


Estratégias big data para análise de tráfego hostil



Liane Tarouco, Cesar Loureiro ,
Afonso Comba de Araujo Neto, Leandro Bertholdo
POP/RS e UFRGS
GTS 24 , São Paulo 28 de novembro de 2014

Resumo

- Estratégias de big data passíveis de uso na análise de registros de acessos hostis com vistas a auxiliar na identificação de padrões ocultos.
- Etapas de análise preditiva usadas para construir um modelo dos dados capaz de auxiliar e dar suporte às decisões de aprimoramento das regras de controle de acesso, com vistas à sua otimização.
- O estudo de caso: registros de log de acessos a um honeypot e de acessos rechaçados por um firewall.




Big data



- Quantidade de informação no mundo dobra a cada 20 meses
- Pesquisa automatizada ou aumentada por computador
- Mineração de dados – elucidar parâmetros, identificar padrões → prever futuras ocorrências
- Mineração de dados é definido como o processo de descobrir padrões nos dados.
- O processo deve ser automático ou semi-automático
- Os padrões descobertos devem ser significativos e levar a alguma vantagem
- Os dados usados são usualmente volumosos

Big data

- Padrão dos dados → previsões
- Padrão detectado
 - Caixa preta
 - Caixa transparente
- Padrão percebido pode ser representado em termos de uma estrutura que pode ser examinada, pensada e usada para apoiar decisões futuras
- Técnicas para descrever os padrões estruturais dos dados



Algoritmos usados em big data

- Aprendizagem automatizada
 - machine learning
- Conjunto de exemplos usado para treinar o algoritmo
- Aprendizagem deve levar a um desempenho melhor no futuro
 - Decisões
 - Aceitar
 - Rejeitar
 - Zona cinza



Performance

- Fidedignidade
 - Falsos positivos e negativos
- Aspectos éticos e institucionais
 - Barrar preventivamente ?



Estilos de aprendizagem em mineração de dados

- Classificação – forma de atribuir classificação aos futuros dados
- Associação – relacionamentos entre características
- Agrupamento – reunião em grupos para tratamento diferenciado
- Previsão numérica – prever valor derivado dos dados


Tecnologia

- Software de **Big Data** recolhe todos os dados que uma organização gera e permite que os administradores e analistas encontrem novas maneiras de usá-los para fins de análise preditiva



Big data : preparação dos dados

- Conjunto exemplo
- Atributos
 - Nominal – enumerados, discretos
 - Numéricos
- Preparação e limpeza dos dados consome considerável tempo e esforço
 - Valores faltando
 - Registros duplicados
 - Pontos anormais
 - Valores derivados
 - Normalização



