インターネット計測とデータ解析 第3回

長 健二朗

2012年4月20日

前回のおさらい

データとばらつき

- 要約統計量 (平均、標準偏差、分布)
- グラフによる可視化
- 演習: 要約統計量計算と gnuplot によるグラフ描画

今日のテーマ

データの収集と記録

- ネットワーク管理ツール
- データフォーマット
- ログ解析手法
- 演習: ログデータと正規表現

ネットワーク管理ツール

ネットワークの構成: 日本のある ISP の場合

東京-大阪を中心に地域拠点を冗長構成で接続

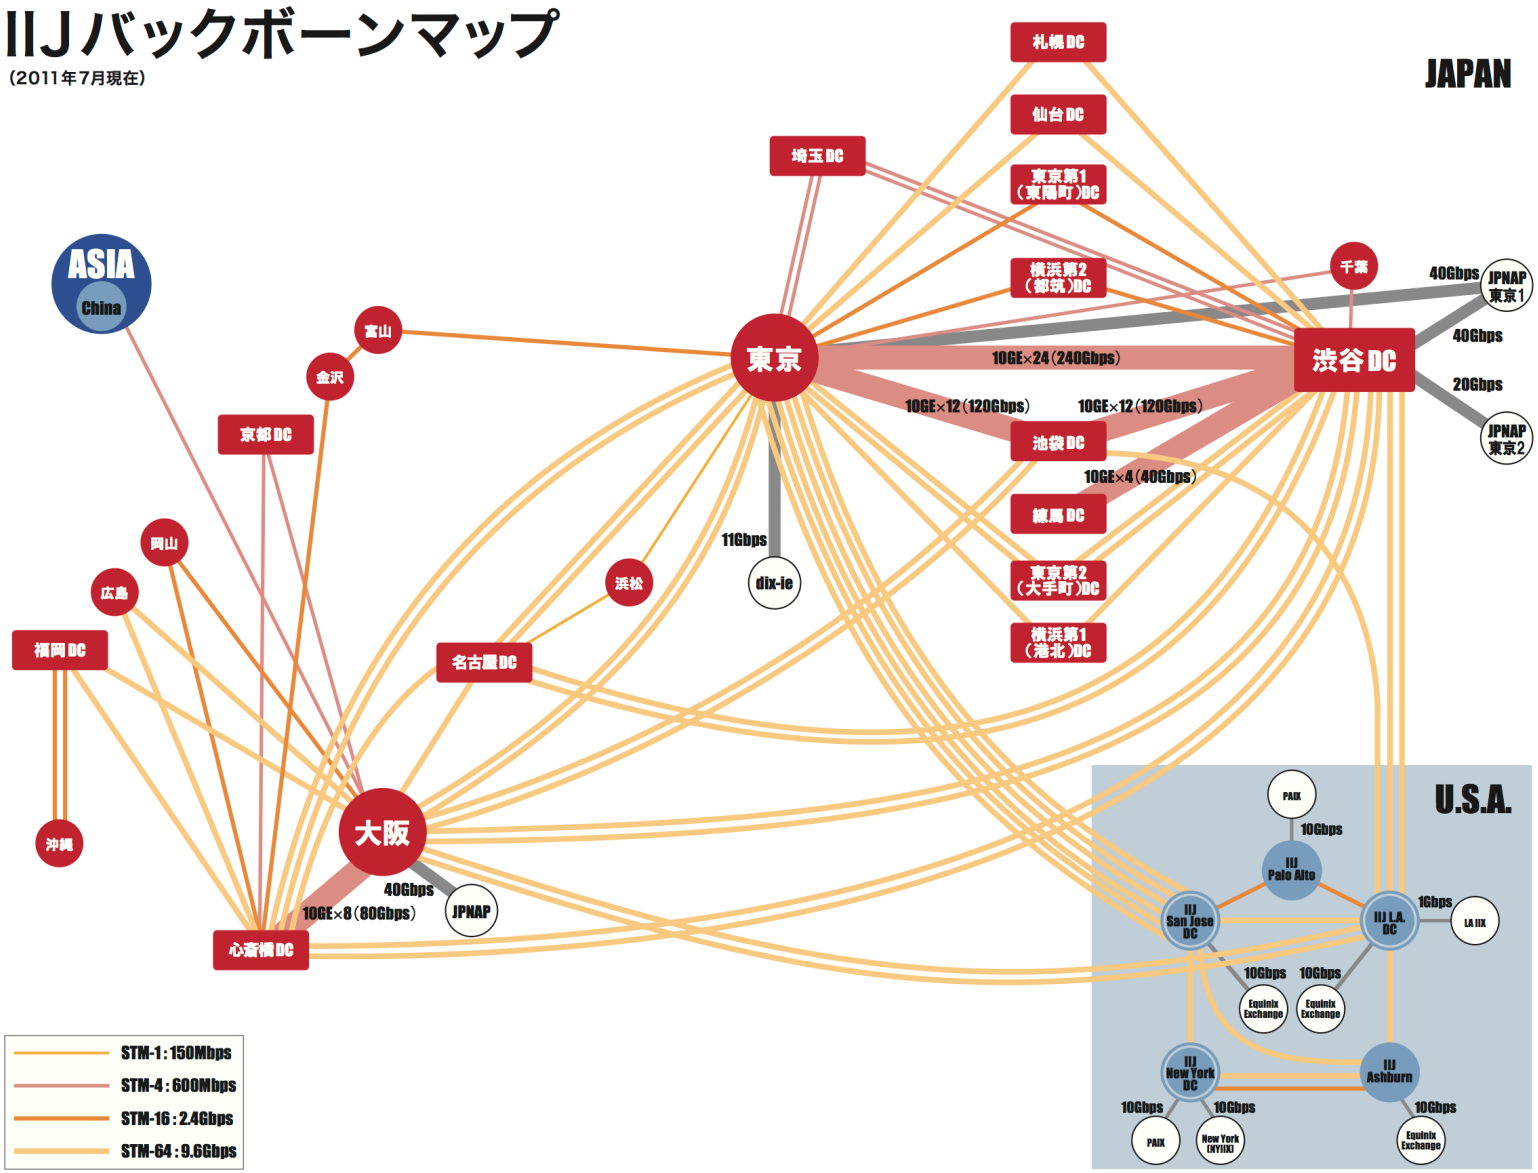

ルータ

ルータ: ネットワークを接続する装置

- 機能
  - 経路制御、パケットフォワーディング、管理機能
- ルータの分類
  - コアルータ、エッジルータ、ブロードバンドルータなど

ルータのアーキテクチャ

- fast path: ハードウェアサポート
- slow path: ソフトウェア処理
  - ICMP などの制御用パケットは通常スローパスで処理

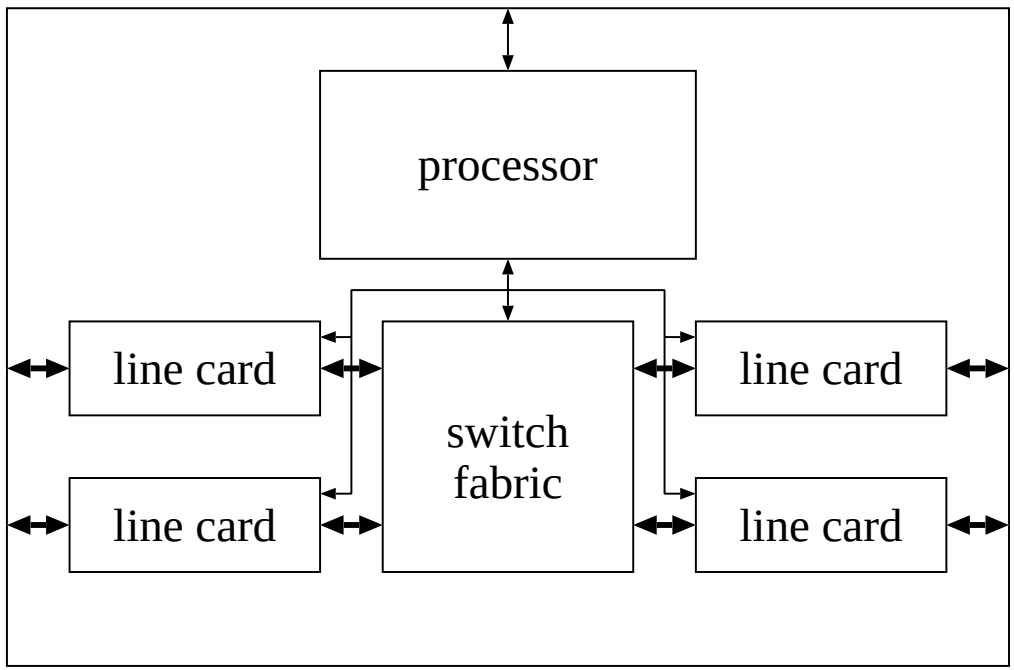

一般的なネットワーク管理ツール

ネットワークの管理用ツール (もともと計測ツールではない)

- ping
  - 到達性、ラウンドトリップタイム
- traceroute
  - 経路観測
- tcpdump
  - パケットキャプチャリング
- SNMP
  - ルータの状態把握

ping

- ネットワーク到達性確認ツール
- ICMP-echo request/reply
- 制約
  - 到達性がある $\neq$ ネットワークの正常動作
  - ICMP は遅延計測に適さない場合がある

ping sample output

```
% ping -c 10 www.ait.ac.th
PING www.ait.ac.th (202.183.214.46): 56 data bytes
64 bytes from 202.183.214.46: icmp_seq=0 ttl=114 time=112.601 ms
64 bytes from 202.183.214.46: icmp_seq=1 ttl=114 time=106.730 ms
64 bytes from 202.183.214.46: icmp_seq=2 ttl=114 time=106.173 ms
64 bytes from 202.183.214.46: icmp_seq=3 ttl=114 time=111.704 ms
64 bytes from 202.183.214.46: icmp_seq=4 ttl=114 time=112.412 ms
64 bytes from 202.183.214.46: icmp_seq=5 ttl=114 time=114.603 ms
64 bytes from 202.183.214.46: icmp_seq=6 ttl=114 time=111.755 ms
64 bytes from 202.183.214.46: icmp_seq=7 ttl=114 time=115.273 ms
64 bytes from 202.183.214.46: icmp_seq=8 ttl=114 time=106.525 ms
64 bytes from 202.183.214.46: icmp_seq=9 ttl=114 time=111.562 ms

--- www.ait.ac.th ping statistics ---
10 packets transmitted, 10 packets received, 0% packet loss
