de desenvolvimento e implementação de soluções com repasse de conhecimento sobre ferramentas de BIG DATA	Horas	800	730,00	584.000,00
3	Serviço de treinamento sobre desenvolvimento e administração de ferramentas de BIG DATA - Turma de 10 pessoas - Carga horária de 120 horas	Turmas	4	115.700,00	462.800,00
VALOR TOTAL: R\$ 2.394.800,00 (dois milhões trezentos e noventa e quatro mil e oitocentos reais)					



Caso#1: Faturamento NFce

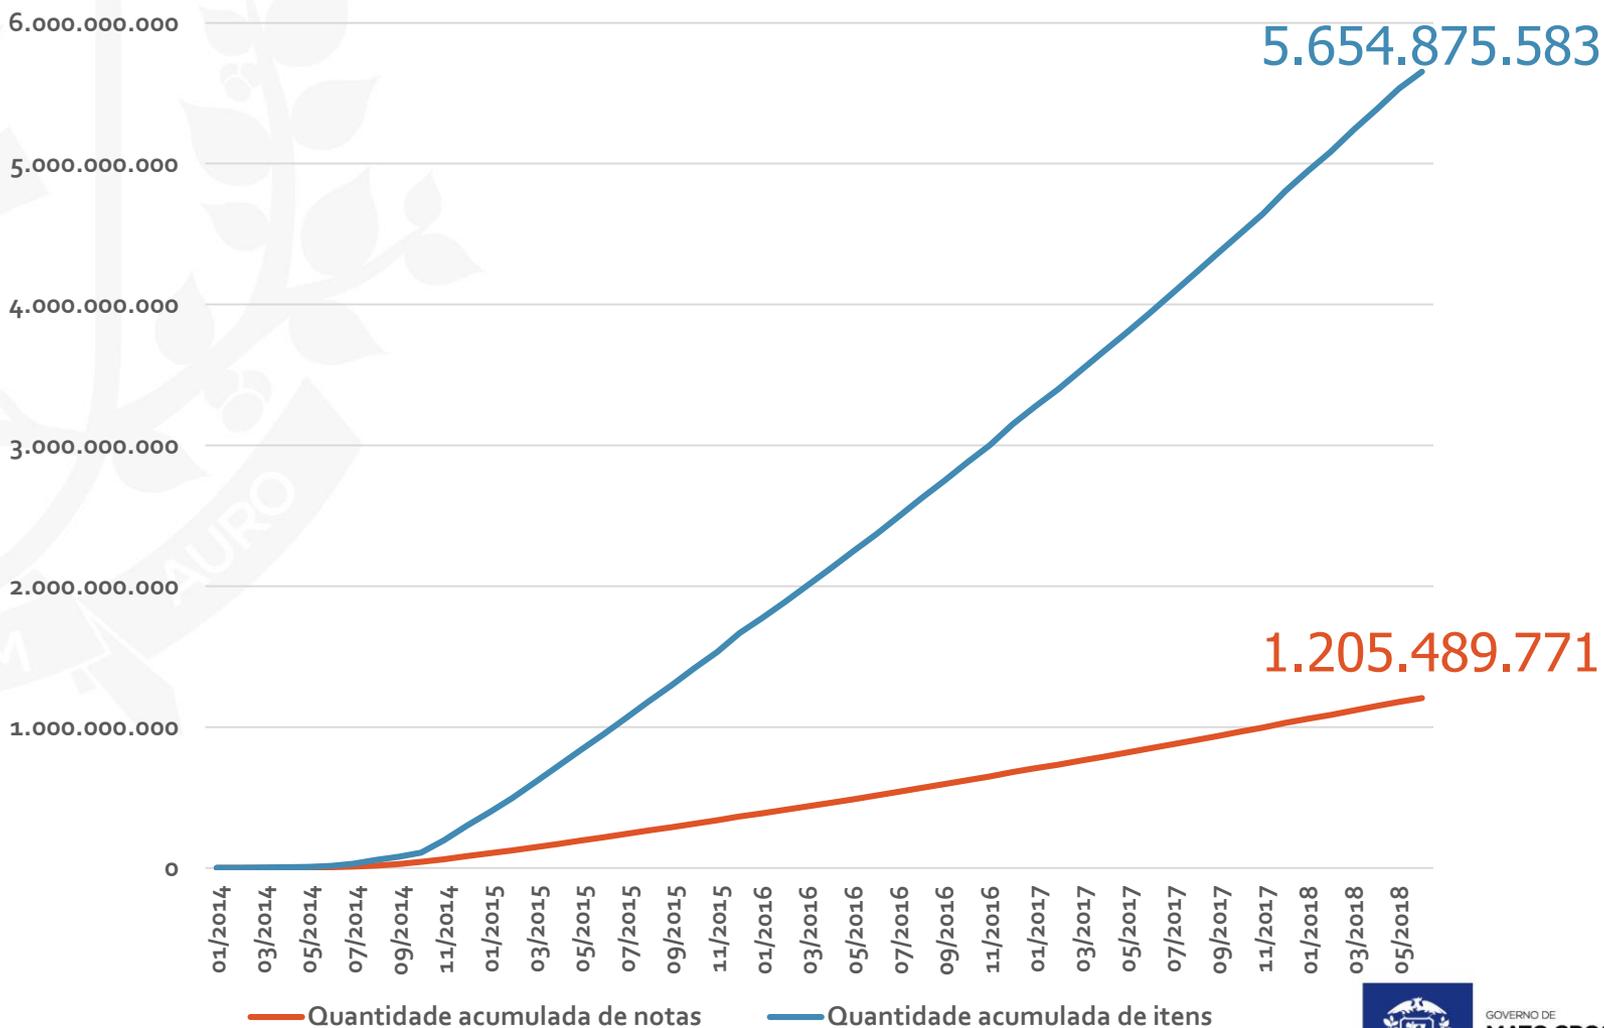
- Verificação de contribuintes enquadrados no SIMPLES:
Calcular o faturamento mensal ou anual de todos os contribuintes, com a somatória de NFCE's emitidas.
- A quantidade de informações na base é muito grande, tornando a consulta desenvolvida ineficaz.