Big Data Security Analytics



Barbarians at the gate

- Ajudar a reduzir falsos positivos
- Lidar com ameaças avançadas persistentes

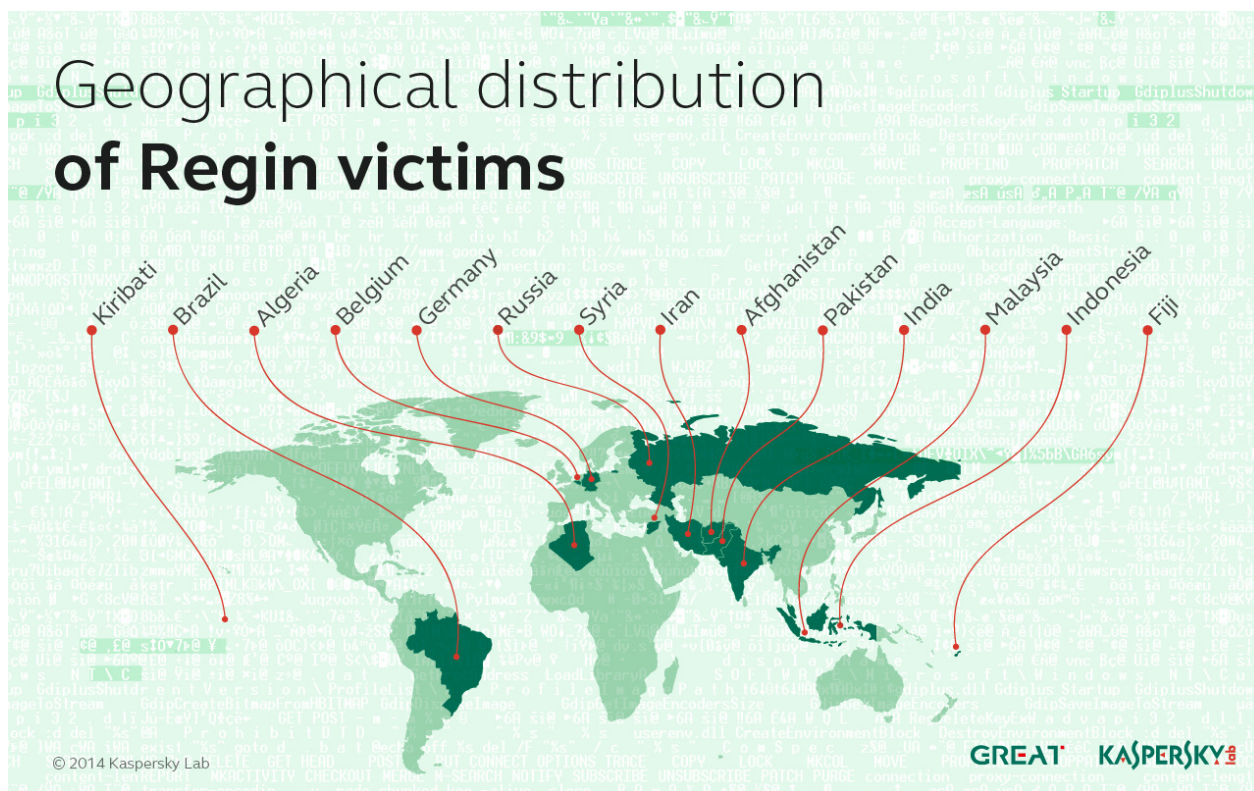
Big data e segurança

- Ataques tradicionais
 - Estratégias mais conhecidas
 - Detecção – padrão e intensidade
- Ataques avançados persistentes
 - Lentos
 - Baixo tráfego
- Detectar uso abusivo de conta
- Identificar exfiltração de dados
- Alertar sobre a execução de novo programa




Regin

- Desde 2008
- Tem atacado nos últimos 6 anos
- Ataca principalmente empresas de telecomunicações e internet e órgãos políticos multinacionais e instituições de investigação financeira
- Ele é o mais discreto possível, dando acesso a invasores para que possam monitorar, não destruir




Cibercrime

- Cibercrime é a maior preocupação das empresas
 - FBI – 50% das grandes empresas norte-americanas foram atacadas pelos chineses; 50% das grandes empresas norte-americanas foram atacadas pelos chineses e não sabem
- Uso de botnets se alastrando
- Blacklists
 - Manutenção
 - IPv6 – dificuldades (Verisign)



SIEM

- SIEM - Security Information and Event Management
- O conceito de **SIEM** é relativamente novo.
- Surgiu em 1999 e evoluiu gradativamente com novas funções.
- A grande maioria dos sistemas e aplicações disponíveis em uma rede corporativa geram eventos que são armazenados em **logs**
- Dados adicionais podem ser obtidos ou comprados de fontes externas



Tendências atuais


- 2013 → 2014
- Aumento da quantidade de ataques
- Aumento na banda
- Aumento dos ataques à infraestrutura
- Diminuição na duração dos ataques
 - Ataques mais curtos e mais intensos
- Aumento na banda de pico usada




