

インターネット計測とデータ解析 第9回

長 健二郎

2015年6月15日

前回のおさらい

第8回 時系列データ (6/8)

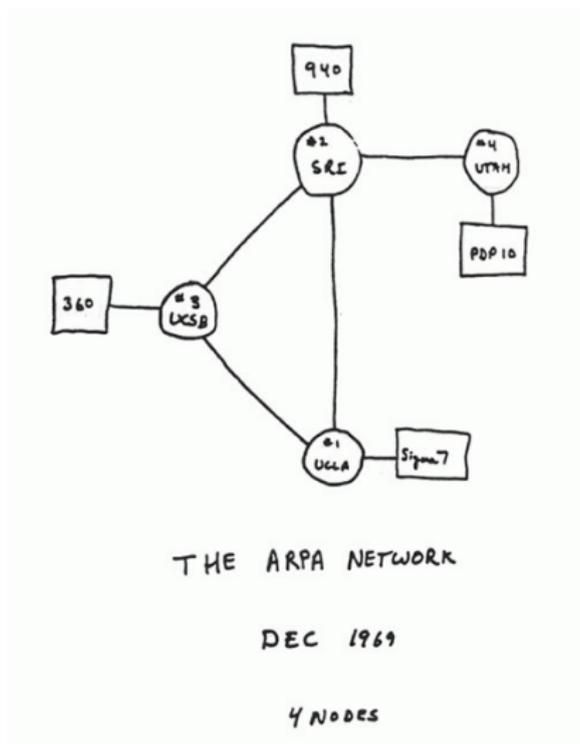
- ▶ インターネットと時刻
- ▶ ネットワークタイムプロトコル
- ▶ 時系列解析
- ▶ 演習: 時系列解析
- ▶ 課題 2

今日のテーマ

第9回 トポロジーとグラフ

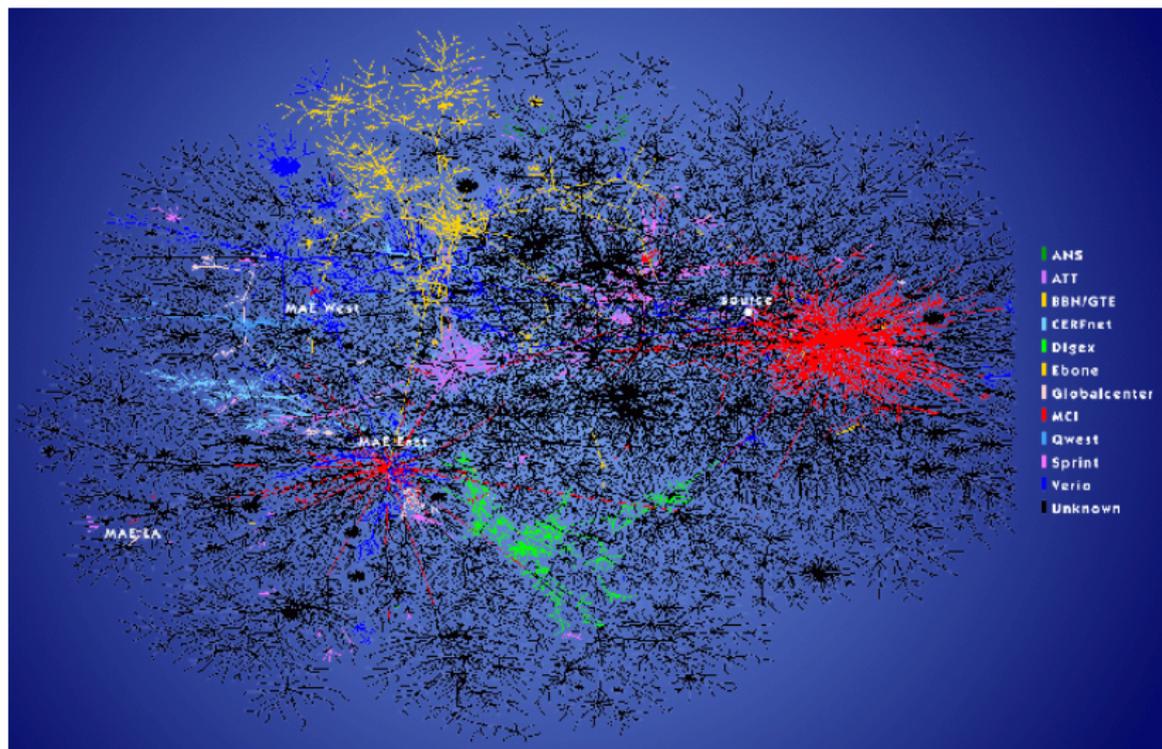
- ▶ 経路制御
- ▶ グラフ理論
- ▶ 最短経路探索
- ▶ 演習: 最短経路探索

最初のパケットスイッチングネットワーク



ARPANET in 1969

インターネット

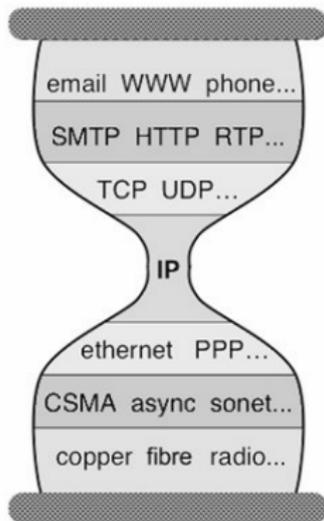


lumeta internet mapping <http://www.lumeta.com>

<http://www.cheswick.com/ches/map/>

インターネットアーキテクチャ

- ▶ パケット配送を IP で共通化
 - ▶ 多様な上位層と下位層をサポート
- ▶ エンド・ツー・エンド モデル
 - ▶ シンプルなネットワーク、機能はエンドノードで実現