- NFCETB30_CONSUMIDOR_ELETRONICA
 - 14/11/2017 - 751.140.807
 - 16/04/2018 - 1.166.018.890
 - 26/06/2018 – 1.205.489.771
- NFCETB34_NFCE_PRODUTO_SERVICO
 - 14/11/2017 - 3.487.843.229
 - 16/04/2018 - 5.251.483.211
 - 26/06/2018 - 5.654.875.583
- Tamanho ocupado no cluster
 - NFCETB30_CONSUMIDOR_ELETRONICA
 - 316.05 G
 - NFCETB34_NFCE_PRODUTO_SERVICO
 - 231.95 G

Quantidade de dados

Faturamento NFCe

Crescimento da base de dados





Ambiente Autorização

- Modelo normalizado
- Armazenamento de XML

Ambiente Consulta

- Modelo denormalizado

ORACLE
EXADATA



Ingestão dos novos dados

- Dados cadastrais
- Novas NFCe

DELL
cloudera



Consolidação dos dados

Ambiente Consulta

- NFCETB30
- NFCETB34
- Dados Cadastrais

Consulta Oracle

- Não executa

Consulta Impala

- Tempo total de execução para um mês: 15 minutos

Sqoop

- Para fazer a carga dos dados

Hive

- Para fazer a ingestão inicial dos dados

Impala

- Para realizar a consulta após a conclusão da ingestão dos dados.

Estado Atual

- Carga diária dos dados
- Resultado disponibilizado via reports
- Melhoria de performance