Chris Beal – MCNC
Internet2 Technology Exchange

Tendências dos DDoS

Infrastructure Layer: 89.29%



Application Layer: 10.71%



Source: Prolexic Quarterly Global DDoS Attack Report – Q2 2014

Ataques de amplificação



NetBIOS 3.8x
SNMP 6.3x



DNS 29x - 54x
QOTD 140x




CHARGEN 359x
NTP 557x



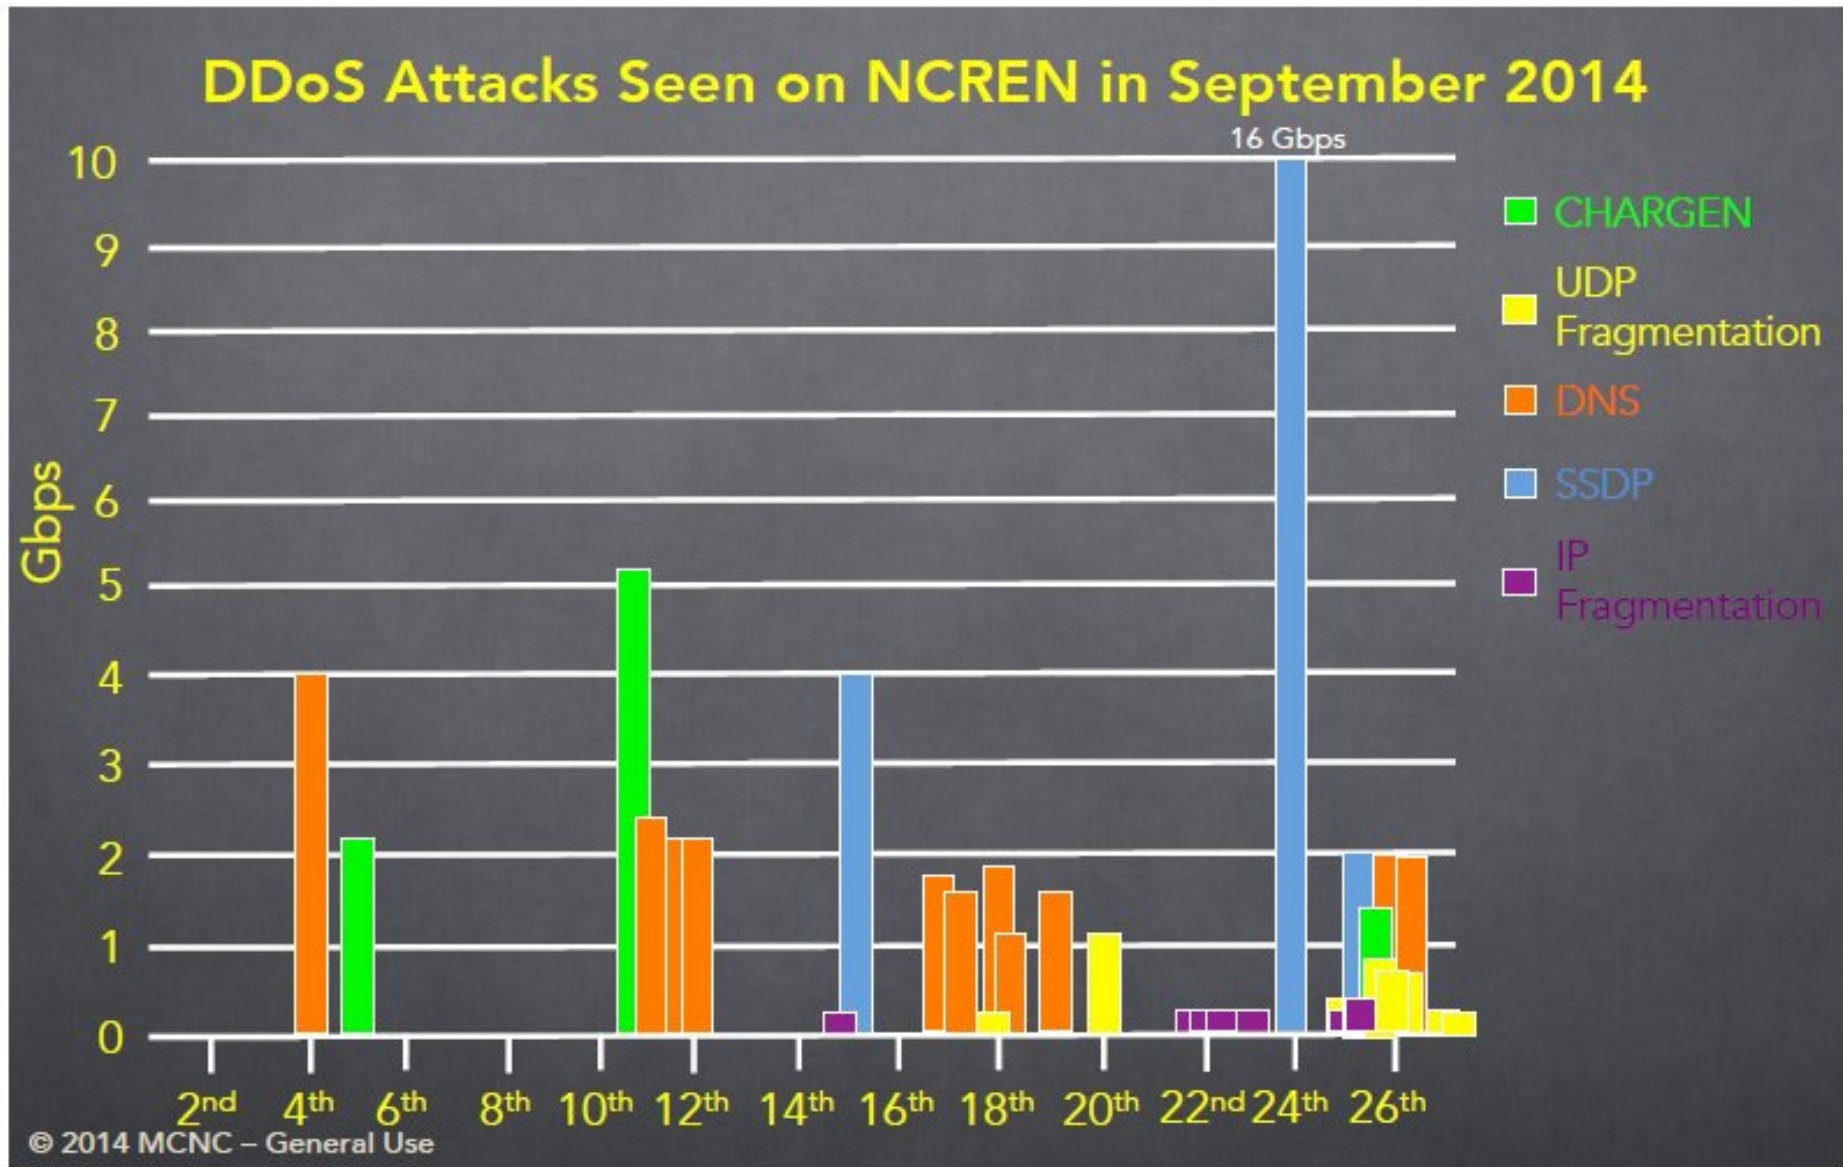
NCREN DDoS Attack Data



DDoS Attacks Seen on NCREN in February 2014



NCREN DDoS Attack Data



Observações sobre os ataques

- MCNC - tendências similares às da indústria
 - Ataques mais curtos - NTP, + SNMP
- Maioria dos ataques visa clientes e não sistema da MCNC ou infraestrutura
 - Conteúdo Web
- Maioria dos ataques à infraestrutura
 - Fragmentação, CHARGEN, DNS, NTP, TCP SYN
- Escolas visadas mais frequentemente
 - Metade para cada segmento: K-12 & Higher-Ed
- Ataques acompanham as atividades escolares
 - Mais ataques quando as escolas estão funcionando
- Mistura de ataques direcionados e vítima “sem sorte”
 - Ataques se adaptam quando alguma mitigação é aplicada