round-trip min/avg/max/stddev = 106.173/110.934/115.273/3.142 ms
```

traceroute

- IP パケットのループ検出のための TTL (time-to-live) を利用
  - ルータはパケット転送時に TTL を 1 減らす
  - TTL が 0 になると ICMP TIME EXCEEDED を送信者に返す
- 制約
  - 経路は時間とともに変化する可能性
  - 非対称な経路も存在する
    - 行きのパスしか分からない
  - 通常ルータはインターフェイス毎に IP アドレスを持つ
    - IP アドレスだけでは同一ルータか判定できない

traceroute sample output

```
% traceroute www.ait.ac.th
traceroute to www.ait.ac.th (202.183.214.46), 64 hops max, 40 byte packets
 1  202.214.86.129 (202.214.86.129)  0.687 ms  0.668 ms  0.730 ms
 2  jc-gw0.IIJ.Net (202.232.0.237)  0.482 ms  0.390 ms  0.348 ms
 3  tky001ix07.IIJ.Net (210.130.143.233)  0.861 ms  0.872 ms  0.729 ms
 4  tky001bb00.IIJ.Net (210.130.130.76)  10.107 ms  1.026 ms  0.855 ms
 5  tky001ix04.IIJ.Net (210.130.143.53)  1.111 ms  1.012 ms  0.980 ms
 6  202.232.8.142 (202.232.8.142)  1.237 ms  1.214 ms  1.120 ms
 7  ge-1-1-0.toknf-cr2.ix.singtel.com (203.208.172.209)  1.338 ms  1.501 ms
 1.480 ms
 8  p6-13.sngtp-cr2.ix.singtel.com (203.208.173.93)  93.195 ms  203.208.172.
229 (203.208.172.229)  88.617 ms  87.929 ms
 9  203.208.182.238 (203.208.182.238)  90.294 ms  88.232 ms  203.208.182.234
(203.208.182.234)  91.660 ms
10  203.208.147.134 (203.208.147.134)  103.933 ms  104.249 ms  103.986 ms
11  210.1.45.241 (210.1.45.241)  103.847 ms  110.924 ms  110.163 ms
12  st1-6-bkk.csloxinfo.net (203.146.14.54)  131.134 ms  129.452 ms  111.408
 ms
13  st1-6-bkk.csloxinfo.net (203.146.14.54)  106.039 ms  105.078 ms  105.196
 ms
14  202.183.160.121 (202.183.160.121)  111.240 ms  123.606 ms  112.153 ms
15  * * *
16  * * *
17  * * *
```

tcpdump

- パケットキャプチャリングのためのツール
  - パケットの先頭 N バイトを記録
- 柔軟なフィルタリング機能
  - 例: 特定のホストからの TCP SYN パケット
- 詳細な解析が可能

