インターネット計測とデータ解析 第 6 回

長 健二朗

2015 年 5 月 25 日

前回のおさらい

第 5 回 多様性と複雑さ (5/18)

- ロングテール
- Web アクセスとコンテンツ分布
- べき乗則と複雑系
- 演習: べき乗則解析

今日のテーマ

第 6 回 相関

- オンラインお勧めシステム
- 距離と類似度
- 相関係数
- 演習: 相関

オンラインお勧めシステム

- EC サイトにおけるロングテールのユーザの潜在ニーズ
  - ユーザの嗜好に合った商品を提示して購買に繋げる
- レコメンダーパッケージによる導入コスト低下で普及

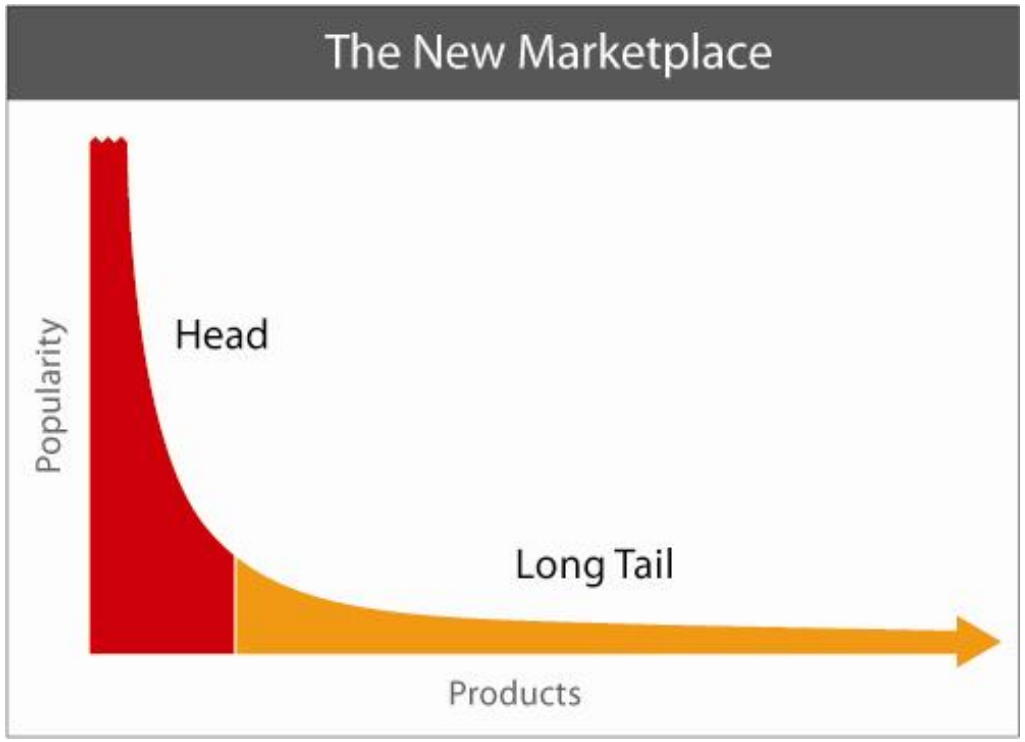

source: http://longtail.com/

お勧めシステムの技術

- ユーザの行動を観察して有用な情報を予測して自動的に提示
- EC サイト: 購買履歴や閲覧履歴からお勧め商品を自動的に提示
- EC サイトだけでなく検索予測、かな漢字変換などへの応用も