Motivação para ataques

- K-12
 - Muitos realizados pelos estudantes
 - Suspende aulas
 - Evitar exames
 - Vingança
- Higher-Ed
 - Motivações variadas
 - Explorar vulnerabilidade de sistemas
 - DDoS relacionado com jogos
 - Outros

Proteção contra DDoS

- Ferramentas para identificar tráfego DDoS
- Detecção apenas
- Algumas vezes o cliente chama
- Comunicação com clientes quando surge problema
- Implementar filtragem direcionada quando necessário
- ACLs, black hole routing
- Trabalhar com provedores quando as crises se apresentam

Ataques de amplificação - UDP

Protocol	Bandwidth Amplification Factor	Vulnerable Command
DNS	28 to 54	
NTP	556.9	
SNMPv2	26.3	GetBulk request
NetBIOS	3.8	Name resolution
SSDP	30.8	SEARCH request
CharGEN	358.8	Character generation request
QOTD	140.3	Quote request
BitTorrent	3.8	File search
Kad	16.3	Peer list exchange
Quake Network Protocol	63.9	Server info exchange
Steam Protocol	5.5	Server info exchange

Proteção almejada

- Detecção rápida
- Remediação automatizada
- Comunicação proativa

- Contrapartida almejada
- Impedir que tráfego forjado saia do backbone
 - BCP 38 / RFC2827 - Network Ingress Filtering
 - Restricting forged traffic

Análise preditiva

- Visão
 - Categorizar
 - Conhecer particularidades
 - Formular hipóteses
 - Novas categorias
- Decisão
 - Proporcionar base para tomada de decisão
 - Agilizar mediante automatização
- Precisão
 - Reduzir erro humano

Iniciando um projeto de análise preditiva

- Obter os fatos que estão ocorrendo atualmente
- Distinguir os fatos ocorrendo de outros que constituíram fatos isolados no passado
 - Tráfego incidental causado por ocorrências isoladas
- Derivar possíveis cenários futuros

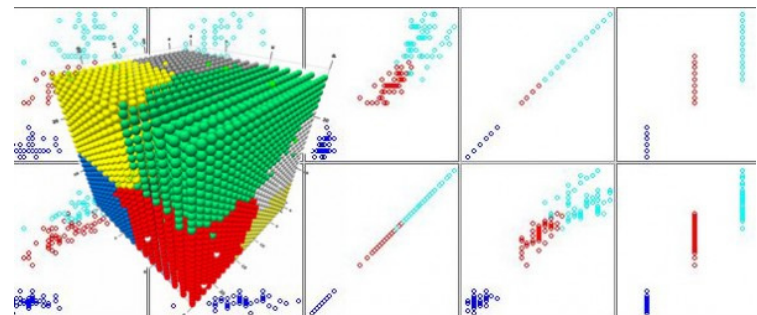
Tecnologia envolvida

- Mineração de dados
- Estatística
- Algoritmos de aprendizagem automática (machine learning)
- Software para construir o modelo



Estudo por amostragem

- Um dia normal ...
 - Honeypot
 - >49000 entradas
 - > > 7 Mbytes
 - Firewall
 - >250000 entradas
 - > 1 Gbytes



Preparação dos Dados

- Log do Honeypot do CERT/RS (AS 2716)
 - Formato único
- Log do Firewall da UFRGS (AS 19200)
 - 12 formatos de mensagens diferentes (muito cat, grep, cut, awk...)
- Conversão de formatos : IP2DEC