- 制約
  - データサイズが大きい
  - 高速ネットワークでは技術的に困難

tcpdump sample output

```
18:45:29.767497 IP 202.214.86.132.50052 > 202.210.220.18.80: \
  S 3304970307:3304970307(0) win 65535 <mss 1460,nop,nop,sackOK,nop, \
  wscale 1,nop,nop,timestamp 710778973 0>
18:45:29.770038 IP 202.210.220.18.80 > 202.214.86.132.50052: \
  S 3129218301:3129218301(0) ack 3304970308 win 65535 <mss 1460,nop, \
  ywscale 1,nop,nop,timestamp 2523776361 710778973,nop,nop,sackOK>
18:45:29.770090 IP 202.214.86.132.50052 > 202.210.220.18.80: \
  . ack 1 win 33304 <nop,nop,timestamp 710778973 2523776361>
18:45:29.787084 IP 202.214.86.132.50052 > 202.210.220.18.80: \
  P 1:521(520) ack 1 win 33304 <nop,nop,timestamp 710778975 2523776361>
18:45:29.791392 IP 202.210.220.18.80 > 202.214.86.132.50052: \
  P 1:222(221) ack 521 win 33304 <nop,nop,timestamp 2523776363 710778975>
18:45:29.887024 IP 202.214.86.132.50052 > 202.210.220.18.80: \
  . ack 222 win 33304 <nop,nop,timestamp 710778985 2523776363>
18:45:34.792726 IP 202.210.220.18.80 > 202.214.86.132.50052: \
  F 222:222(0) ack 521 win 33304 <nop,nop,timestamp 2523776864 710778985>
18:45:34.792763 IP 202.214.86.132.50052 > 202.210.220.18.80: \
  . ack 223 win 33304 <nop,nop,timestamp 710779475 2523776864>
18:45:42.528539 IP 202.214.86.132.50052 > 202.210.220.18.80: \
  F 521:521(0) ack 223 win 33304 <nop,nop,timestamp 710780249 2523776864>
18:45:42.531088 IP 202.210.220.18.80 > 202.214.86.132.50052: \
  . ack 522 win 33303 <nop,nop,timestamp 2523777637 710780249>
```

SNMP (Simple Network Management Protocol)

- SNMP
  - リモートから情報問い合わせ、情報の格納、トラップの設定
  - UDP の利用 (信頼性がない)
- 標準化されたトラフィック統計情報
  - ほとんどのルータ、スイッチ、ホスト OS に実装
  - 多くの管理ツールが存在
- MIB (Management Information Base)
  - SNMP オブジェクトの木構造データベース
    - 例: interfaces.ifTable.ifEntry.ifOutOctets
    - 標準 MIB とプライベート MIB
  - get, set, get-next to access MIB
- 制約
  - 標準化されている情報は限られている
  - オブジェクトのサポートを後から追加することは難しい
  - アクセスの効率が悪い

フロー計測

- SNMP によるインターフェイスカウンタ値による計測の限界
  - 総量は分かるが、それ以上の情報取得が困難
- フローベースの計測
  - 5 tupples (protocol, srcaddr, dstaddr, srcport, dstport), AS, etc
  - プロトコル: NetFlow、 sFlow、 IPFIX、 ...
- サンプリングによるデータ量削減も可能

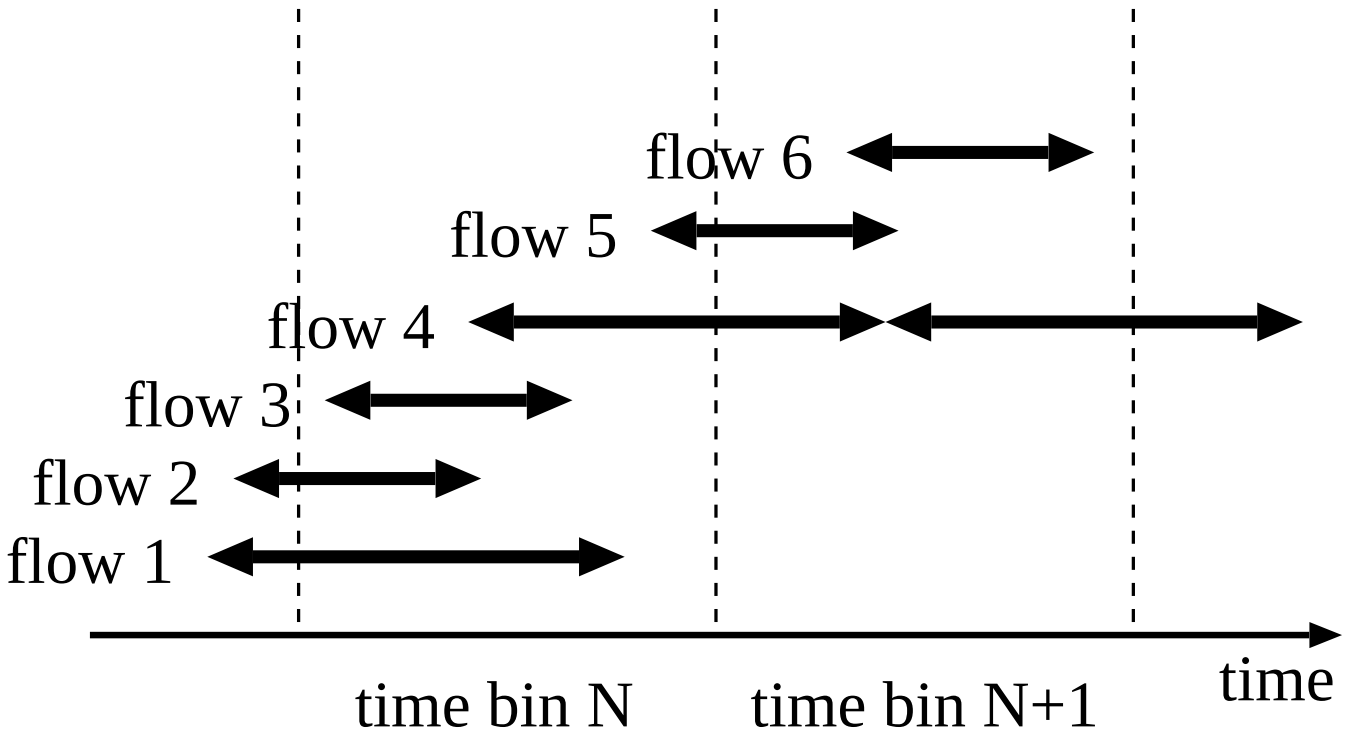

MRTG

- SNMP データをグラフ化するツール
- 古い時系列データを集約しデータ量を一定にする仕組み
  - daily, weekly, monthly, yearly
- inbound/outbound traffic
  - 他の時系列データにも利用可能