Planos Futuros

- Utilização dos conceitos em outras bases de dados grandes



Caso#2: Quantidade de NFCe emitida por contribuinte

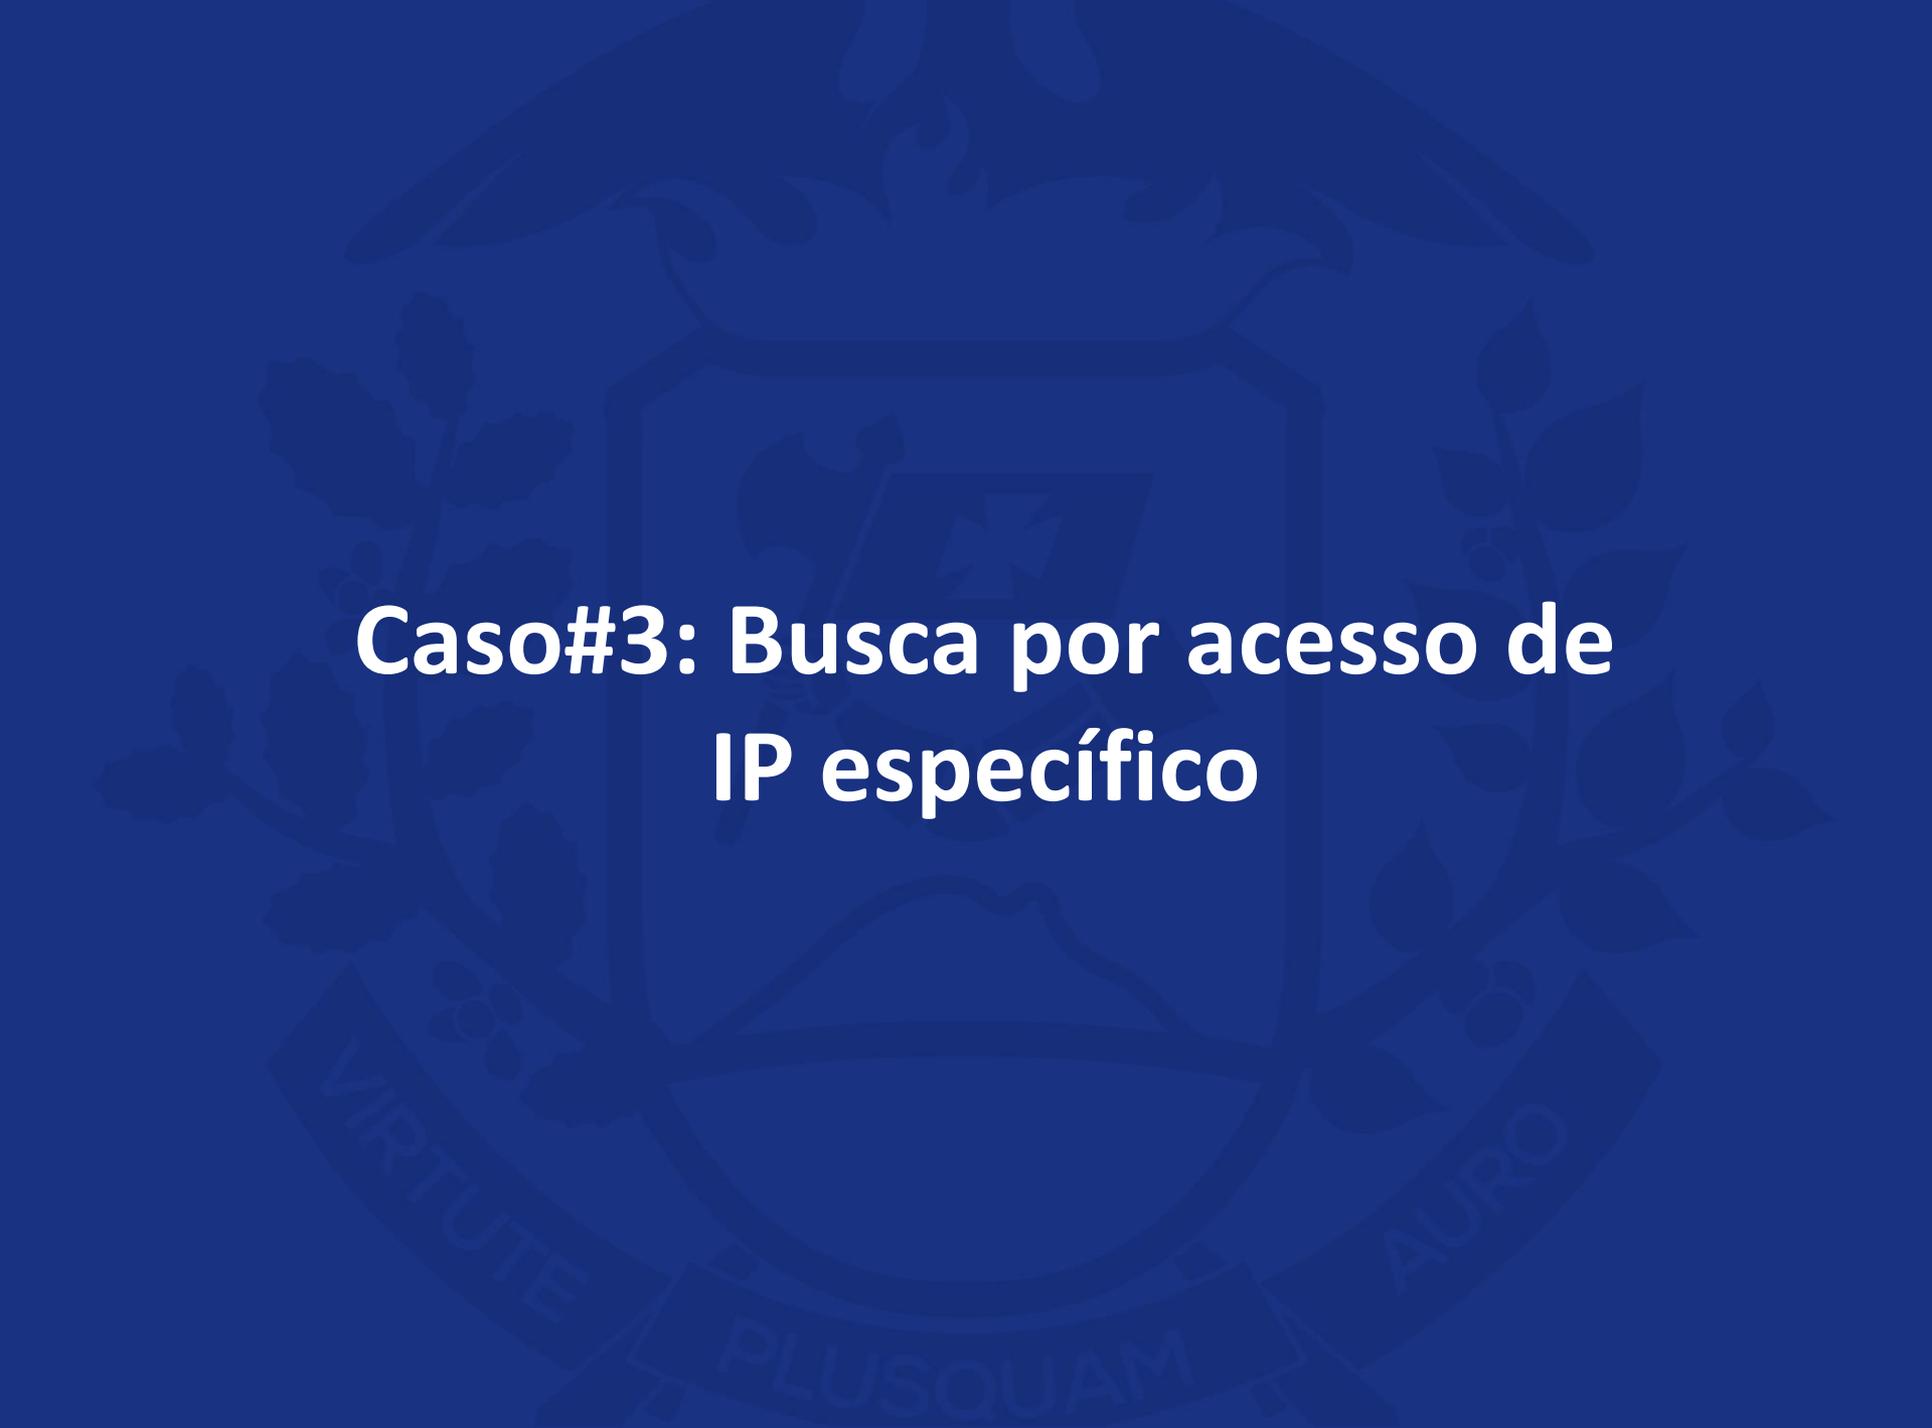
- Contar quantas NFCes de cada tipo foram emitidas por cada um dos contribuintes.
- A quantidade de informações na base é muito grande, tornando a consulta desenvolvida ineficaz.