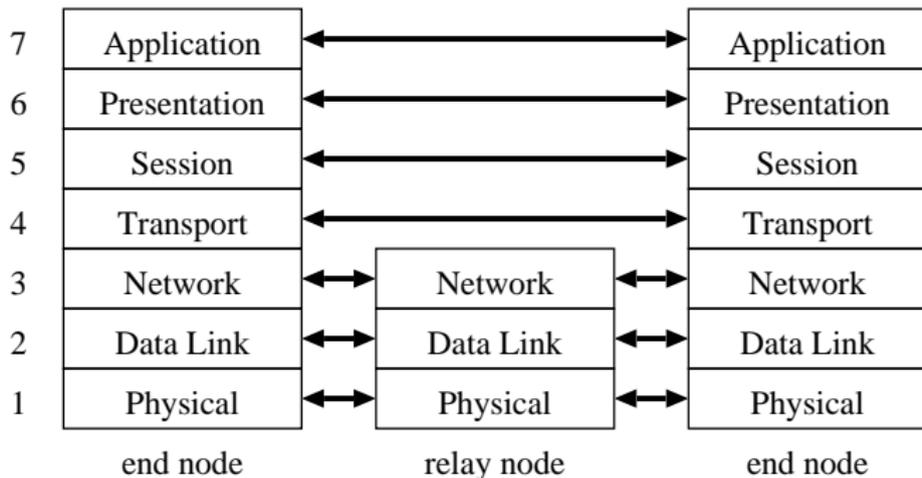


インターネットアーキテクチャの砂時計モデル

ネットワーク階層モデル

複雑なシステムを機能別レイヤ (階層) に分けて抽象化

- ▶ ネットワーク層 (L3)
 - ▶ パケット配送: パケットを受け取り、転送
 - ▶ 経路制御: 宛先に応じて、転送先を決定する仕組み

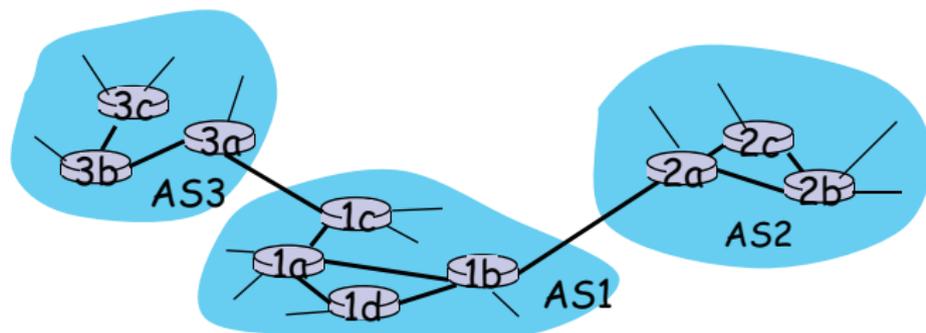


OSI 7 階層モデル

経路制御アーキテクチャ

階層的経路制御 (hierarchical routing)

- ▶ Autonomous System (AS): 経路制御上のポリシーの単位 (組織)
 - ▶ Keio University: AS38635
 - ▶ WIDE Project: AS2500
 - ▶ SINET: AS2907
- ▶ インターネットの経路制御は AS 内部と AS 間の 2 階層
 - ▶ スケーラビリティ
 - ▶ AS 間は管理ポリシーの異なるネットワークを繋ぐ
 - ▶ 内部情報の隠蔽や運用ポリシーの反映が必要



経路制御プロトコル

隣接ルータと経路情報を交換、自身の持つ経路情報を更新する

IGP (Interior Gateway Protocol): AS 内部で使用

- ▶ RIP (Routing Information Protocol)
 - ▶ distance vector routing protocol (Bellman-Ford algorithm)
- ▶ OSPF (Open Shortest Path First)
 - ▶ link state routing protocol (Dijkstra's algorithm)

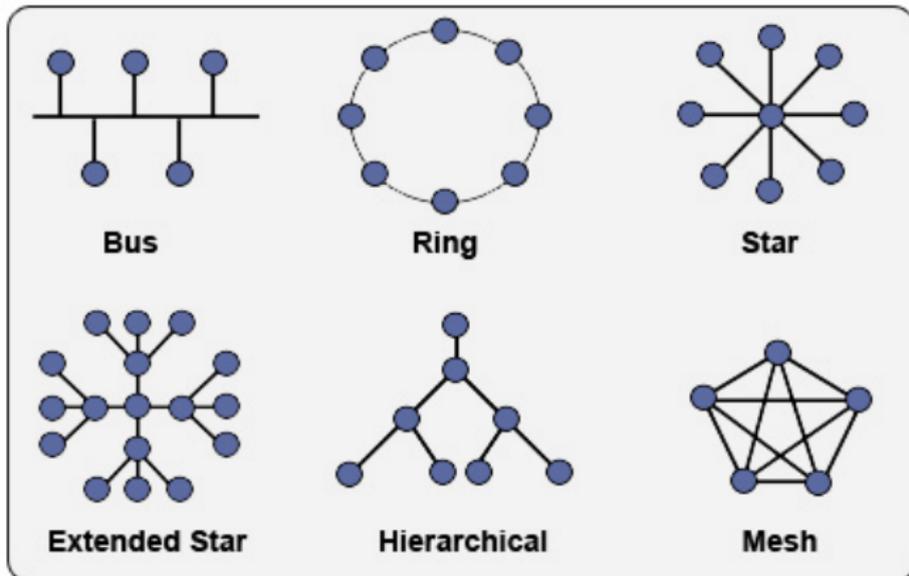
EGP (Exterior Gateway Protocol): AS 間で使用

- ▶ BGP (Boader Gateway Protocol)
 - ▶ path vector routing protocol

トポロジ (topology)

トポロジー (ネットワーク構造)

- ▶ 簡単なトポロジ
 - ▶ バス、リング、スター、ツリー、メッシュ
- ▶ さまざまなレベルでのトポロジ
 - ▶ 物理配線、レイヤ 2、IP レベル、オーバーレイ
 - ▶ ハイパーリンク、ソーシャルネットワーク



インターネットのトポロジ

インターネットスケールのトポロジ情報

▶ ルータレベル

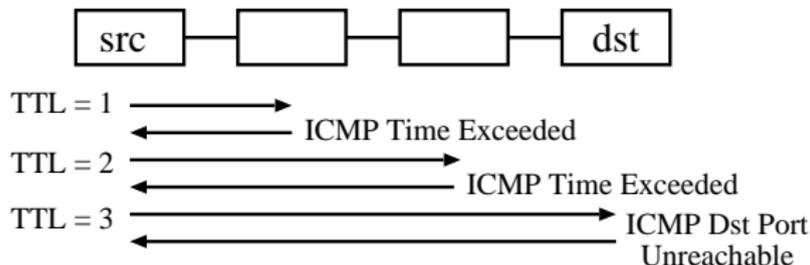
- ▶ traceroute
- ▶ データプレーン情報
- ▶ データの収集公開:
 - ▶ skitter/ark (CAIDA): 20 程のモニターから定点観測
 - ▶ iPlane (U. Washington): PlanetLab の利用
 - ▶ DIMES (Tel Aviv U.) エンドユーザによる計測

▶ AS レベル

- ▶ BGP 経路表
- ▶ コントロールプレーン情報
- ▶ データの収集公開: RouteViews (U. Oregon), RIPE RIS

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.tokenf-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  * * *
```

BGP 情報

- ▶ 各 AS はポリシーに従って隣接 AS に経路を広告
 - ▶ AS パスに自 AS をプリペンド
 - ▶ ポリシー: どの AS にどの経路をどのように広告するか
- ▶ BGP データ: 経路表のダンプ、アップデート情報
- ▶ BGP データのサンプル:

```
BGP table version is 33157262, local router ID is 198.32.162.100
Status codes: s suppressed, d damped, h history, * valid, > best, i -
internal, S Stale
Origin codes: i - IGP, e - EGP, ? - incomplete
```

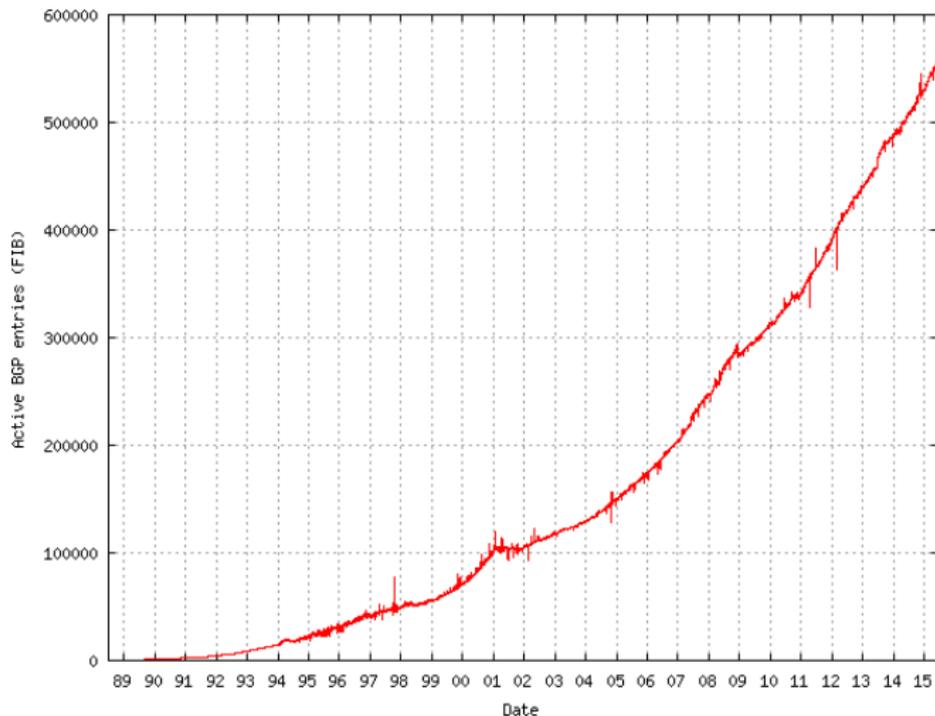
	Network	Next Hop	Metric	LocPrf	Weight	Path
*	202.48.48.0/20	196.7.106.245	0	0	2905 701 2500	i
*>		203.181.248.233		0	7660 2500	i

RouteViews プロジェクト

- ▶ University of Oregon によるデータ収集公開プロジェクト
 - ▶ <http://www.routeviews.org/>
- ▶ 10 のコレクタ: メジャーな AS からのデータ提供
- ▶ 1997 年からのデータを蓄積、公開

経路表サイズの推移

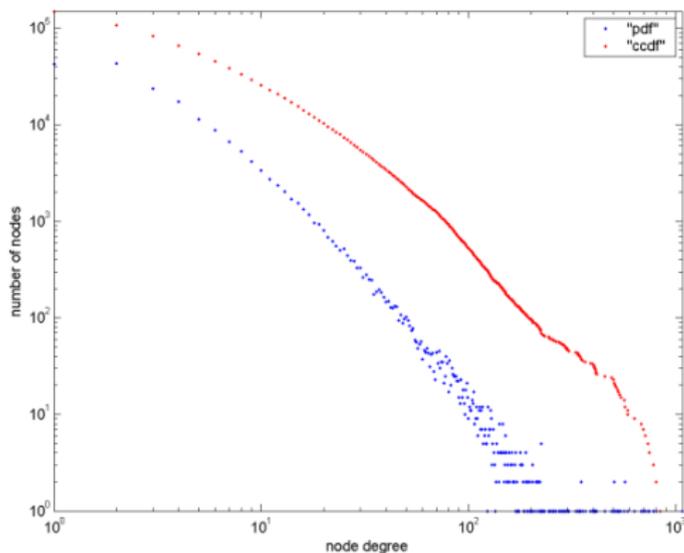
- ▶ active BGP entries (RIB): 557k on 2015/6/10



<http://www.cidr-report.org/>

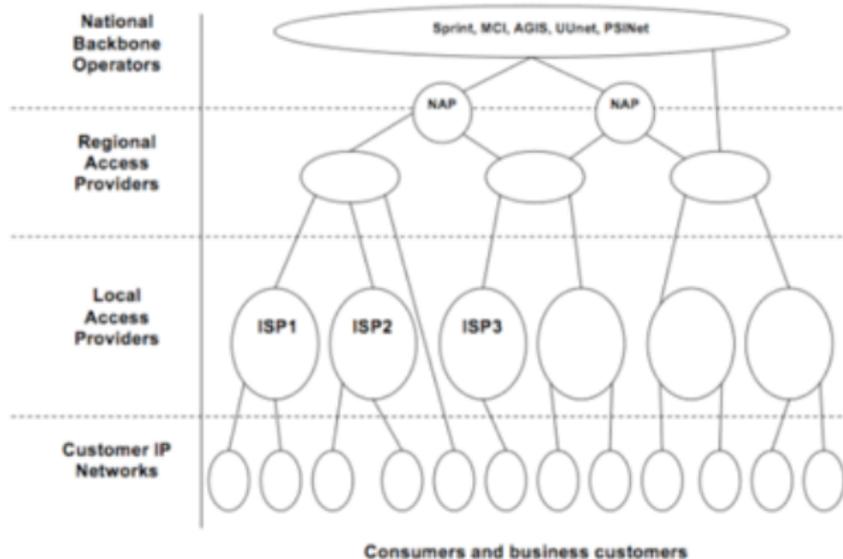
CAIDA's skitter/ark projects

- ▶ CAIDA によるトポロジー計測
 - ▶ skitter/ark: traceroute を並列実行
 - ▶ 約 20 のモニターが全域へのパスを調査



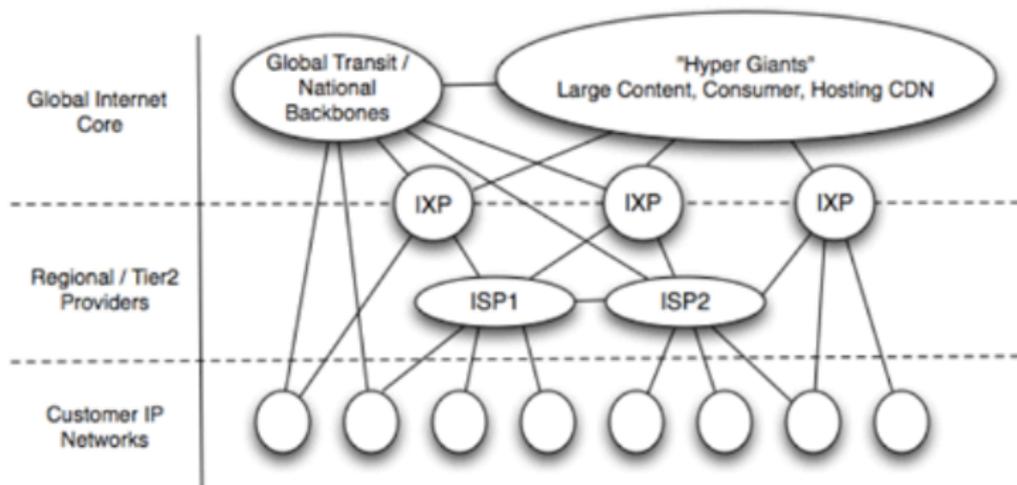
ルータレベルの次数分布

Textbook Internet (1995 – 2007)



- Tier1 global core (modulo a few name changes over the years)
- Still taught today

The New Internet



- **New core of interconnected content and consumer networks**
- **New commercial models between content, consumer and transit**
- **Dramatic improvements in capacity and performance**

グラフ理論

トポロジはグラフ理論で表現可能

- ▶ グラフはノード (node or vertex) とエッジ (edge) から構成
- ▶ 無向グラフと有向グラフ: エッジが方向を持つかどうか
- ▶ 重み付きグラフ: エッジに重み (コスト) が付く
- ▶ パス (path): 2 つのノード間の経路
- ▶ 部分グラフ (subgraph):
- ▶ 次数 (degree): ノードに接続するエッジ数

ネットワークアルゴリズムへの応用

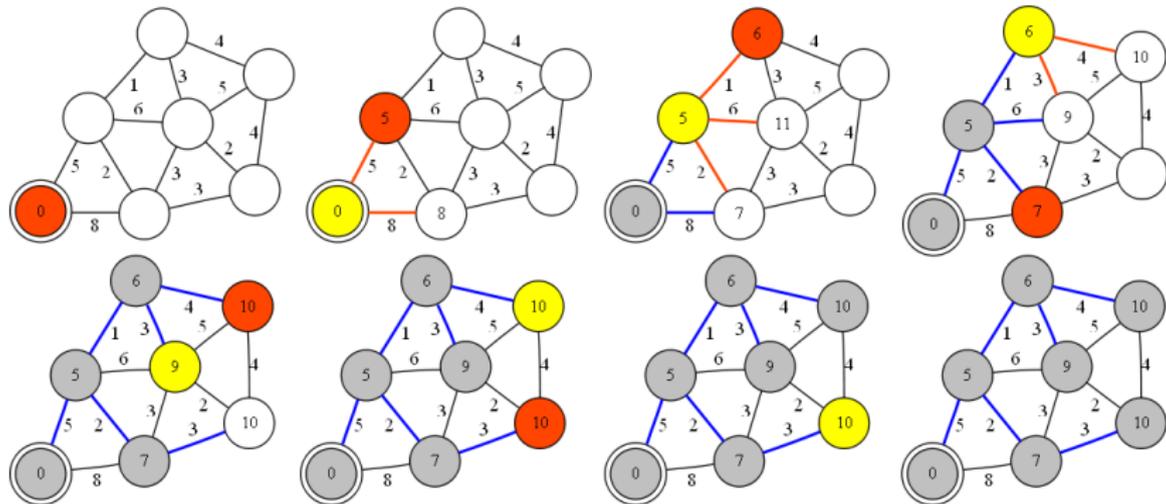
- ▶ スパニングツリーの作成 (ループ回避)
- ▶ 最短経路探索 (経路制御)
 - ▶ Bellman-Ford アルゴリズム
 - ▶ Dijkstra アルゴリズム

ネットワークの特徴解析

- ▶ クラスタリング
- ▶ 平均最短距離 (スモールワールド)
- ▶ 次数分布解析 (スケールフリー: 次数分布がべき乗)

Dijkstra アルゴリズム

1. 初期化: スタートノード値 = 0、他のノード値 = 未定義
2. ループ:
 - (1) 未確定ノード中、最小値のノードを確定
 - (2) 確定したノードの隣接ノードのコスト更新

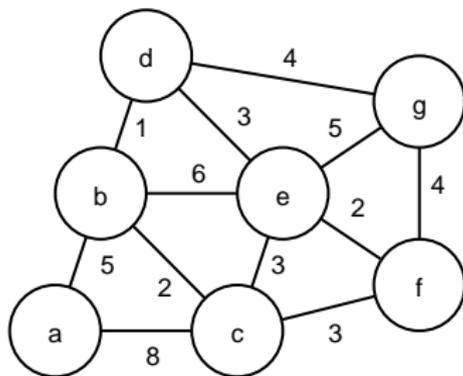


dijkstra algorithm

今回の演習: Dijkstra アルゴリズム

- ▶ トポロジファイルを読んで、最短経路木を計算する