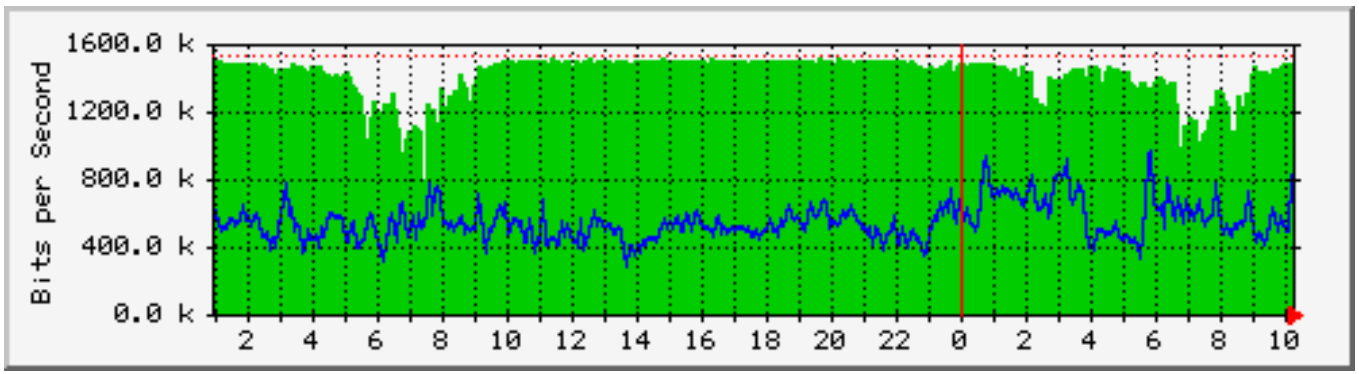

RRDtool

- RRDtool: MRTG の作者による後継ツール
  - 柔軟な設定が可能に
  - 任意の時系列データを扱えるよう工夫
- flowscan による RRDtool を使った NetFlow データのグラフ

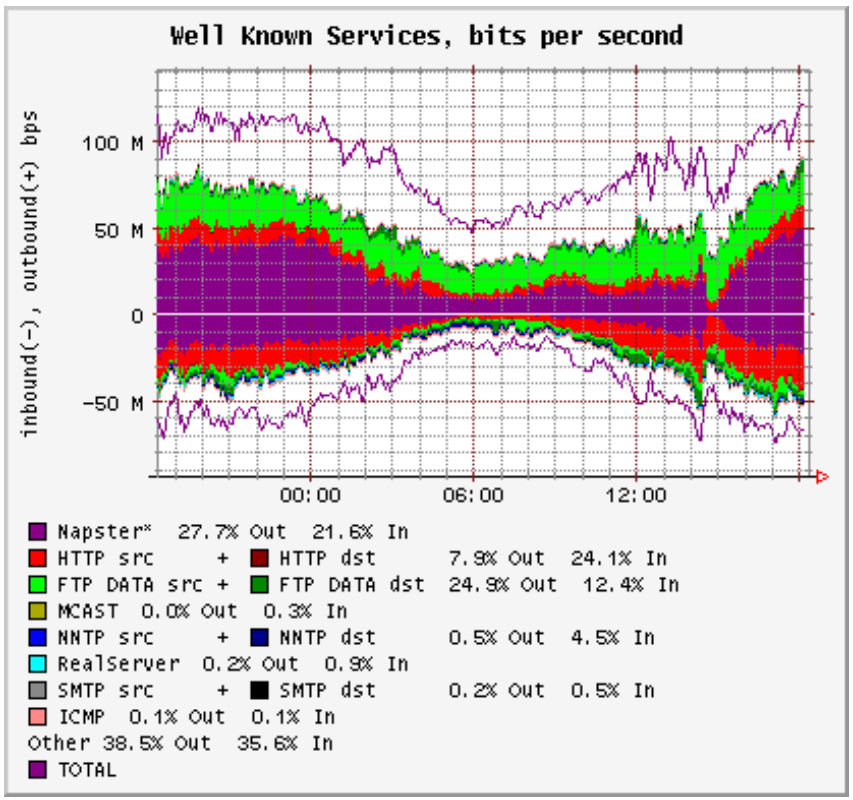

from caida web site

ネットワーク管理ツールのまとめ

- もともと管理用ツールで計測ツールではない
- 多くの計測で利用されている
- 利用に際しては仕組みと制約を理解する必要がある

データフォーマット

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 サーバへのアクセス

- HTTP プロトコル
- リクエスト/レスポンス

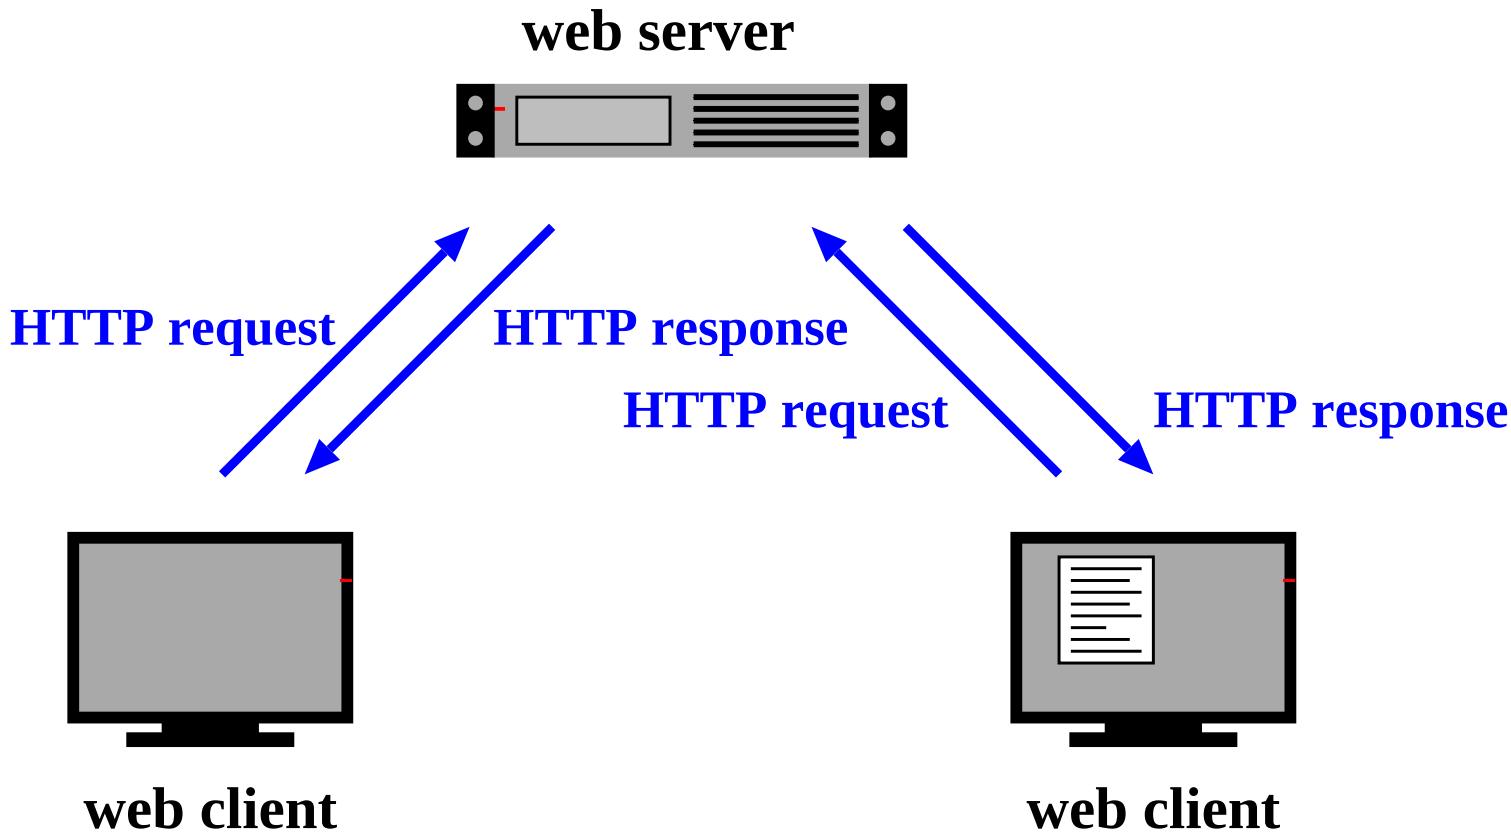

web server access log

- Apache Common Log Format
  - client_IP client_ID user_ID time request status_code size
- 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
- その他 カスタマイズ可能

client_IP: アクセス元の IP アドレス
client_ID: クライアントの識別子
user_ID: 認証ユーザ名
time: 時刻
request: リクエストの最初の行
status_code: レスポンスステータス
size: 送信バイト数 (ヘッダーは含まず) 0 バイトだと"-"
referer: リクエストのリンク元
user-agent: リクエスト元のブラウザの種類やバージョン