Consulta Oracle

- Tempo total de execução para um mês: 40 minutos

Consulta Impala

- Tempo total de execução para um mês: 10 seg



Caso#3: Busca por acesso de IP específico

- Buscar usuário do acesso web que acessou por um determinado IP
- Nem todos os registro do Acesso Web no SCL possuíam o IP que era necessário
- Os dados do log do apache do servidor de produção possuem uma formatação específica

- Pesquisar os logs dos servidores de produção
- Pesquisar quais requisições tiveram origem no IP buscado
- Buscar as funcionalidades acessadas pelo IP

```
1 192.168.5.3 - - [22/Sep/2016:08:17:55 -0400] "GET /" 200 422 "-" "-"
2 192.168.5.2 - - [22/Sep/2016:08:17:55 -0400] "GET /" 200 422 "-" "-"
3 177.**.**.152 - - [22/Sep/2016:08:17:56 -0400] "GET /imggd/imagens/miniatura/150x95/Array HTTP/1.1" 403 246 "http://www.sefaz.mt.gov.br/portal/index.php?link=1" "Mozilla/5.0 (Windows NT 6.1) AppleWebKit/537.36 (KHTML, like Gecko) Chrome/53.0.2785.116 Safari/537.36"
4 191.**.**.101 - - [22/Sep/2016:08:17:56 -0400] "GET /arrecadacao/darlivre/menudarlivre HTTP/1.1" 200 6515 "-" "Mozilla/5.0 (Windows NT 6.1) AppleWebKit/537.36 (KHTML, like Gecko) Chrome/53.0.2785.116 Safari/537.36"
5 201.**.**.130 - - [22/Sep/2016:08:17:56 -0400] "GET /sid/consulta/infocadastral/consultar/publica HTTP/1.1" 200 9035 "http://www.sintegra.gov.br/new_bv.html" "Mozilla/5.0 (Windows NT 6.3; WOW64) AppleWebKit/537.36 (KHTML, like Gecko) Chrome/53.0.2785.116 Safari/537.36"
6 191.**.**.101 - - [22/Sep/2016:08:17:56 -0400] "GET /estilos/SefazEstilos.css HTTP/1.1" 304 - "https://www.sefaz.mt.gov.br/arrecadacao/darlivre/menudarlivre" "Mozilla/5.0 (Windows NT 6.1) AppleWebKit/537.36 (KHTML, like Gecko) Chrome/53.0.2785.116 Safari/537.36"
```

HDFS

- Armazenamento inicial dos arquivos de logs

HIVE

- Ingestão dos dados
- Transformação de vários arquivos de log em uma única tabela HIVE

Impala

- Consulta dos dados

Jupyter Notebook

- Analise dos dados

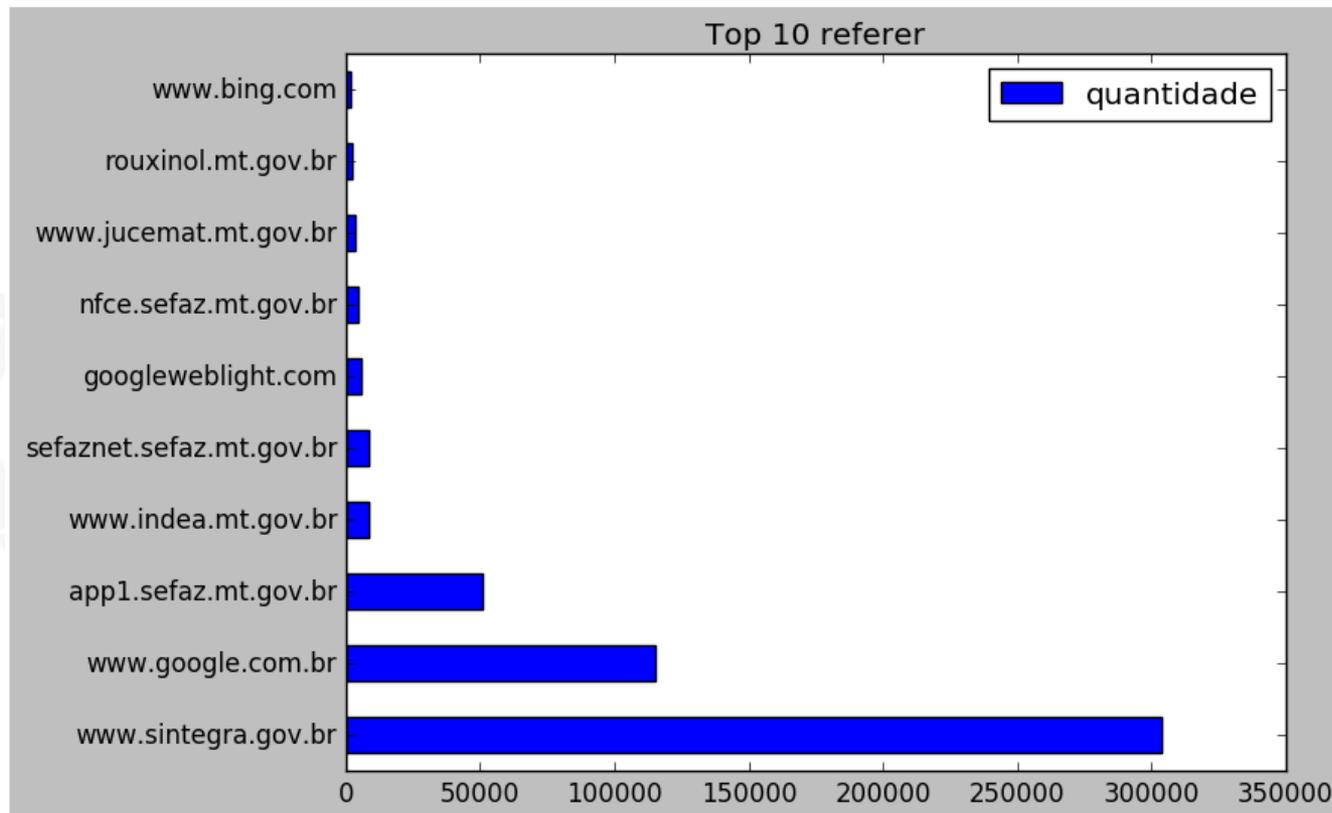
- Arquivos originais:
 - 96 arquivos
 - 23,4Gb
- LOGTB01_ACCESS_LOG
 - 116.283.297
- Tamanho ocupado no cluster
 - LOGTB01_ACCESS_LOG
 - 5.2Gb