データベースの作り方

- アイテムベース: アイテムごとに情報をまとめる
- ユーザベース: ユーザごとに情報をまとめる
- 実際にはこれらを組み合わせて使う

お勧めシステムの予測手法

- コンテンツベース:
  - ユーザが過去に利用したアイテムから類似アイテムを推薦
    - アイテムの属性分類
    - 機械学習クラスタリングによるグループ化
    - ノウハウのルール化
  - 比較的狭い範囲での推薦になりがち、意外性が低い
- 協調フィルタリング: amazon をはじめ広く利用されている
  - 購買履歴から顧客間の類似度を計算
  - 類似したユーザの実績から共通度の高いアイテムを推薦
  - 特徴: 個別のアイテムに関する情報は使わない
  - 思いがけない発見 (serendipity) の可能性
- 単純ベイズ分類器: スパム判定と同じ原理
  - アイテムやユーザに関する個別の多様な情報から確率計算、機械学習する

最近のターゲティング広告の進化

- ターゲティング広告
  - 特定ジャンルに興味を持つユーザに絞った広告
  - 広告効果や費用対効果の向上
- アドネットワーク
  - ネット広告枠と広告主を仲介するネット広告配信サービス
  - 例: 個人が運営するサイトにバナー広告を入れる
- Real Time Bidding
  - ネット広告枠をリアルタイムでオークションする仕組み
  - 広告枠を提供するオークション主催者
    - ユーザの属性情報、行動履歴情報など (cookie による追跡)
  - 広告枠を入札するオークション参加者
    - 提供された情報を元に入札価格を決める
    - リターゲティング: 過去に自社のサイトを訪問したユーザに対する広告
  - RTB 用のプラットフォーム: ミリ秒オーダーの落札を実現

協調フィルタリング (collaborative filtering)

- 複数のアルゴリズムが存在
- シンプルなユーザ間相関分析
  - ユーザ間の相関をとり類似ユーザを抽出
  - 類似ユーザの類似度を重みに各アイテムの合計点数を計算

例: ユーザの購買履歴

	item						
user	a	b	c	d	e	f	···
A	1		1		1		···
B			1	1			···
C	1	1					···
D	1		1		1		···
···							···

A と相関高いユーザから A の持っていないアイテムのスコアを計算

	similarity	item					
user	σ	a	b	c	d	e	f	···
A	1	1		1		1		···
S	0.88		0.88		-		0.88	···
C	0.81		0.81		-		-	···
K	0.75		-		-		-	···
F	0.73		0.73		0.73		0.73	···
score			2.50		0.73		1.61	···

例: Netflix Prize

- 米国のオンライン DVD レンタルサービス Netflix のアルゴリズムコンテスト
- 同社のオンラインお薦めシステムの性能を 10%向上すれば 100 万ドルの賞金
- コンテスト用データセット:
  $< user\_id, movie\_id, date\_of\_grade, grade >$
  - トレーニング用データセット: 1 億件の評価スコア
  - 評価用データセット: 280 万件の評価スコア
    - 答え合わせ用データセット: 140 万件
    - 採点用データセット: 140 万件
  - 採点スコアは結果の誤差の平均二乗偏差 (10%改善目標)
- コンテストは 2006 年に始まり、2009 年に終了
  - プライバシー問題で批判
  - 匿名化されたユーザを他の映画評価サイトのユーザとマッチング可能

距離について

いろいろな距離

- ユークリッド距離 (Euclidean distance)
- 標準化ユークリッド距離 (standardized Euclidean distance)
- ミンコフスキー距離 (Minkowski distance)
- マハラノビス距離 (Mahalanobis distance)

類似度

- バイナリベクトルの類似度
- n 次元ベクトルの類似度

距離の性質

空間上の 2 点 (x, y) 間の距離 $d(x, y)$:
非負性 (positivity)

$$d(x, y) \geq 0$$

$$d(x, y) = 0 \Leftrightarrow x = y$$

対称性 (symmetry)

$$d(x, y) = d(y, x)$$

三角不等式 (triangle inequality)

$$d(x, z) \leq d(x, y) + d(y, z)$$

ユークリッド距離 (Euclidean distance)

