

インターネット計測とデータ解析 第10回

長 健二郎

2010年12月15日

前回のおさらい

インターネットの異常や問題を計る

- ▶ 異常検出
- ▶ スпам判定
- ▶ ベイズ理論

今日のテーマ

データの記録とログ解析

- ▶ データフォーマット
- ▶ ログ解析手法

いろいろなログ

- ▶ web server accesslog
- ▶ mail log
- ▶ syslog
- ▶ firewall log
- ▶ IDS log
- ▶ その他 あらゆる記録

なぜログ解析をするのか？

- ▶ 現状の把握
 - ▶ 新しい発見: 技術の進歩や利用形態の変化
 - ▶ そのうえで将来予測
- ▶ セキュリティ上の問題や機器故障、それらの兆候の把握
- ▶ 解析技術の向上
 - ▶ 自動化
- ▶ 障害のレポート、問題への対応
- ▶ 記録の必要性
 - ▶ 法的理由、その他

そもそも解析されないログには意味がない
(ログを取るだけで安心してはいけない)

ログ解析の問題

- ▶ 膨大なデータ量
- ▶ 必要な情報や精度の欠如、時刻情報や内容の信憑性
- ▶ (収集システムの障害などによる) 記録の欠落
- ▶ さまざまなフォーマットが存在
- ▶ 解析には時間と労力が必要
- ▶ 解析は難しいという思い込み

ログの管理

- ▶ ログ収集
 - ▶ プログラミング (syslog API の利用など)
 - ▶ 収集システム構築
- ▶ ログローテーション
 - ▶ 古いデータを一定期間保存した後削除
 - ▶ ログサイズ、時間、データの古さ
 - ▶ ローテーション時にデータを失わないよう工夫
- ▶ RRD (Round Robin Database)
 - ▶ 古いログを集約することで、データサイズを一定にする
 - ▶ 例: 5分粒度で1週間、2時間粒度で1カ月、1日粒度で1年
- ▶ 可視化
 - ▶ グラフ化して web に貼ることで状況の把握を容易に

さまざまなフォーマット

- ▶ web server access log
- ▶ mail log
- ▶ DHCP server log
- ▶ syslog

web server access log

- ▶ Apache Combined Log Format
 - ▶ Common Log Format に referer と User-agent を追加
 - ▶ client_IP client_ID user_ID time request status_code size
referer user-agent

例:

```
127.0.0.1 - frank [10/Oct/2000:13:55:36 -0700] \  
"GET /apache_pb.gif HTTP/1.0" 200 2326 \  
"http://www.example.com/start.html" \  
"Mozilla/4.08 [en] (Win98; I ;Nav)"
```

mail log

受信、送信などのメール処理毎にログが取られる
例:

```
Oct 27 13:32:54 server3 sm-mta[24510]: m9R4WsBe024510:\
  from=<client@example.com>, size=2403, class=0, nrcpts=1 \
  msgid=<201012121547.oBCF1PX6032787@example.com>, \
  proto=ESMTP, daemon=MTA, relay=mail.example.co.jp [192.0.2.1] \
Oct 27 14:43:04 server3 sm-mta[24511]: m9R4WsBe024510: \
  to=<user@example.co.jp>, delay=01:10:10 xdelay=00:00:00, \
  mailer=local, pri=32599, dsn=2.0.0, stat=Sent
```

- ▶ 時刻
- ▶ ホスト名
- ▶ プロセスオーナー [プロセス番号]
- ▶ Queue ID: メールの内部 ID
- ▶ ...
- ▶ nrcpts: 受信者数
- ▶ relay: 次の送信先サーバ
- ▶ dsn: Delivery Status Notification, RFC3463
 - ▶ 2.X.X:Success, 4.X.X:Persistent Transient Failure,
 - ▶ 5.X.X:Permanent Failure
- ▶ stat: Message Status
 - ▶ Sent, Deferred, Bounced, etc