Top 10 Referer

Busca por IP específico

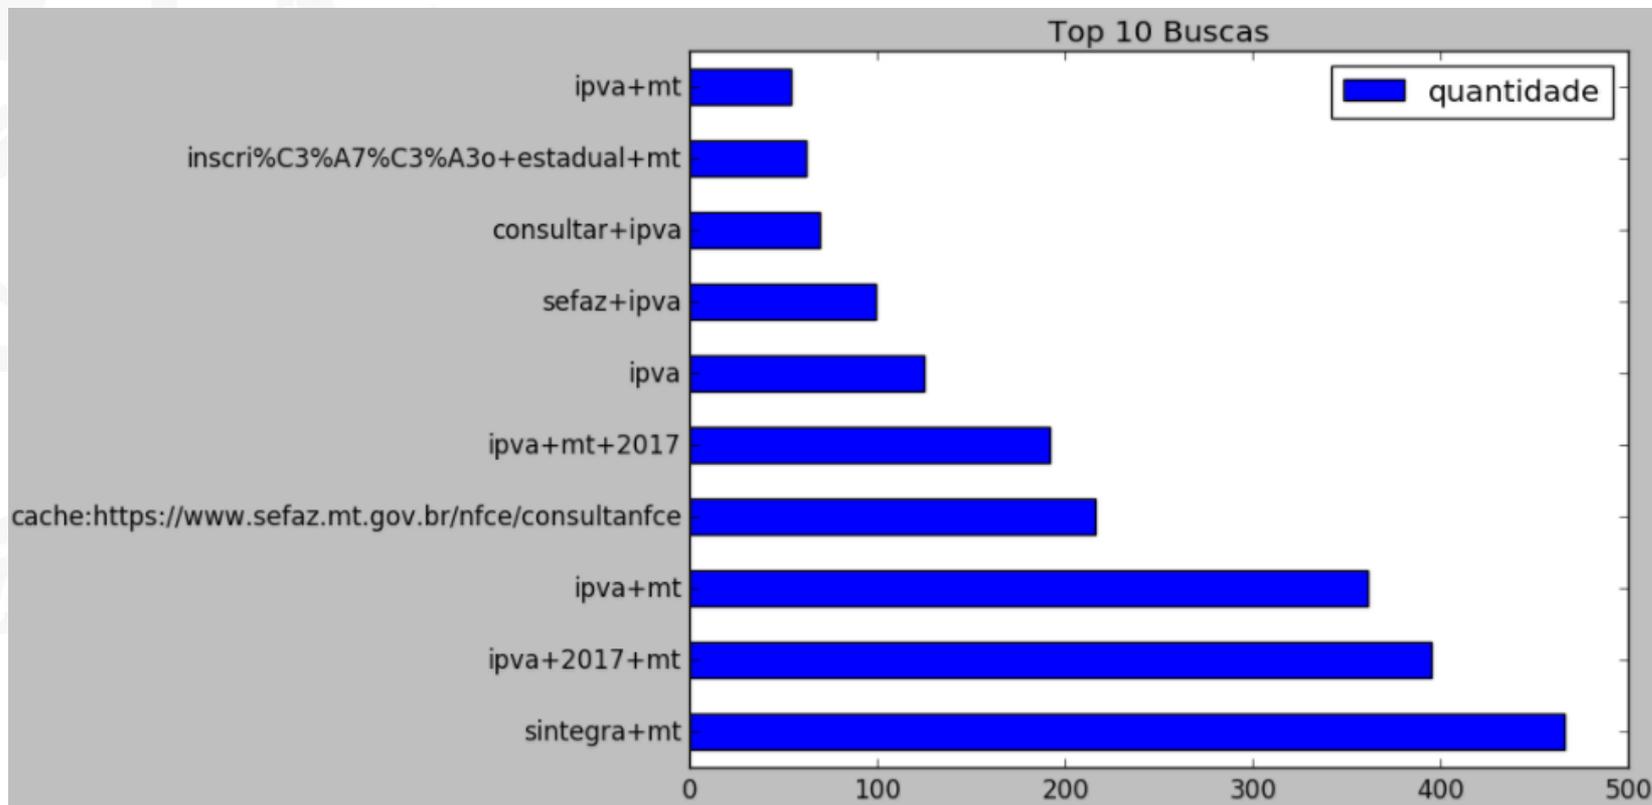
```
top10 = df_top_referers[(df_top_referers.referer_host != 'www.sefaz.mt.gov.br') & (df_top_referers.referer_host != '')].head(10)
ax = top10.plot(kind='barh', title='Top 10 referer')
#ax.axis('off')

ax.set_yticklabels([i for i in top10.referer_host])
rects = ax.patches
```