普通に距離といえばユークリッド距離を指す
n 次元空間での 2 点 (x, y) の距離

$$d(x, y) = \sqrt{\sum_{k=1}^{n} (x_k - y_k)^2}$$

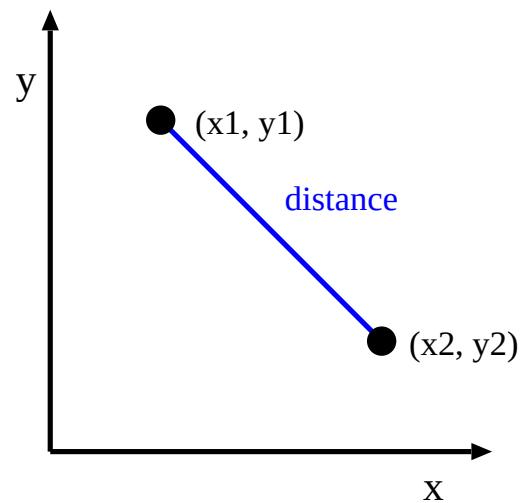

euclidean distance in 2-dimensional space

標準ユークリッド距離 (standardized Euclidean distance)

- 変数間でばらつきの大きさが異なると、距離が影響を受ける
- そこで、ユークリッド距離を各変数の分散で割って正規化

$$d(x,y) = \sqrt{\sum_{k=1}^{n}(\frac{x_k}{s_k} - \frac{y_k}{s_k})^2} = \sqrt{\sum_{k=1}^{n}\frac{(x_k - y_k)^2}{s_k^2}}$$

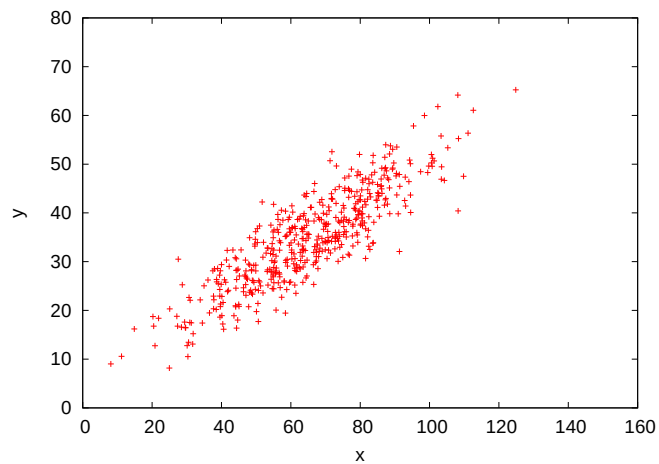

ミンコフスキー距離 (Minkowski distance)

ユークリッド距離を一般化

- パラメータ r が大きいほど、次元軸にとらわれない移動 (斜め方向のショートカット) を重視する距離

$$d(x, y) = (\sum_{k=1}^{n} |x_k - y_k|^r)^{\frac{1}{r}}$$

- $r = 1$: マンハッタン距離
  - ハミング距離: 2 つの文字列間の同じ位置の文字の不一致数
  - 例えば、111111 と 101010 のハミング距離は 3
- $r = 2$: ユークリッド距離

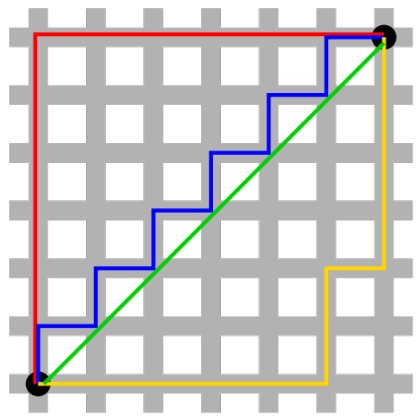

Manhattan distance vs. Euclidean distance

ベクトルのノルム (vector norm) (1/2)