```
$ cat topology.txt
a - b 5
a - c 8
b - c 2
b - d 1
b - e 6
c - e 3
d - e 3
c - f 3
e - f 2
d - g 4
e - g 5
f - g 4
$ ruby dijkstra.rb -s a topology.txt
a: (0) a
b: (5) a b
c: (7) a b c
d: (6) a b d
e: (9) a b d e
f: (10) a b c f
g: (10) a b d g
$
```



おまけ: JR の区間距離による最短経路検索

▶ 山手線、中央線と総武線の一部 (区間距離単位 100m)

```
$ cat jr.txt
# JR Yamanote line
Osaki - Gotanda 09
Gotanda - Meguro 12
Meguro - Ebisu 15
Ebisu - Shibuya 16
Shibuya - Harajuku 12
Harajuku - Yoyogi 15
...
Tamachi - Shinagawa 22
Shinagawa - Osaki 20
# JR Chuo line
Tokyo - Kanda 13
Kanda - Ochanomizu 13
Ochanomizu - Suidobashi 08
...
Sendagaya - Yoyogi 10
Yoyogi - Shinjuku 07
# JR Sobu line
Ochanomizu - Akihabara 09
Akihabara - Asakusabashi 11
$
$ ruby dijkstra.rb -s Shinagawa -d Ochanomizu jr.txt
Ochanomizu: (94) Shinagawa Tamachi Hamamatsucho Shinbashi Yurakucho Tokyo Kanda Ochanomizu
$ ruby dijkstra.rb -s Tokyo -d Shinjuku jr.txt
Shinjuku: (103) Tokyo Kanda Ochanomizu Suidobashi Iidabashi Ichigaya Yotsuya Shinanomachi Sendagaya Yoyogi
$
```

sample code (1/4)