例 Combined Log Format:

```
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.oBCFlPX6032787@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;
}
```

syslog

- 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

Web クローラ

クローラ (crawler) によるデータの収集

- クローラ: 自動でデータを収集するプログラム
- web クローラ: web ページを自動巡回する
  - 検索用データベースやインデックスの作成など
  - ページ内のリンクを辿って次のページへ
- いろいろツールが存在
  - 急激なアクセスは攻撃と思われるので注意

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と役立つ
- 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

正規表現 (regular expression)

正規表現

- 文字列パターンの表記法、文字列の検索や置換に利用
- もともとは形式言語理論において正規言語を表すための手段
- 文字列のパターンマッチのための記法として普及
  - grep, expr, awk, vi, lex, perl, ruby, ...

Ruby の正規表現

```
Regexp class
regular expression literal: /regexp/opt
=~ operator: subject =~ /regexp/
match() method:  /regexp/.match(subject)
string class: string.match(/regexp/)
```

Ruby の正規表現クイックレファレンス

```
[abc]  A single character: a, b or c
[^abc]  Any single character but a, b, or c
[a-z]  Any single character in the range a-z
[a-zA-Z]  Any single character in the range a-z or A-Z
^  Start of line
$  End of line
\A  Start of string
\z  End of string
.  Any single character
\s  Any whitespace character
\S  Any non-whitespace character
\d  Any digit
\D  Any non-digit
\w  Any word character (letter, number, underscore)
\W  Any non-word character
\b  Any word boundary character
(...)  Capture everything enclosed
(a|b)  a or b
a?  Zero or one of a
a*  Zero or more of a
a+  One or more of a
a{3}  Exactly 3 of a
a{3,}  3 or more of a
a{3,6}  Between 3 and 6 of a
```

Ruby の正規表現クイックレファレンス (つづき)

```
options:
i case insensitive
m make dot match newlines
x ignore whitespace in regex
o perform #{...} substitutions only once
```

最長マッチと最短マッチ (最短マッチの方が高速)

"*"や"+"は最長マッチ、"*?"や"+?"は最短マッチ

```
/<.*>/.match("<a><b><c>")  # => "<a><b><c>"
/<.*?>/.match("<a><b><c>") # => "<a>"
```

前回の演習: 要約統計量の計算

- 平均
- 標準偏差
- 中央値

- 市民マラソンのデータを使う: 出典 P. K. Janert “Gnuplot in Action”

`http://web.sfc.keio.ac.jp/~kjc/classes/sfc2012s-measurement/marathon.txt`

前回の演習: 平均の計算

- 各行から、完走時間 (分) と人数を読み合計、最後に総数で割る

```
# regular expression to read minutes and count
re = /^(\d+)\s+(\d+)/

sum = 0 # sum of data
n = 0 # the number of data
ARGF.each_line do |line|
    if re.match(line)
      min = $1.to_i
      cnt = $2.to_i
      sum += min * cnt
      n += cnt
    end
end

mean = Float(sum) / n

printf "n:%d mean:%.1f\n", n, mean
```

```
% ruby mean.rb marathon.txt
n:2355 mean:171.3
```

前回の演習: 標準偏差の計算

- アルゴリズム: $\sigma^2 = \frac{1}{n}\sum_{i=1}^{n}(x_i - \bar{x})^2$

```
# regular expression to read minutes and count
re = /^(\d+)\s+(\d+)/

data = Array.new
sum = 0 # sum of data
n = 0 # the number of data
ARGF.each_line do |line|
    if re.match(line)
      min = $1.to_i
      cnt = $2.to_i
      sum += min * cnt
      n += cnt
      for i in 1 .. cnt
        data.push min
      end
    end
end
mean = Float(sum) / n
sqsum = 0.0
data.each do |i|
  sqsum += (i - mean)**2
end
var = sqsum / n
stddev = Math.sqrt(var)
printf "n:%d mean:%.1f variance:%.1f stddev:%.1f\n", n, mean, var, stddev
```

```
% ruby stddev.rb marathon.txt
n:2355 mean:171.3 variance:199.9 stddev:14.1
```

前回の演習: 標準偏差の計算の改良

- アルゴリズムを改良: $\sigma^2 = \frac{1}{n}\sum_{i=1}^{n} x_i^2 - \bar{x}^2$

```
# regular expression to read minutes and count
re = /^(\d+)\s+(\d+)/

sum = 0 # sum of data
n = 0 # the number of data
sqsum = 0 # su of squares
ARGF.each_line do |line|
    if re.match(line)
      min = $1.to_i
      cnt = $2.to_i
      sum += min * cnt
      n += cnt
      sqsum += min**2 * cnt
    end
end

mean = Float(sum) / n
var = Float(sqsum) / n - mean**2
stddev = Math.sqrt(var)

printf "n:%d mean:%.1f variance:%.1f stddev:%.1f\n", n, mean, var, stddev
```

```
% ruby stddev2.rb marathon.txt
n:2355 mean:171.3 variance:199.9 stddev:14.1
```

前回の演習: 中央値の計算

- 各走者のタイムを配列に入れソート、中央値を取り出す

```
# regular expression to read minutes and count
re = /^(\d+)\s+(\d+)/

data = Array.new

ARGF.each_line do |line|
    if re.match(line)
      min = $1.to_i
      cnt = $2.to_i
      for i in 1 .. cnt
        data.push min
      end
    end
end

data.sort! # just in case data is not sorted

n = data.length # number of array elements
r = n / 2 # when n is odd, n/2 is rounded down
if n % 2 != 0
  median = data[r]
else
  median = (data[r - 1] + data[r])/2
end

printf "r:%d median:%d\n", r, median
```

```
% ruby median.rb marathon.txt
r:1177 median:176
```

前回の演習: gnuplot

- gnuplot を使って簡単なグラフを書く

前回の演習: ヒストグラム

- 市民マラソンの完走タイムの分布

```
plot "marathon.txt" using 1:2 with boxes
```

グラフを見やすくする (右側)

```
set boxwidth 1
set xlabel "finish time (minutes)"
set ylabel "count"
set yrange [0:180]
set grid y
plot "marathon.txt" using 1:2 with boxes notitle
```