Top 10 Buscas

Busca por IP específico



Top 10 Buscas

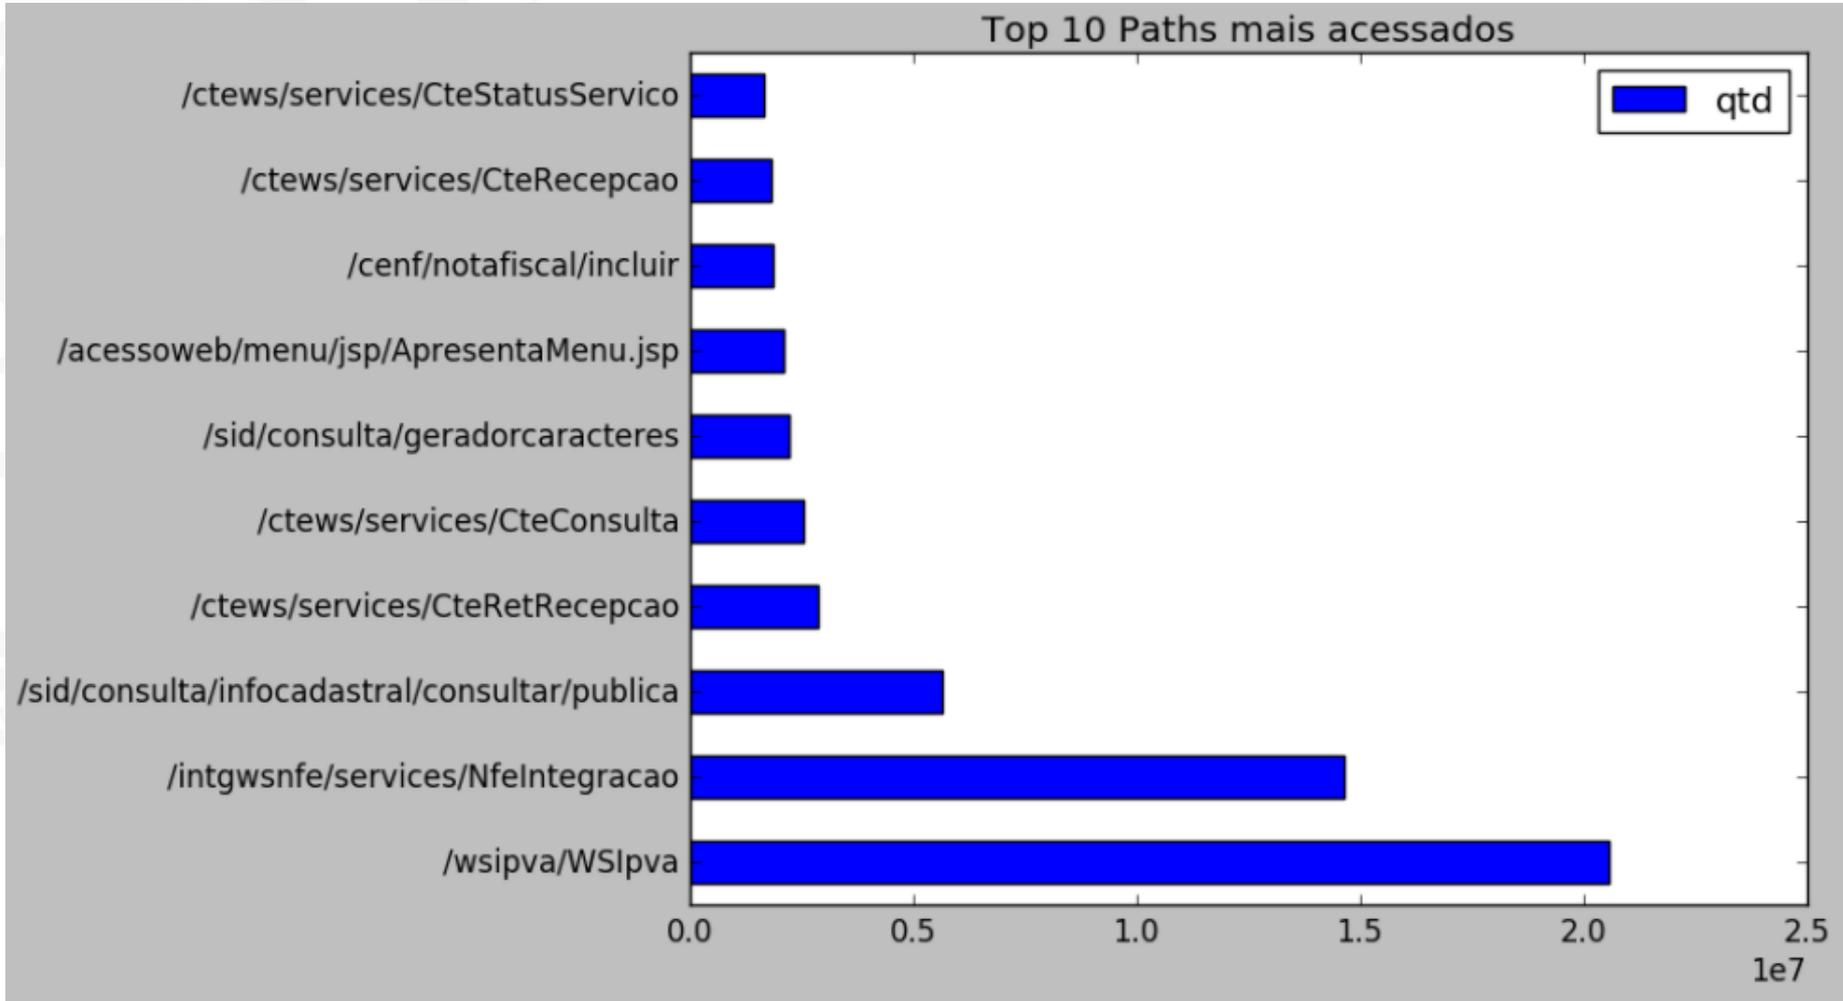
Busca por IP específico

```
df_searchs.head(10)
```

	referer_host	query	quantidade
0	www.google.com.br	sintegra+mt	466
1	www.google.com.br	ipva+2017+mt	395
2	www.google.com.br	ipva+mt	361
3	webcache.googleusercontent.com	cache:https://www.sefaz.mt.gov.br/nfce/consult...	216
4	www.google.com.br	ipva+mt+2017	192
5	www.google.com.br	ipva	125
6	www.google.com.br	sefaz+ipva	99
7	www.google.com.br	consultar+ipva	69
8	www.google.com.br	inscri%C3%A7%C3%A3o+estadual+mt	62
9	www.bing.com	ipva+mt	54