Perfil Ataques – GTS 2005

- Inicio Projeto Honeypot

POP-RS / CERT-RS

Origem das Tentativas de Acesso

Tentativas de Acesso




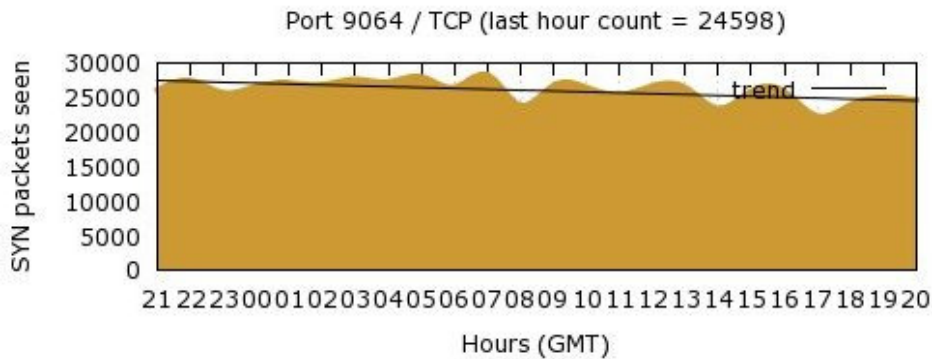


Acessos ao honeypot

País	Frequência	País	Frequência
USA	823	Japão	91
China	509	Italia	87
Russia	292	Bulgaria	86
Venezuela	291	Alemanha	70
Taiwan	221	Indonesia	68
Brasil	202	Mexico	68
França	171	Vietnam	64
India	169	Espanha	62
Korea	162	Holanda	59
Canada	127	Inglaterra	59
Romania	115	Hong Kong	56
Turquia	104	Argentina	50

Amostragem de um 1 dia no honeypot local

Consórcio honeypot brasileiro



9064 – EMC2 (Legato) Networker or Sun Solcitime Backup (Official)

445 – SMB over TCP/IP

22 – SSH


23 - telnet

Algumas observações

- Acessos honeypot
 - 97 % - tcp
 - 1848 (em 49036) também apareceram no log do firewall da UFRGS no mesmo dia (3,76 %)
 - Rajadas de port scan
 - Análise de valores atípicos


Análise do conjunto exemplo

- IPs que acessaram o Honeypot e foram barrados no firewall da UFRGS – 1848 IPs
- Distribuídos em 50 países diferentes.
- Top 10