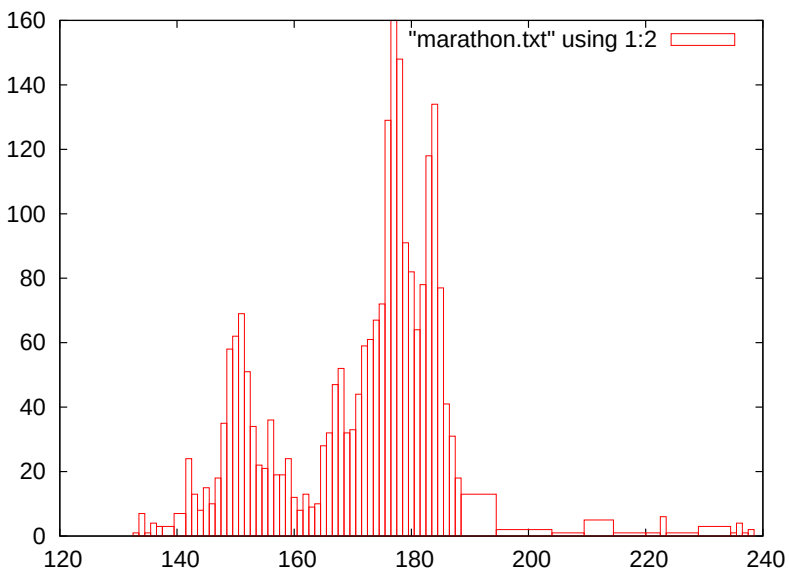

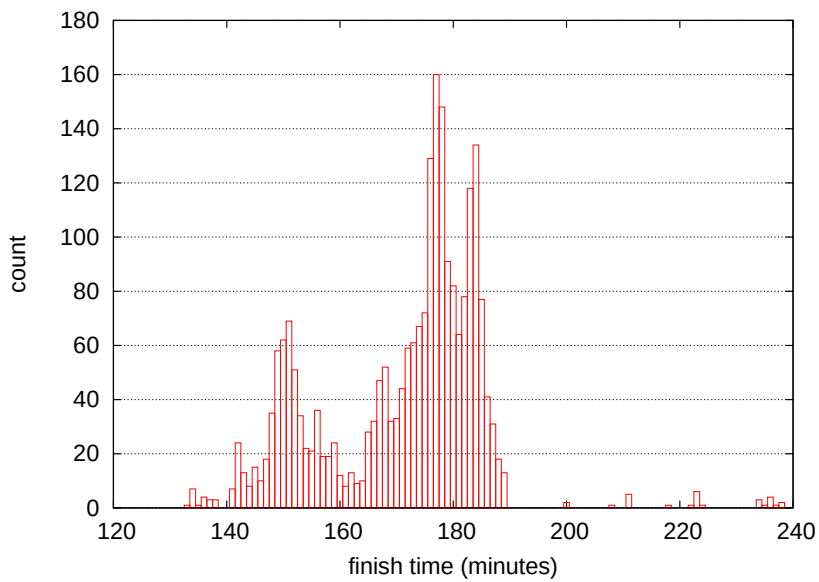

前回の演習: 完走時間の CDF の作成

元データ:

```
# Minutes Count
133 1
134 7
135 1
136 4
137 3
138 3
141 7
142 24
...
```

累積度数を追加:

```
# Minutes Count CumulativeCount
133 1 1
134 7 8
135 1 9
136 4 13
137 3 16
138 3 19
141 7 26
142 24 50
...
```

前回の演習: CDF (2)

ruby code:

```
re = /^(\d+)\s+(\d+)/
cum = 0
ARGF.each_line do |line|
  begin
    if re.match(line)
      # matched
      time, cnt = $~.captures
      cum += cnt.to_i
      puts "#{time}\t#{cnt}\t#{cum}"
    end
  end
end
```

gnuplot command:

```
set boxwidth 1
set xlabel "finish time (minutes)"
set ylabel "CDF"
set grid y
plot "marathon-cdf.txt" using 1:($3 / 2355) with lines notitle
```