Top 10 Paths mais acessados

Busca por IP específico



Top 10 Paths mais acessados

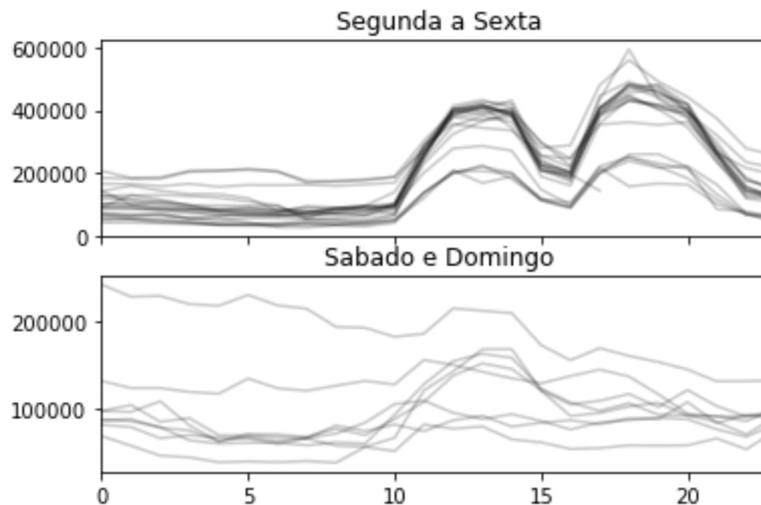
Busca por IP específico

```
df_mais_acessados.head(10)
```

	path1	qtd
0	/wsipva/WSIpva	20560252
1	/intgwsnfe/services/NfeIntegracao	14652998
2	/sid/consulta/infocadastral/consultar/publica	5672614
3	/ctews/services/CteRetRecepcao	2864434
4	/ctews/services/CteConsulta	2567251
5	/sid/consulta/geradorcaracteres	2243567
6	/acessoweb/menu/jsp/ApresentaMenu.jsp	2092318
7	/cenf/notafiscal/incluir	1864221
8	/ctews/services/CteRecepcao	1815906
9	/ctews/services/CteStatusServico	1662677

```
In [14]: f, ax = plt.subplots(2, sharex=True)
plt.xlim((0,23))
for day in dias:
    x, y, weekday = get_serie(day)
    if weekday[0] < 5:
        ax[0].plot(x, y, alpha=0.2, label=day, c='black')
    else:
        ax[1].plot(x, y, alpha=0.2, label=day, c='black')
ax[0].set_title('Segunda a Sexta')
ax[1].set_title('Sabado e Domingo')
```