- Brasil: 4

Distribuição dos IPs atacantes

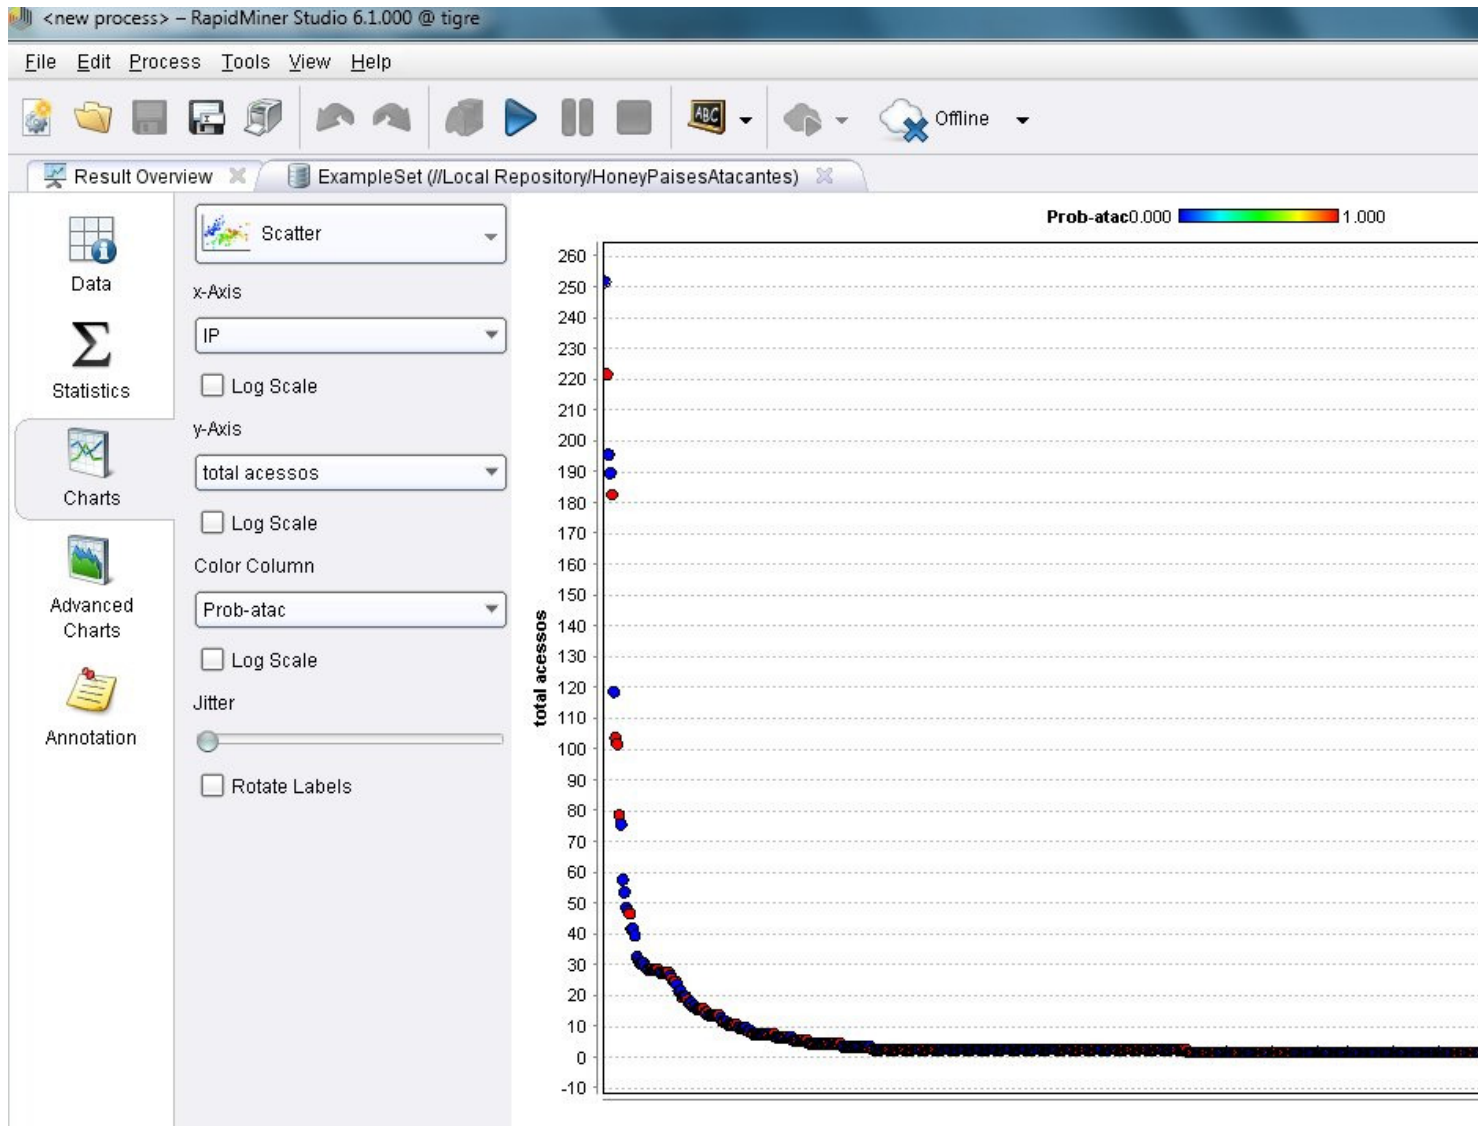


Origem dos IPs atacantes

Acessos honeypot



Honeyd & Firewall



Informações para contato

- CERT RS <http://www.cert-rs.tche.br/>
- TRI UFRGS <http://www.ufrgs.br/tri/>