```
#!/usr/bin/env ruby
#
# dijkstra's algorithm based on the pseudo code in the wikipedia
# http://en.wikipedia.org/wiki/Dijkstra%27s_algorithm
# usage: dijkstra.rb -s source [-d destination] topologyfile
require 'optparse'

source = nil # source of spanning-tree
destination = nil # destination

OptionParser.new {|opt|
  opt.on('-s VAL') {|v| source = v}
  opt.on('-d VAL') {|v| destination = v}
  opt.parse!(ARGV)
}

INFINITY = 0x7fffffff # constant to represent a large number
```

sample code (2/4)

```
# read topology file and initialize nodes and edges
# each line of topology file should be "node1 (-|>) node2 weight_val"
nodes = Array.new # all nodes in graph
edges = Hash.new # all edges in graph
ARGF.each_line do |line|
  s, op, t, w = line.split
  next if line[0] == '?' # || w == nil
  unless op == "-" || op == ">"
    raise ArgumentError, "edge_type should be either '-' or '>'"
  end
  weight = w.to_i
  nodes << s unless nodes.include?(s) # add s to nodes
  nodes << t unless nodes.include?(t) # add t to nodes
  # add this to edges
  edges[s] ||= {} # if edges[s] doesn't exist, initialize with empty hash
  edges[s][t] = weight
  # if this edge is undirected, add the reverse directed edge
  if (op == "-")
    edges[t] ||= {}
    edges[t][s] = weight
  end
end
# sanity check
if source == nil
  raise ArgumentError, "specify source_node by '-s source'"
end
unless nodes.include?(source)
  raise ArgumentError, "source_node(#{source}) is not in the graph"
end
```

sample code (3/4)

```
# create and initialize 2 hashes: distance and previous
dist = Hash.new # distance for destination
prev = Hash.new # previous node in the best path
nodes.each do |i|
  dist[i] = INFINITY # Unknown distance function from source to v
  prev[i] = -1 # Previous node in best path from source
end

# run the dijkstra algorithm
dist[source] = 0 # Distance from source to source
while (nodes.length > 0)
  # u := vertex in Q with smallest dist[]
  u = nil
  nodes.each do |v|
    if (!u) || (dist[v] < dist[u])
      u = v
    end
  end
  if (dist[u] == INFINITY)
    break # all remaining vertices are inaccessible from source
  end
  nodes = nodes - [u] # remove u from Q
  # update dist[] of u's neighbors
  edges[u].keys.each do |v|
    alt = dist[u] + edges[u][v]
    if (alt < dist[v])
      dist[v] = alt
      prev[v] = u
    end
  end
end
end
```

sample code (4/4)

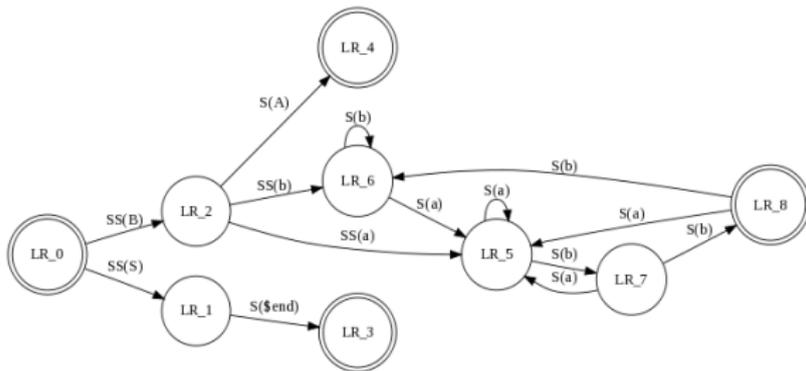
```
# print the shortest-path spanning-tree
dist.sort.each do |v, d|
  # if destination is specified, skip other destinations
  next if destination && destination != v

  print "#{v}: " # destination node
  if d != INFINITY
    print "(#{d}) " # distance
    # construct path from dest to source
    i = v
    path = "#{i}"
    while prev[i] != -1 do
      path.insert(0, "#{prev[i]} ") # prepend previous node
      i = prev[i]
    end
    puts "#{path}" # print path from source to dest
  else
    puts "unreachable"
  end
end
```

グラフ理論的なグラフ描画ツール

- ▶ ノードとエッジの関係を定義すればレイアウト
- ▶ graphviz (<http://www.graphviz.org/>) の例

```
digraph finite_state_machine {  
    rankdir=LR;  
    size="8,5"  
    node [shape = doublecircle]; LR_0 LR_3 LR_4 LR_8;  
    node [shape = circle];  
    LR_0 -> LR_2 [ label = "SS(B)" ];  
    LR_0 -> LR_1 [ label = "SS(S)" ];  
    ...  
    LR_8 -> LR_6 [ label = "S(b)" ];  
    LR_8 -> LR_5 [ label = "S(a)" ];  
}
```



課題 2: twitter データ解析

- ▶ ねらい: 大規模実データ処理の実践
- ▶ 課題用データ:
 - ▶ Kwak らによる 2009 年 7 月の twitter data、約 4000 万ユーザ分
 - ▶ 元データ: <http://an.kaist.ac.kr/traces/WWW2010.html>
 - ▶ twitter_degrees-10000.txt (135KB)
 - ▶ 10,000 人分のサンプルデータ
 - ▶ twitter_degrees.zip (164MB, 解凍後 550MB)
 - ▶ 約 4000 万人分のフルデータ
 - ▶ numeric2screen.zip (365MB, 解凍後 756MB)
 - ▶ ユーザ ID とスクリーン名のマッピング
- ▶ 提出項目
 1. twitter ユーザの following/follower 数散布図プロット
 - ▶ 10,000 人分のデータを使った散布図
 2. フルデータによる following/follower 数分布の CCDF プロット
 - ▶ X 軸に following/follower 数を取り log-log プロット
 3. フォローワ数の多いトップ 50 ユーザの表
 - ▶ ランク、ユーザ ID、スクリーン名、フォロワー数、フォローワ数
 4. オプション: その他の解析
 5. 考察: データから読みとれることを記述
- ▶ 提出形式: PDF 形式のレポートを SFC-SFS から提出
- ▶ 提出〆切: 2015 年 6 月 24 日

課題データについて

twitter_degrees.zip (164MB, 解凍後 550MB)

```
# id followings followers
```

```
12      586      1001061
13      243      1031830
14      106      8808
15      275      14342
16      273      218
17      192      6948
18      87       6532
20      912      1213787
21      495      9027
22      272      3791
...
```

numeric2screen.zip (365MB, 解凍後 756MB)