Out[14]: <matplotlib.text.Text at 0xb3072e8>

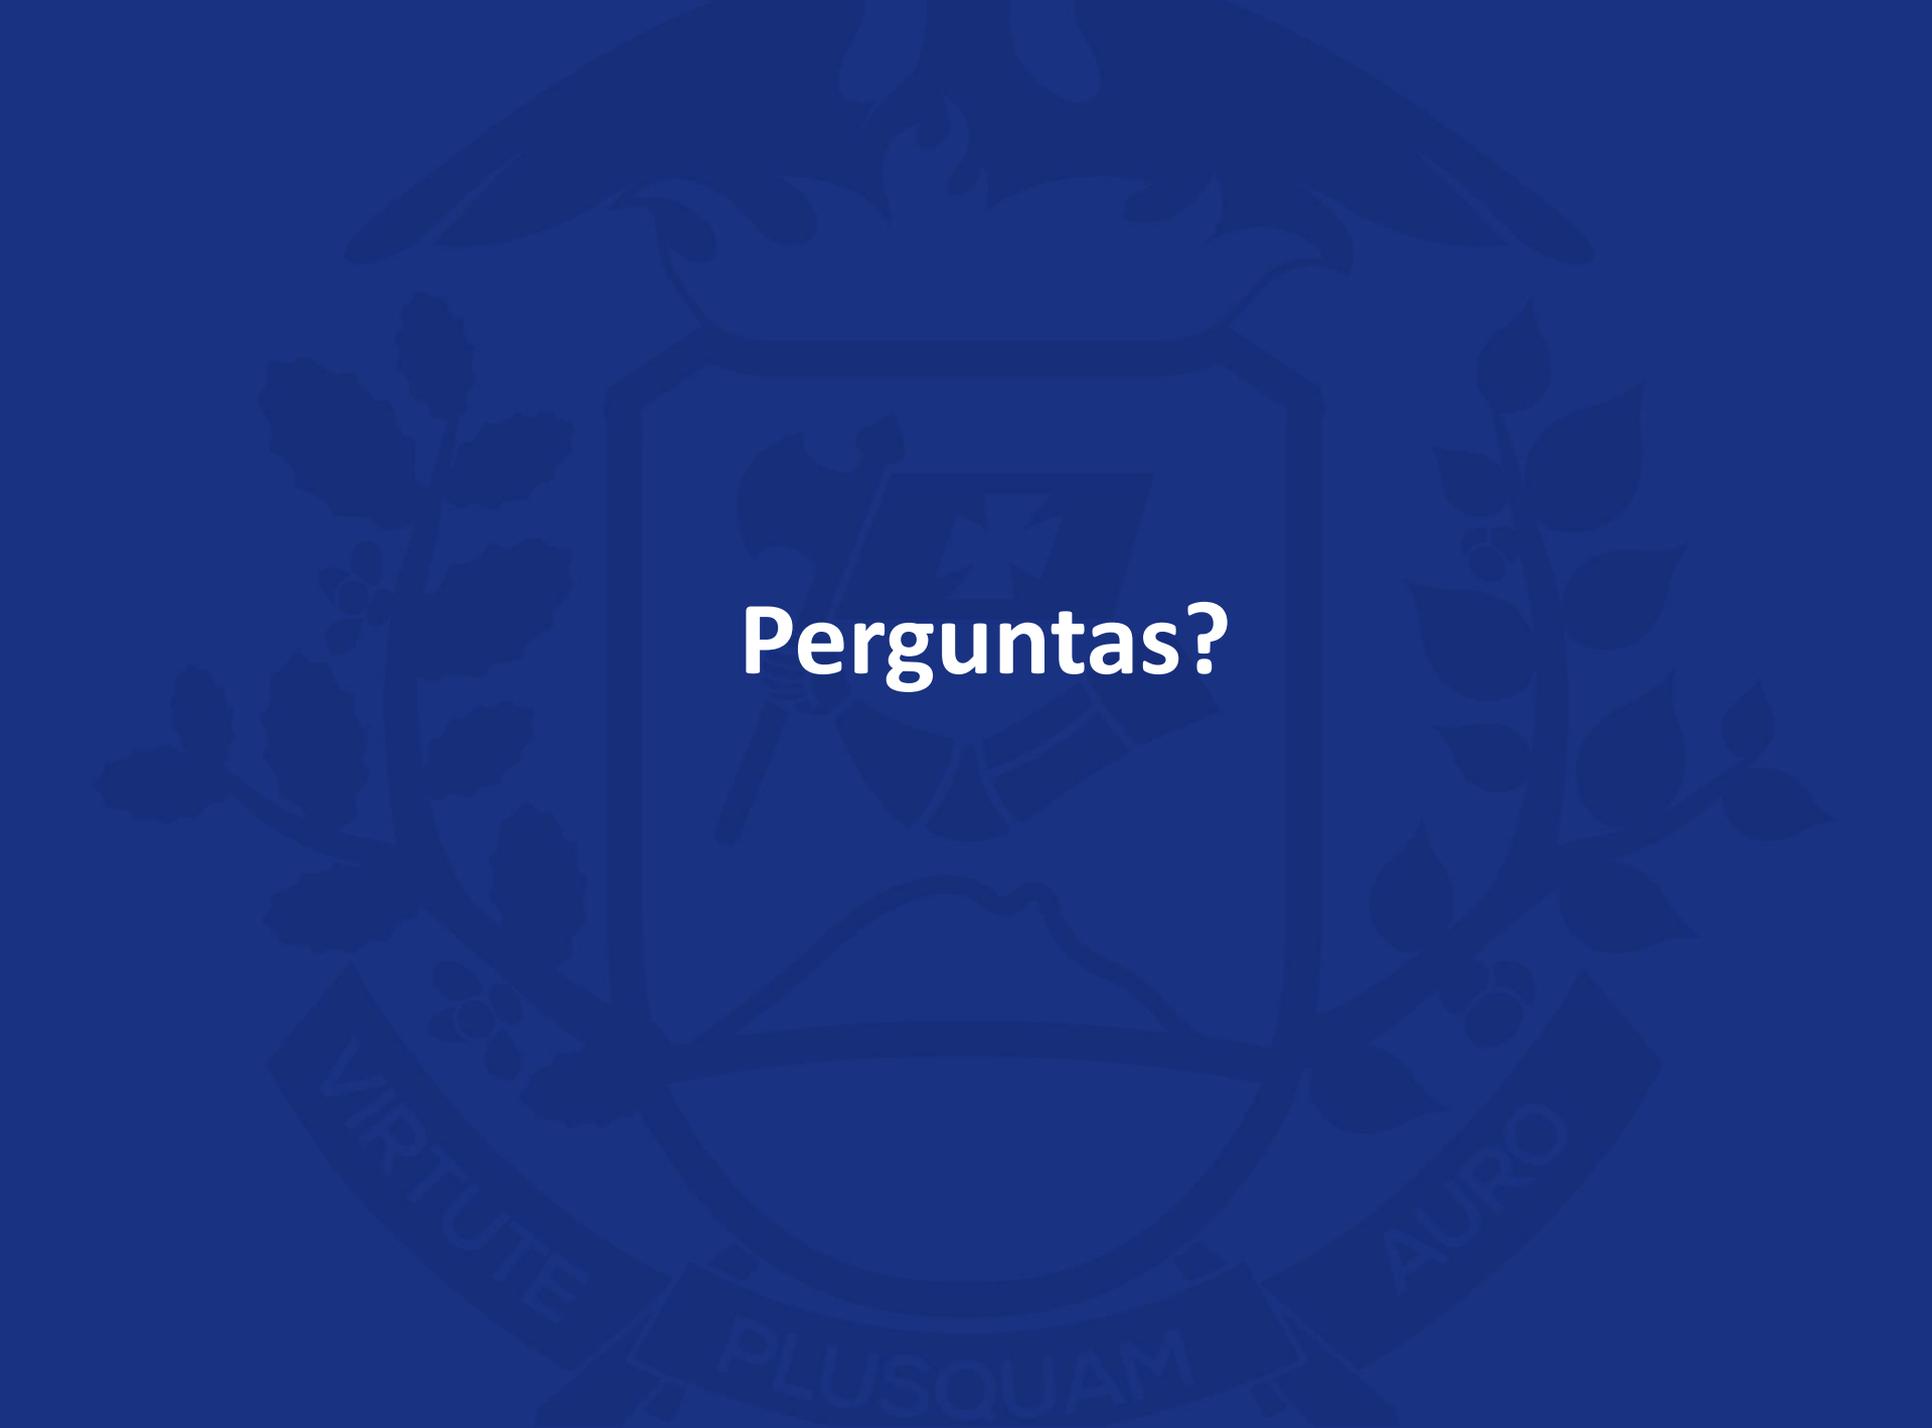


Estado Atual

- Carga inicial dos logs feita
- Buscas pelos IPs que foram especificados
- Algumas outras análises

Planos Futuros

- Criar um processo para salvar os logs no cluster
- Continuar o processo de análise e monitoramento dos logs



Perguntas?