ベクトルのノルム: ベクトルの長さ

$$\|x\| \text{ where } x \text{ is a vector}$$

ベクトル x の l_n-ノルムはミンコフスキー距離で定義される

$$\|x\|_n = \sqrt[n]{\sum_i |x_i|^n}$$

l_0-norm: ベクトルの 0 でない要素の数

$$\|x\|_0 = \#(i|x_i \neq 0)$$

l_1-norm: 差分の和

$$\|x\|_1 = \sum_i |x_i|$$

l_2-norm: ユークリッド距離

$$\|x\|_2 = \sqrt{\sum_i |x_i|^2}$$

l_∞-norm: ベクトルの最大要素

$$\|x\|_\infty = max(|x_i|)$$

ベクトルのノルム (vector norm) (2/2)

例: ベクトル $x = (1, 2, 3)$ に対して

$$\begin{aligned} \|x\|_0 &\quad 3 = 3.000 \\ \|x\|_1 &\quad 6 = 6.000 \\ \|x\|_2 &\quad \sqrt{14} = 3.742 \\ \|x\|_3 &\quad 6^{2/3} = 3.302 \\ \|x\|_4 &\quad 2^{1/4}\sqrt{7} = 3.146 \\ \|x\|_\infty &\quad 3 = 3.000 \end{aligned}$$

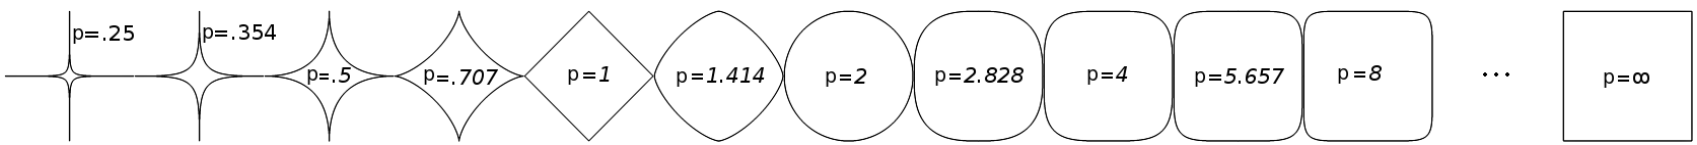

unit circles of l_p-norm with various values of p

マハラノビス距離 (Mahalanobis distance)

変数間に相関がある場合に、相関を考慮した距離

$$mahalanobis(x, y) = (x - y)\Sigma^{-1}(x - y)^T$$

ここで Σ^{-1} は共分散行列の逆行列

類似度

類似度

- ふたつのデータの似ている度合の数値表現

類似度の性質

非負性 (positivity)

$$0 \leq s(x, y) \leq 1$$

$$s(x, y) = 1 \Leftrightarrow x = y$$

対称性 (symmetry)

$$s(x, y) = s(y, x)$$

三角不等式 (triangle inequality) は一般に類似度には当てはまらない

バイナリベクトルの類似度

Jaccard 係数

- 1 の出現が少ないバイナリベクトル同士の類似度に使われる
- 文書中に出現する単語から文書の類似度を示す場合など
- 多くの単語は両方ともに出現しない $\Rightarrow$ これらは考慮しない
- 2 つのベクトルの各要素の対応関係を表のように集計

		vector y	
		1	0
vector x	1	n_{11}	n_{10}
	0	n_{01}	n_{00}

Jaccard 係数は以下で表される

$$J = \frac{n_{11}}{n_{11} + n_{10} + n_{01}}$$

n 次元ベクトルの類似度

一般のベクトルの類似度

- 文書の類似度で出現頻度も考慮する場合など

コサイン類似度

- ベクトルの x, y の cosine を取る、向きが一致:1、直交:0、向きが逆:-1
- ベクトルの長さで正規化 $\Rightarrow$ 大きさは考慮しない

$$cos(x, y) = \frac{x \cdot y}{\|x\|\|y\|}$$

$x \cdot y = \sum_{k=1}^{n} x_k y_k$: ベクトルの積
$\|x\| = \sqrt{\sum_{k=1}^{n} x_k^2} = \sqrt{x \cdot x}$: ベクトルの長さ