```
# id screenname
```

```
12 jack
13 biz
14 noah
15 crystal
16 jeremy
17 tonystubblebine
18 Adam
20 ev
21 dom
22 rabble
...
```

課題 提出物

散布図

- ▶ 10,000 人分のデータを用いて、X 軸に following、Y 軸に follower 数を取り log-log プロット
- ▶ 対数グラフなので範囲は 1 から。(0 のデータはプロット不要)

CCDF プロット

- ▶ X 軸に following/follower 数を取り log-log プロット
- ▶ ここでも対数グラフなので範囲は 1 から。

フォローワ数の多いトップ 50 ユーザの表

- ▶ ランク、ユーザ ID、スクリーン名、フォロー数、フォローワ数

#	rank	id	screenname	followings	followers
	1	19058681	aplusk	183	2997469
	2	15846407	TheEllenShow	26	2679639
	3	16409683	britneyspears	406238	2674874
	4	428333	cnnbrk	18	2450749
	5	19397785	Oprah	15	1994926
	6	783214	twitter	55	1959708

...

sort コマンド

sort コマンド: テキストファイルの行をソートして並び替える

```
$ sort [options] [FILE ...]
```

- ▶ options (課題で使いそうなオプション)
 - ▶ -n : フィールドを数値として評価
 - ▶ -r : 結果を逆順に並べる
 - ▶ -k POS1[,POS2] : ソートするフィールド番号 (1 オリジン) を指定する
 - ▶ -t SEP : フィールドセパレータを指定する
 - ▶ -m : 既にソートされたファイルをマージする
 - ▶ -T DIR : 一時ファイルのディレクトリを指定する

例: file を第 3 フィールドを数値とみて逆順にソート、一時ファイルは” /usr/tmp” に作る

```
$ sort -nr -k3,3 -T/usr/tmp file
```

前回の演習: 自己相関

- ▶ 1週間分のトラフィックデータから自己相関を計算する

```
# ruby autocorr.rb autocorr_5min_data.txt > autocorr.txt
# head -10 autocorr_5min_data.txt
2011-02-28T00:00 247 6954152
2011-02-28T00:05 420 49037677
2011-02-28T00:10 231 4741972
2011-02-28T00:15 159 1879326
2011-02-28T00:20 290 39202691
2011-02-28T00:25 249 39809905
2011-02-28T00:30 188 37954270
2011-02-28T00:35 192 7613788
2011-02-28T00:40 102 2182421
2011-02-28T00:45 172 1511718
# head -10 autocorr.txt
0 1.000
1 0.860
2 0.860
3 0.857
4 0.857
5 0.854
6 0.851
7 0.849
8 0.846
9 0.841
```

前回の演習: 自己相関

- ▶ 1週間分のトラフィックデータから自己相関を計算する

```
# ruby autocorr.rb autocorr_5min_data.txt > autocorr.txt
# head -10 autocorr_5min_data.txt
2011-02-28T00:00 247 6954152
2011-02-28T00:05 420 49037677
2011-02-28T00:10 231 4741972
2011-02-28T00:15 159 1879326
2011-02-28T00:20 290 39202691
2011-02-28T00:25 249 39809905
2011-02-28T00:30 188 37954270
2011-02-28T00:35 192 7613788
2011-02-28T00:40 102 2182421
2011-02-28T00:45 172 1511718
# head -10 autocorr.txt
0 1.000
1 0.860
2 0.860
3 0.857
4 0.857
5 0.854
6 0.851
7 0.849
8 0.846
9 0.841
```

自己相関関数の求め方

タイムラグ k の自己相関関数

$$R(k) = \frac{1}{n} \sum_{i=1}^n x_i x_{i+k}$$

$k = 0$ の場合は、同一データの相関なので、 $R(k)/R(0)$ で規格化する

$$R(0) = \frac{1}{n} \sum_{i=1}^n x_i^2$$

2n 個のデータ数が必要

自己相関関数スクリプト

```
# regular expression for matching 5-min timeseries
re = /\d{4}-\d{2}-\d{2}T\d{2}:\d{2}\s+(\d+)\s+(\d+)/

v = Array.new() # array for timeseries
ARGF.each_line do |line|
  if re.match(line)
    v.push $3.to_f
  end
end

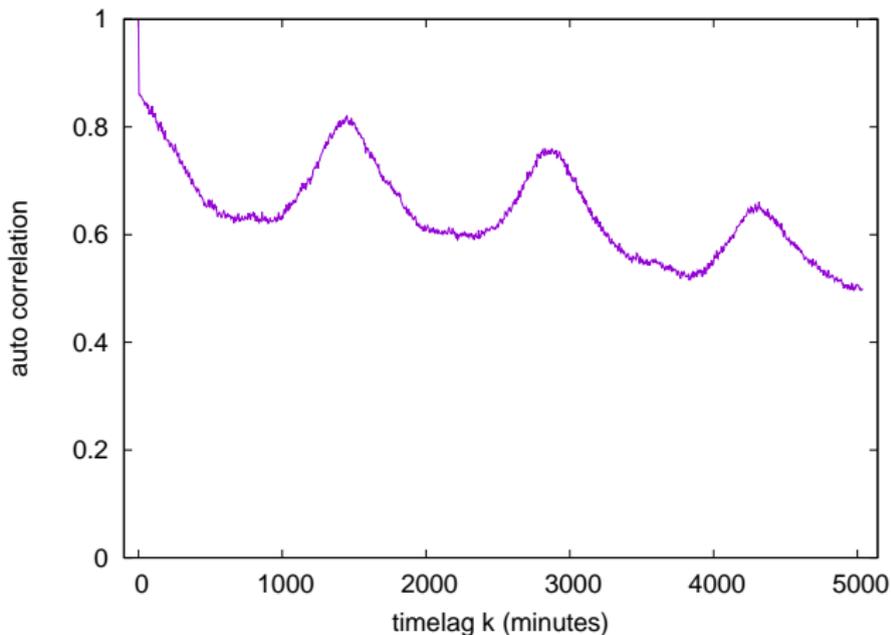
n = v.length # n: number of samples
h = n / 2 - 1 # (half of n) - 1

r = Array.new(n/2) # array for auto correlation
for k in 0 .. h # for different timelag
  s = 0
  for i in 0 .. h
    s += v[i] * v[i + k]
  end
  r[k] = Float(s)
end