前回の演習: 市民マラソンの完走時間 CDF

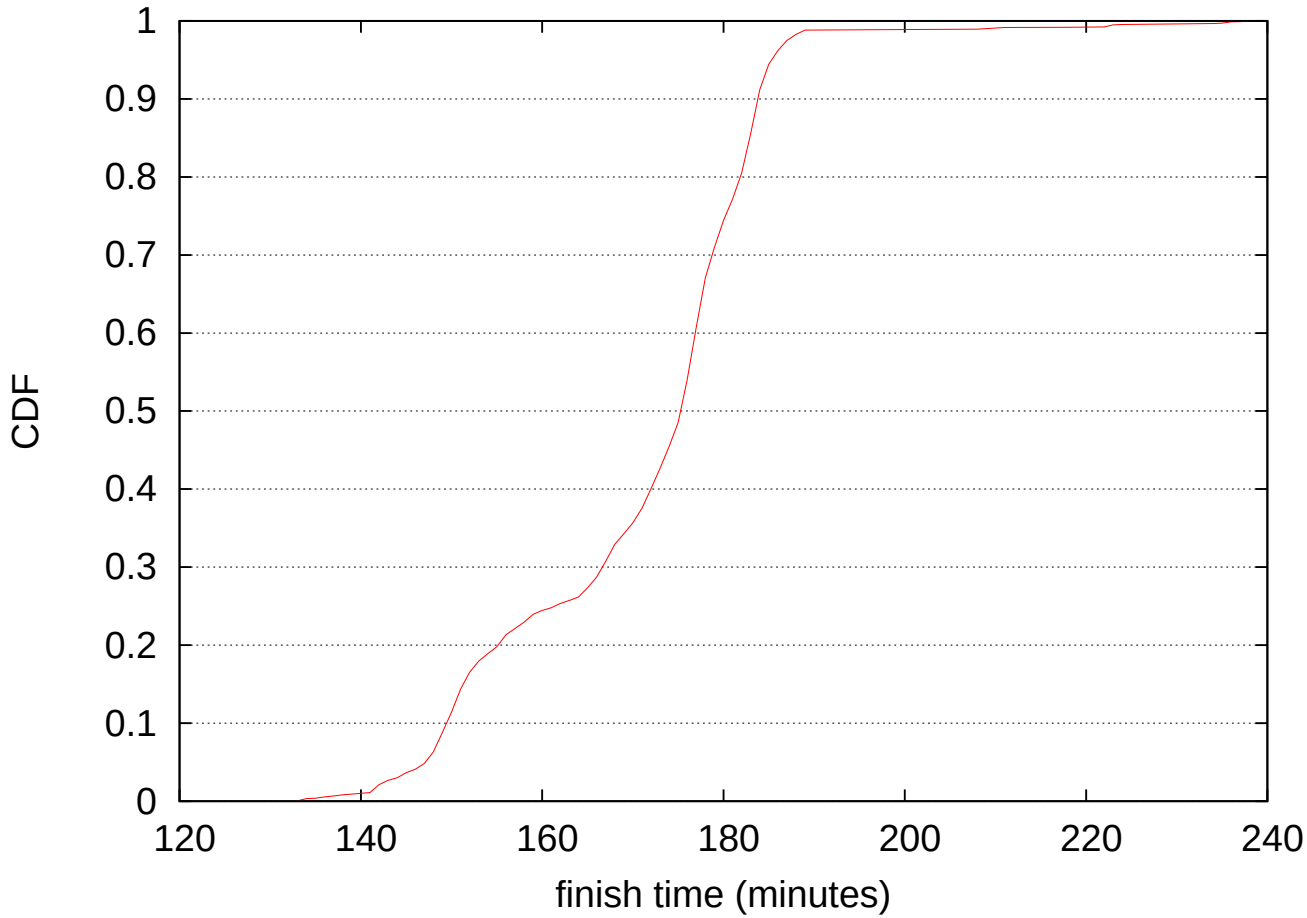

今日の演習: Web アクセスログ サンプルデータ

- apache log (combined log format)
- 自称日本最強のミラーサーバ
- 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
- 約 14MB(bzip2 圧縮)、 解凍後は約 280MB
- 1/10 sampling
- クライアント IP アドレスはプライバシーを考慮して匿名化 (1-to-1 mapping)

```
access log for 24 hours:
 http://www.iijlab.net/~kjc/classes/sfc2012s-measurement/sample_access_log.bz2
test data (first 100 lines):
 http://www.iijlab.net/~kjc/classes/sfc2012s-measurement/test-100lines
```

サンプルアクセスログ

```
143.207.214.239 - - [18/Jul/2010:23:59:53 +0900] "GET /pub/mozilla.org/firefox/releases/3.6.6/\
  update/mac/de/firefox-3.6.6.complete.mar HTTP/1.1" 206 300371 "-" "Mozilla/5.0 (Macintosh; U;\
  Intel Mac OS X 10.6; de; rv:1.9.2.3) Gecko/20100401 Firefox/3.6.3" ftp.jaist.ac.jp
161.42.4.49 - - [18/Jul/2010:23:59:20 +0900] "GET /pub/PC-BSD/8.0/i386/PCBSD8.0-x86-DVD.iso\
  HTTP/1.1" 206 58970 "http://ftp.jaist.ac.jp/pub/PC-BSD/8.0/i386" "Mozilla/4.0 (compatible;\
  MSIE 6.0; Windows NT 5.1; SV1; .NET CLR 1.1.4322; .NET CLR 2.0.50727)" ftp.jaist.ac.jp
150.107.216.201 - - [18/Jul/2010:23:59:56 +0900] "GET /pub/mozilla.org/firefox/releases/3.6.6/\
  update/win32/en-GB/firefox-3.6.6.complete.mar HTTP/1.1" 206 300368 "-" "Mozilla/5.0 (Windows;\
  U; Windows NT 6.0; en-GB; rv:1.9.2.3) Gecko/20100401 Firefox/3.6.3 (.NET CLR 3.5.30729)"\
  ftp.jaist.ac.jp
22.32.128.50 - - [19/Jul/2010:00:00:00 +0900] "HEAD /project/clamav/clamav/win32/ClamAV-0.96.1\
  -64bit-beta.zip HTTP/1.0" 200 302 "http://jaist.dl.sourceforge.net/project/clamav/clamav/\
  win32/" "Wget/1.10.2 (Red Hat modified)" jaist.dl.sourceforge.net
137.29.144.83 - - [19/Jul/2010:00:00:00 +0900] "GET /pub/mozilla.org/thunderbird/releases/\
  2.0.0.24/update/win32/en-US/thunderbird-2.0.0.24.complete.mar HTTP/1.1" 200 65845 "-"\
  "Mozilla/5.0 (Windows; U; Windows NT 5.1; en-US; rv:1.8.1.22) Gecko/20090605 Thunderbird/\
  2.0.0.22" ftp.jaist.ac.jp
22.32.128.50 - - [19/Jul/2010:00:00:00 +0900] "HEAD /project/clamav/clamav/win32/Clamunrar-\
  0.96.zip HTTP/1.0" 200 298 "http://jaist.dl.sourceforge.net/project/clamav/clamav/win32/"\
  "Wget/1.10.2 (Red Hat modified)" jaist.dl.sourceforge.net
209.235.74.175 - - [18/Jul/2010:23:59:52 +0900] "GET /pub/mozilla.org/firefox/releases/3.6.6/\
  update/win32/en-US/firefox-3.6.6.complete.mar HTTP/1.1" 206 300368 "-" "Mozilla/5.0 (Windows;\
  U; Windows NT 6.1; en-US; rv:1.9.2) Gecko/20100115 Firefox/3.6" ftp.jaist.ac.jp
153.42.115.45 - - [18/Jul/2010:23:59:56 +0900] "GET /pub/mozilla.org/firefox/releases/3.5.10/\
  update/win32/pl/firefox-3.5.10.complete.mar HTTP/1.1" 206 300368 "-" "Mozilla/5.0 (Windows;\
  U; Windows NT 6.0; pl; rv:1.9.1.5) Gecko/20091102 Firefox/3.5.5 (.NET CLR 3.5.30729)"\
  ftp.jaist.ac.jp
...
```

今日の演習: リクエスト数の時系列プロット

- サンプル Web アクセスログを使う
- リクエスト数と転送バイト数を 5 分間隔で抽出
- 結果をプロット

```
% ruby parse_accesslog.rb sample_access_log > access-5min.txt
% more access-5min.txt
2010-07-18T16:55 1 600572285
...
2010-07-18T23:55 463 2128020418
2010-07-19T00:00 4123 1766135158
2010-07-19T00:05 3963 1857342919
2010-07-19T00:10 3871 2171231118
2010-07-19T00:15 3965 4378143224
...
% gnuplot
gnuplot> load 'access.plt'
```

extract request counts and transferred bytes with 5 minutes bins

```
#!/usr/bin/env ruby
require 'date'

# regular expression for apache common log format
#   host ident user time request status bytes
re = /^(\S+) (\S+) (\S+) \[(.*?)\] "(.*?)" (\d+) (\d+|-)/
timebins = Hash.new([0, 0])
count = parsed = 0
ARGF.each_line do |line|
  count += 1
  if re.match(line)
    host, ident, user, time, request, status, bytes = $~.captures
    # ignore if the status is not success (2xx)
    next unless /2\d{2}/.match(status)
    parsed += 1
    # parse timestamp
    ts = DateTime.strptime(time, '%d/%b/%Y:%H:%M:%S %z')
    # create the corresponding key for 5-minutes timebins
    rounded = sprintf("%02d", ts.min.to_i / 5 * 5)
    key = ts.strftime("%Y-%m-%dT%H:#{rounded}")
    # count by request and byte
    timebins[key] = [timebins[key][0] + 1, timebins[key][1] + bytes.to_i]
  else
    # match failed
    $stderr.puts("match failed at line #{count}: #{line.dump}")
  end
end
timebins.sort.each do |key, value|
  puts "#{key} #{value[0]} #{value[1]}"
end
$stderr.puts "parsed:#{parsed} ignored:#{count - parsed}"
```