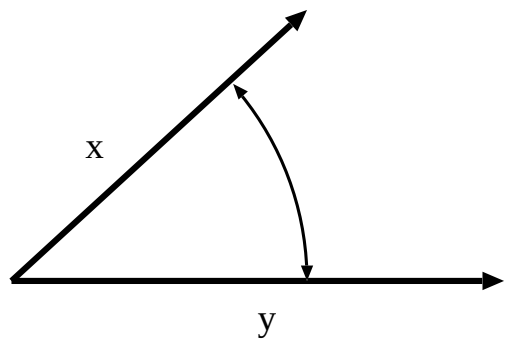

コサイン類似度の例題

$$x = 3 \quad 2 \quad 0 \quad 5 \quad 0 \quad 0 \quad 0 \quad 2 \quad 0 \quad 0$$
$$y = 1 \quad 0 \quad 0 \quad 0 \quad 0 \quad 0 \quad 0 \quad 1 \quad 0 \quad 2$$

$$x \cdot y = 3 * 1 + 2 * 1 = 5$$
$$\|x\| = \sqrt{3 * 3 + 2 * 2 + 5 * 5 + 2 * 2} = \sqrt{42} = 6.481$$
$$\|y\| = \sqrt{1 * 1 + 1 * 1 + 2 * 2} = \sqrt{6} = 2.449$$

$$cos(x, y) = \frac{5}{6.481 * 2.449} = 0.315$$

散布図と相関係数

- 散布図は 2 つの変数の関係を見るのに有効
  - X 軸: 変数 X
  - Y 軸: それに対応する変数 Y の値
- 散布図で分かる事
  - X と Y に関連があるか
    - 無相関、正の相関、負の相関
  - 外れ値の存在があるか
- 相関係数: 相関の方向 (正負) と強さを表す量

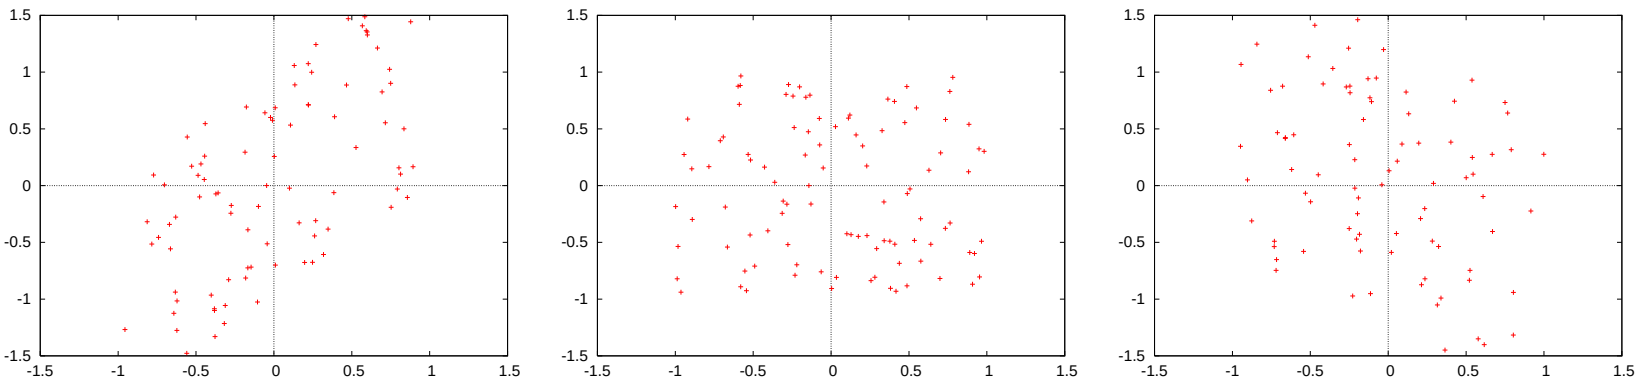

例: (左) 正の相関 0.7 (中) 無相関 0.0 (右) 負の相関 -0.5

相関 (correlation)