# normalize by dividing by r0
if r[0] != 0.0
  r0 = r[0]
  for k in 0 .. h
    r[k] = r[k] / r0
    printf "%d %.3f\n", k, r[k]
  end
end
```

自己相関プロット

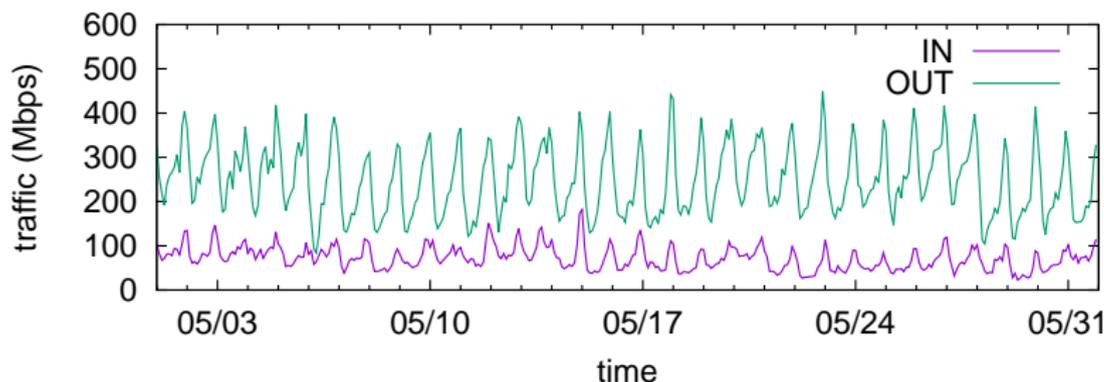
```
set xlabel "timelag k (minutes)"  
set ylabel "auto correlation"  
set xrange [-100:5140]  
set yrange [0:1]  
plot "autocorr.txt" using ($1*5):2 notitle with lines
```



前回の演習 2: トラフィック解析

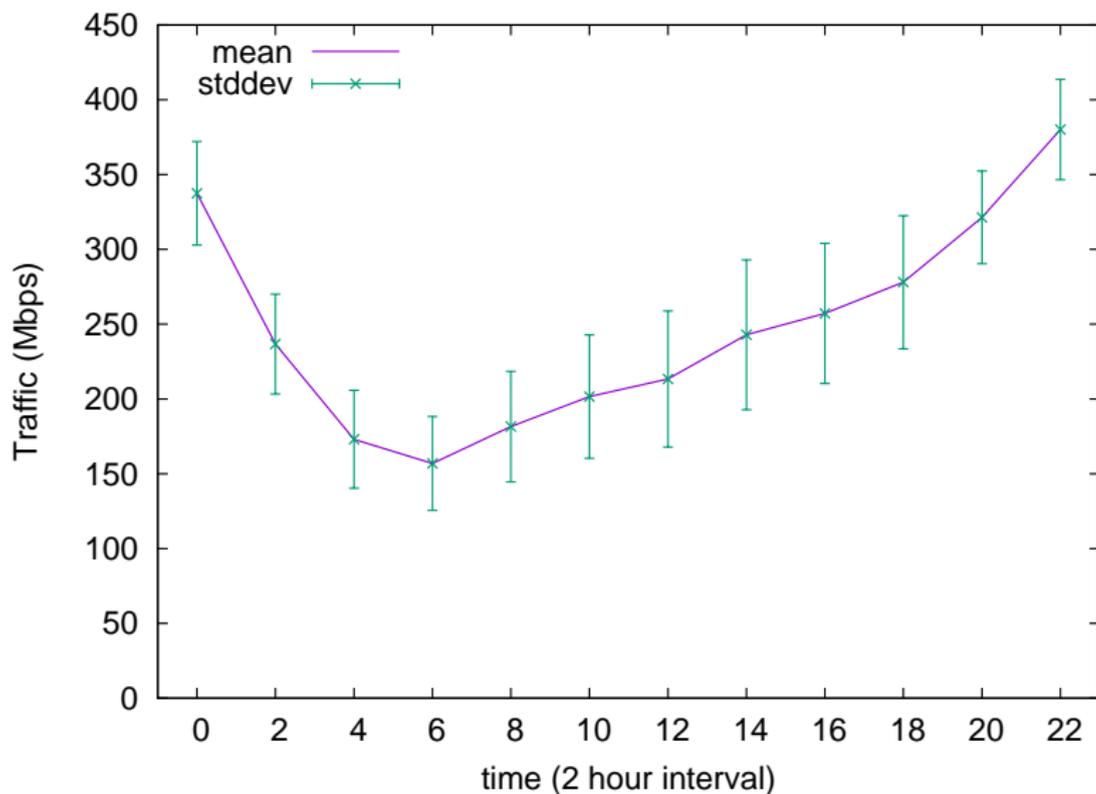
演習用データ: ifbps-201205.txt

- ▶ あるブロードバンド収容ルータのインターフェイスカウンタ値
- ▶ 2012年5月の1ヶ月分、2時間粒度
- ▶ format: time IN(bits/sec) OUT(bits/sec)
- ▶ 元データのフォーマットを変換してある
 - ▶ original format: unix_time IN(bytes/sec) OUT(bytes/sec)
- ▶ ここでは OUT トラフィックを解析
 - ▶ IN トラフィックは自習用



今回の演習 2: 時間帯別トラフィック

- ▶ 時間毎の平均と標準偏差をプロット



前回の演習 2: 時間帯別トラフィック抽出スクリプト

```
# time in_bps out_bps
re = /^(\d{4}-\d{2}-\d{2})T(\d{2}):(\d{2}):(\d{2})\s+\d+\.\d+\s+(\d+\.\d+)/

# arrays to hold values for every 2 hours
sum = Array.new(12, 0.0)
sqsum = Array.new(12, 0.0)
num = Array.new(12, 0)

ARGF.each_line do |line|
  if re.match(line)
    # matched
    hour = $2.to_i / 2
    bps = $3.to_f

    sum[hour] += bps
    sqsum[hour] += bps**2
    num[hour] += 1
  end
end

printf "#hour\t\tmean\t\tstddev\n"
for hour in 0 .. 11
  mean = sum[hour] / num[hour]
  var = sqsum[hour] / num[hour] - mean**2
  stddev = Math.sqrt(var)