plot graphs of request counts and transferred bytes

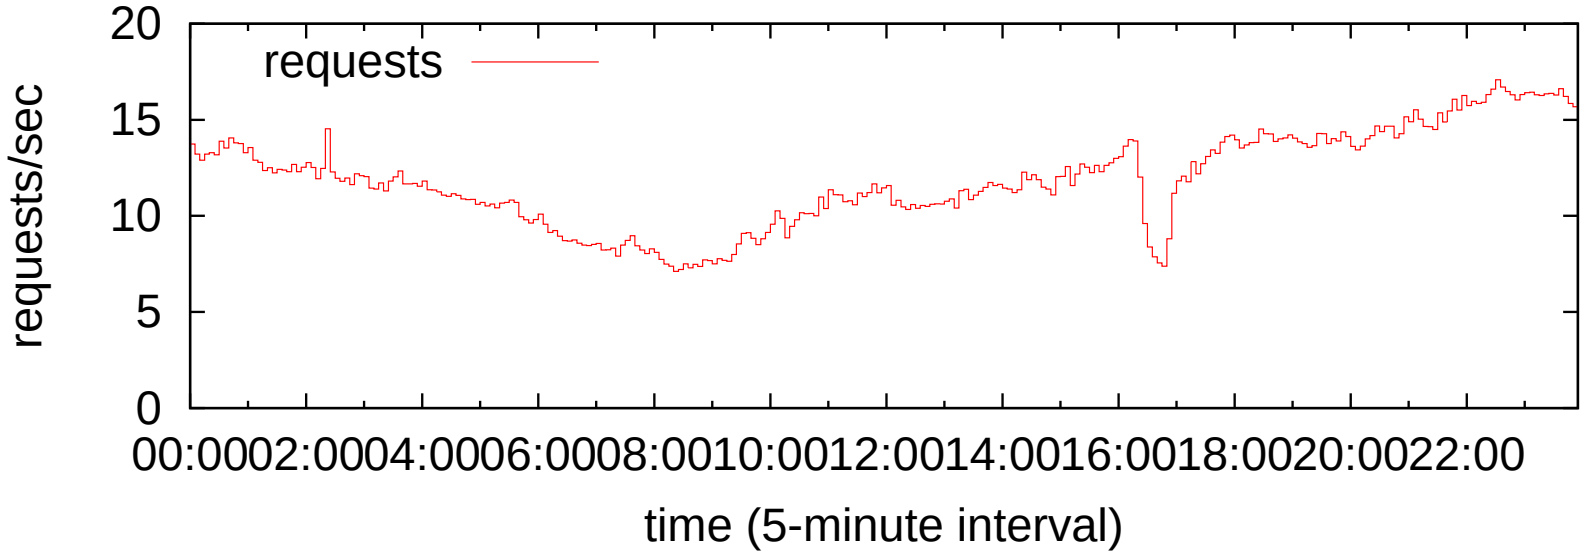

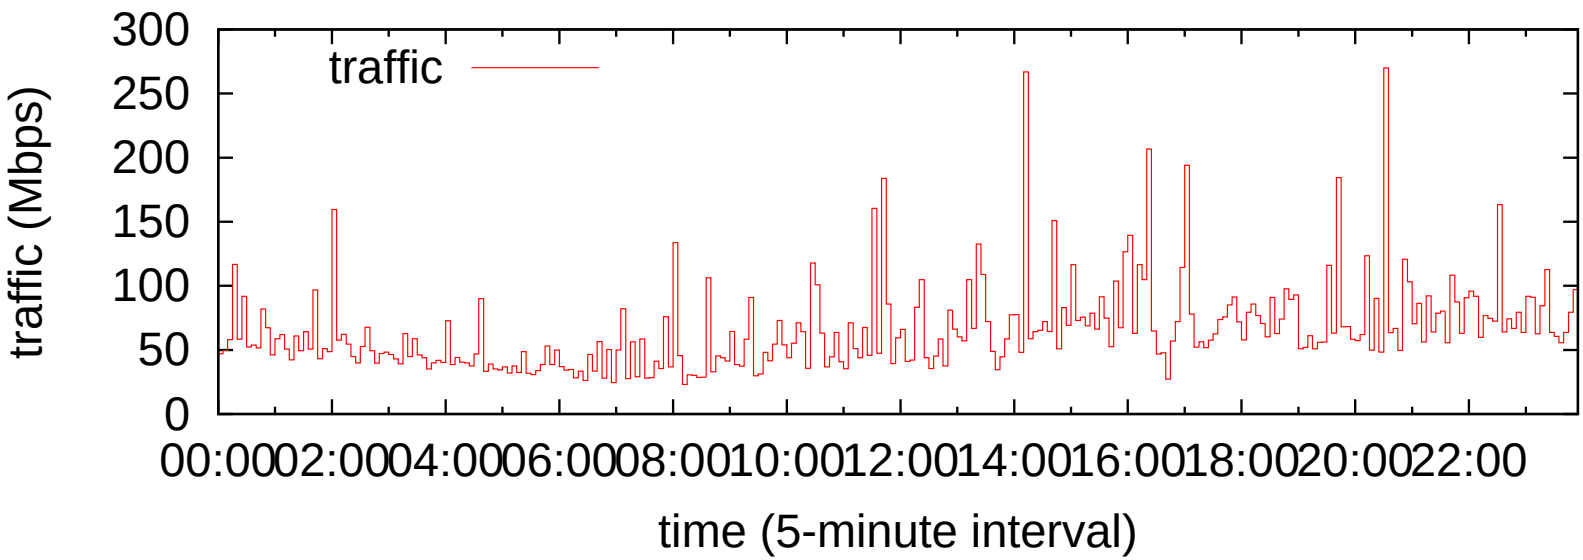

gnuplot script

- multiplot 機能で 2 つのプロットをまとめる

```
set xlabel "time (5-minute interval)"
set xdata time
set format x "%H:%M"
set timefmt "%Y-%m-%dT%H:%M"
set xrange ['2010-07-19T00:00':'2010-07-19T23:55']
set key left top

set multiplot layout 2,1

set yrange [0:20]
set ylabel "requests/sec"
plot "access-5min.txt" using 1:($2/300) title 'requests' with steps

set yrange [0:300]
set ylabel "traffic (Mbps)"
plot "access-5min.txt" using 1:($3*8/300/1000000) title 'traffic' with steps

unset multiplot
```

まとめ

データの収集と記録

- ネットワーク管理ツール
- データフォーマット
- ログ解析手法
- 演習: ログデータと正規表現

次回予定

第 4 回 分布と信頼区間 (4/27)

- 正規分布
- 信頼区間と検定
- 分布の生成
- 演習: 信頼区間
- **課題 1**