- 共分散 (covariance):

$$\sigma_{xy}^2 = \frac{1}{n}\sum_{i=1}^{n}(x_i - \bar{x})(y_i - \bar{y})$$

- 相関係数 (correlation coefficient):

$$\rho_{xy} = \frac{\sigma_{xy}^2}{\sigma_x \sigma_y} = \frac{\sum_{i=1}^{n}(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^{n}(x_i - \bar{x})^2 \sum_{i=1}^{n}(y_i - \bar{y})^2}}$$

- 相関係数は共分散を正規化したもの。 -1 から 1 の値を取る。
- 相関係数は外れ値の影響を大きく受ける。 散布図と併用し、外れ値を確認する必要。
- 相関関係と因果関係
  - 相関関係が因果関係を示すとは限らない。
    - 未知の第 3 の共通の要因が存在する場合
    - 単なる偶然

相関係数の計算 (1)

偏差平方和 (sum of squares)

$$
\begin{aligned}
\sum_{i=1}^{n}(x_i - \bar{x})^2 &= \sum_{i=1}^{n}(x_i^2 - 2x_i\bar{x} + \bar{x}^2) \\
&= \sum_{i=1}^{n} x_i^2 - 2\bar{x}\sum_{i=1}^{n} x_i + n\,\bar{x}^2 \\
&= \sum_{i=1}^{n} x_i^2 - 2\bar{x}\cdot n\,\bar{x} + n\,\bar{x}^2 \\
&= \sum_{i=1}^{n} x_i^2 - n\,\bar{x}^2 = \sum_{i=1}^{n} x_i^2 - \frac{(\sum_{i=1}^{n} x_i)^2}{n}
\end{aligned}
$$

偏差積和 (sum of products)

$$
\begin{aligned}
\sum_{i=1}^{n}(x_i - \bar{x})(y_i - \bar{y}) &= \sum_{i=1}^{n}(x_i y_i - x_i\bar{y} - \bar{x}y_i + \bar{x}\bar{y}) \\
&= \sum_{i=1}^{n} x_i y_i - \bar{x}\sum_{i=1}^{n} y_i - \bar{y}\sum_{i=1}^{n} x_i + n\,\bar{x}\bar{y} \\
&= \sum_{i=1}^{n} x_i y_i - \bar{x}\cdot n\,\bar{y} - \bar{y}\cdot n\,\bar{x} + n\,\bar{x}\bar{y} \\
&= \sum_{i=1}^{n} x_i y_i - n\,\bar{x}\bar{y} = \sum_{i=1}^{n} x_i y_i - \frac{(\sum_{i=1}^{n} x_i)(\sum_{i=1}^{n} y_i)}{n}
\end{aligned}
$$

相関係数の計算 (2)

相関係数 (correlation coefficient)

$$
\begin{aligned}
\rho_{xy} &= \frac{\sigma_{xy}^2}{\sigma_x \sigma_y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \\
&= \frac{\sum_{i=1}^n x_i y_i - n\,\bar{x}\bar{y}}{\sqrt{(\sum_{i=1}^n x_i^2 - n\,\bar{x}^2)(\sum_{i=1}^n y_i^2 - n\,\bar{y}^2)}} \\
&= \frac{\sum_{i=1}^n x_i y_i - \frac{(\sum_{i=1}^n x_i)(\sum_{i=1}^n y_i)}{n}}{\sqrt{(\sum_{i=1}^n x_i^2 - \frac{(\sum_{i=1}^n x_i)^2}{n})(\sum_{i=1}^n y_i^2 - \frac{(\sum_{i=1}^n y_i)^2}{n})}}
\end{aligned}
$$