  printf "%02d\t%d\t%.1f\t%.1f\n", hour * 2, num[hour], mean, stddev
end
```

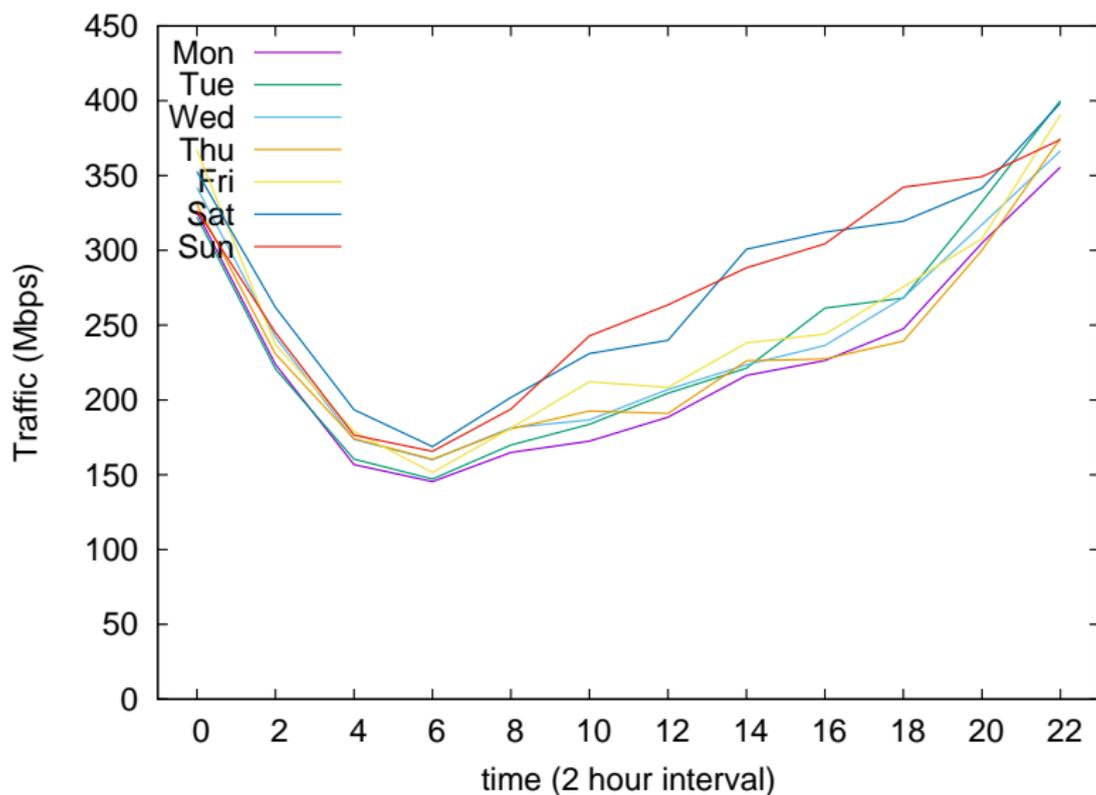
前回の演習 2: 時間帯別トラフィックのプロット

```
set xlabel "time (2 hour interval)"
set xtic 2
set xrange [-1:23]
set yrange [0:]
set key top left
set ylabel "Traffic (Mbps)"

plot "hourly_out.txt" using 1:($3/1000000) title 'mean' with lines, \
"hourly_out.txt" using 1:($3/1000000):($4/1000000) title "stddev" with yerrorbars
```

前回の演習 2: 曜日別時間帯別トラフィック

- ▶ 曜日毎のトラフィックをプロット



前回の演習 2: 曜日別時間帯別トラフィックの抽出

```
# time in_bps out_bps
re = /^\\d{4}-\\d{2}-\\d{2})T(\\d{2}):\\d{2}:\\d{2}\\s+\\d+\\.\\d+\\s+(\\d+\\.\\d+)/

# 2012-05-01 is Tuesday, add wdoffset to make wday start with Monday
wdoffset = 0

# traffic[wday][hour]
traffic = Array.new(7){ Array.new(12, 0.0) }
num = Array.new(7){ Array.new(12, 0) }

ARGF.each_line do |line|
  if re.match(line)
    # matched
    wday = ($1.to_i + wdoffset) % 7
    hour = $2.to_i / 2
    bps = $3.to_f

    traffic[wday][hour] += bps
    num[wday][hour] += 1
  end
end
printf "#hour\\tMon\\tTue\\tWed\\tThu\\tFri\\tSat\\tSun\\n"
for hour in 0 .. 11
  printf "%02d", hour * 2
  for wday in 0 .. 6
    printf " %.1f", traffic[wday][hour] / num[wday][hour]
  end
  printf "\\n"
end
```

前回の演習 2: 曜日別時間帯別トラフィックのプロット

```
set xlabel "time (2 hour interval)"
set xtic 2
set xrange [-1:23]
set yrange [0:]
set key top left
set ylabel "Traffic (Mbps)"

plot "week_out.txt" using 1:($2/1000000) title 'Mon' with lines, \
"week_out.txt" using 1:($3/1000000) title 'Tue' with lines, \
"week_out.txt" using 1:($4/1000000) title 'Wed' with lines, \
"week_out.txt" using 1:($5/1000000) title 'Thu' with lines, \
"week_out.txt" using 1:($6/1000000) title 'Fri' with lines, \
"week_out.txt" using 1:($7/1000000) title 'Sat' with lines, \
"week_out.txt" using 1:($8/1000000) title 'Sun' with lines
```

前回の演習 2: 曜日間の相関係数行列

- ▶ 曜日間の相関係数行列を計算
 - ▶ 曜日間の各時間帯平均値を使う

	Mon	Tue	Wed	Thu	Fri	Sat	Sun
Mon	1.000	0.985	0.998	0.991	0.988	0.955	0.901
Tue	0.985	1.000	0.981	0.975	0.969	0.964	0.927
Wed	0.998	0.981	1.000	0.987	0.987	0.946	0.897
Thu	0.991	0.975	0.987	1.000	0.988	0.933	0.859
Fri	0.988	0.969	0.987	0.988	1.000	0.951	0.896
Sat	0.955	0.964	0.946	0.933	0.951	1.000	0.971
Sun	0.901	0.927	0.897	0.859	0.896	0.971	1.000

前回の演習 2: 曜日間の相関係数行列の計算

- ▶ 曜日別時間帯別で作った配列を使えばよい

```
n = 12
for wday in 0 .. 6
  for wday2 in 0 .. 6
    sum_x = sum_y = sum_xx = sum_yy = sum_xy = 0.0
    for hour in 0 .. 11
      x = traffic[wday][hour] / num[wday][hour]
      y = traffic[wday2][hour] / num[wday2][hour]

      sum_x += x
      sum_y += y
      sum_xx += x**2
      sum_yy += y**2
      sum_xy += x * y
    end
    r = (sum_xy - sum_x * sum_y / n) /
      Math.sqrt((sum_xx - sum_x**2 / n) * (sum_yy - sum_y**2 / n))
    printf "%.3f\t", r
  end
  printf "\n"
end
```

まとめ

第9回 トポロジーとグラフ

- ▶ 経路制御
- ▶ グラフ理論
- ▶ 最短経路探索
- ▶ 演習: 最短経路探索

次回予定

第 10 回 異常検出と機械学習 (6/22)

- ▶ 異常検出
- ▶ 機械学習
- ▶ スпам判定とベイズ理論
- ▶ 演習: 単純ベイズ分類器