DHCP server log

SYSLOG: メッセージの記録

```
Oct 28 15:04:32 server33 dhcpd: DHCPDISCOVER from 00:23:df:ff:a8:a7 via eth0
Oct 28 15:04:32 server33 dhcpd: DHCPOFFER on 192.168.2.101 \
  to 00:23:df:ff:a8:a7 via eth0
Oct 28 15:04:32 server33 dhcpd: DHCPREQUEST for 192.168.2.101 \
  from 00:23:df:ff:a8:a7 via eth0
Oct 28 15:04:32 server33 dhcpd: DHCPACK on 192.168.2.101 \
  to 00:23:df:ff:a8:a7 via eth0
Oct 28 15:09:32 server33 dhcpd: DHCPREQUEST for 192.168.2.101 \
  from 00:23:df:ff:a8:a7 via eth0
Oct 28 15:09:32 server33 dhcpd: DHCPACK on 192.168.2.101 \
  to 00:23:df:ff:a8:a7 via eth0
```

dhcpd.leases: 割り当てた IP アドレスの個別情報

```
lease 192.168.100.161 {
  starts 4 2010/12/09 23:13:39;
  ends 5 2010/12/10 00:13:39;
  tstp 5 2010/12/10 00:13:39;
  binding state free;
  hardware ethernet 5c:26:0a:17:06:00;
}
```

- ▶ UNIX系OSで任意のメッセージを通知したり保存する仕組み
 - ▶ もともとメールの処理記録保存用だったが広く使われるようになった
 - ▶ 他のサーバに転送も可能
 - ▶ ログのローテーション機能のサポート
- ▶ Windows Event Log

ログ解析手法

- ▶ 思いつくことを色々試す、グラフ化する
 - ▶ 手を動かしている内に分かる事、思いつく事が多い
- ▶ 処理スクリプトとコマンドラインツール (grep, sort, uniq, sed, awk, etc)
- ▶ 大量データを効率よく処理する工夫
- ▶ 繰り返し行う処理はできるだけ自動化する
 - ▶ いっぽうで自動化した処理を過信しないこと

大量データの扱い

- ▶ ナイーブにやると膨大なデータの読み込みや処理テーブルが必要
 - ▶ データ構造やアルゴリズムを勉強しておく役立つ
- ▶ 大量データを扱う工夫
 - ▶ 集計に不要な情報の削除
 - ▶ 時間的、空間的に集約
 - ▶ 必要に応じて分割処理
 - ▶ 必要に応じて分散並列処理
- ▶ 中間ファイルに変換する、分割処理する
- ▶ 処理に必要なメモリ量の見積り
 - ▶ データ構造を工夫する
 - ▶ 一度に処理するサイズ、次元を押える工夫
- ▶ 全体の処理時間の見積り
 - ▶ 小さいデータセットで試行
 - ▶ スケールするアルゴリズム
- ▶ メモリサイズと処理時間のトレードオフに配慮

基本的手法


- ▶ 正規表現
- ▶ 集約
- ▶ 正規化
- ▶ 閾値
- ▶ 外れ値の扱い

ログ解析の具体例


ftp.jaist.ac.jp の apache access log

- ▶ 自称日本最強のミラーサーバ
(<http://ftp-admin.blogspot.com/>)
- ▶ ソフトウェア配布が主なので普通の web server ではない
- ▶ ftp という名前だが、http がメイン
- ▶ 期間: 2010/07/18-28
 - ▶ 2 回の firefox の更新
 - ▶ その間に mozilla.org のミラーサーバ選択ポリシー変更
- ▶ 簡単な解析
 - ▶ 1 時間ごとのリクエスト数の推移
 - ▶ コンテンツごとのリクエスト数の分布

1時間ごとのリクエスト数の推移




Firefox update




コンテンツごとのリクエスト数分布

Content popularity distribution




コンテンツごとのリクエスト数 CDF

CDF of Content popularity distribution




コンテンツごとのリクエスト数 CCDF


CCDF of Content popularity distribution



リクエスト数によるグループ分け



リクエスト数によるグループ分け



まとめ

データの記録とログ解析

- ▶ データフォーマット
- ▶ ログ解析手法

次回予定

第 11 回 データマイニング (12/22)

- ▶ パターン抽出
- ▶ クラス分類
- ▶ クラスタリング