他の相関係数

- ピアソンの積率相関係数 (Pearson's product-moment correlation coefficient)
  - 単に相関係数といえばこれを指す (この授業でも同様)
- 順位相関係数 (rank correlation coefficient):
  - 同じ項目を持つデータセットに対する順位付けの違いとその関係
  - スピアマンの順位相関係数
  - ケンドールの順位相関係数
- その他の相関係数

課題 1: ホノルルマラソン 2014 完走時間分布のプロット

- ねらい: 実データから分布を調べる
- データ: 2014 年のホノルルマラソンの記録
  - http://www.pseresults.com/events/647/results
  - 完走者 21,815 人
- 提出項目
  1. 全完走者、男性完走者、女性完走者それぞれの、完走時間の平均、標準偏差、中間値
  2. それぞれの完走時間のヒストグラム
     - 3 つのヒストグラムを別々の図に書く
     - ビン幅は 10 分にする
     - 3 つのプロットは比較できるように目盛を合わせること
  3. それぞれの CDF プロット
     - ひとつの図に 3 つのプロットを書く
  4. オプション
     - 年代別や国別の CDF プロットなど自由
  5. 考察
     - データから読みとれることを記述
- 提出形式: レポートをひとつの PDF ファイルにして SFC-SFS から提出
- 提出〆切: 2015 年 5 月 27 日

ホノルルマラソンデータ

データフォーマット

Place	Num	Chip Time	Lname	Fname	Country	Division	Div Plc	Div Tot	Sex Plc	Sex Total	10Km	21Km	30Km	40Km	Pace
1	3	2:15:35	Chebet	Wilson	KEN	MElite	1	8	1	11507	0:31:50	1:08:45	1:37:47	2:09:49	5:11
2	6	2:16:04	Lonyangata	Paul	KEN	MElite	2	8	2	11507	0:31:50	1:08:45	1:37:47	2:10:05	5:12
3	7	2:16:27	Abraha	Geb	ETH	MElite	3	8	3	11507	0:31:49	1:08:44	1:37:46	2:10:24	5:13
4	5	2:16:37	Kolum	Benjamin	KEN	MElite	4	8	4	11507	0:31:50	1:08:44	1:37:47	2:10:32	5:13
5	4	2:17:54	Adhane	Yemane	ETH	MElite	5	8	5	11507	0:31:50	1:08:45	1:37:47	2:11:06	5:16
6	2	2:17:59	Chelimo	Nicholas	KEN	MElite	6	8	6	11507	0:31:51	1:08:46	1:37:48	2:11:32	5:16
7	25151	2:27:26	Harada	Taku	JPN	M30-34	1	1218	7	11507	0:32:26	1:11:15	1:43:20	2:20:27	5:38
8	8	2:28:23	Arile	Julius	KEN	MElite	7	8	8	11507	0:31:51	1:08:44	1:38:39	2:19:39	5:40
9	30300	2:29:52	Ito	Tatsuya	JPN	M30-34	2	1218	9	11507	0:34:36	1:13:04	1:44:37	2:22:16	5:43
10	F9	2:30:23	Chepkirui	Joyce	KEN	WElite	1	9	1	10308	0:34:37	1:13:07	1:44:50	2:22:43	5:45
...															

- Chip Time: 完走時間
- Category: MElite, WElite, M15-19, M20-24, ..., W15-29, W20-24, ...
  - "No Age"となっている人がいるので注意
- Country: 3-letter country code: e.g., JPN, USA
- 完走者を抽出したら、総数が合っているかチェックすること

課題 1 補足説明

- 要約統計量: 結果を表にすればよい
- ヒストグラム: X 軸は 10 分ビンの完走時間、Y 軸は各ビンの完走者数
- CDF プロット: X 軸は完走時間、Y 軸は CDF [0:1]
- ページ数: 3-6 ページ程度　(ソースコードは必要ない)

Chip Time を抜き出すサンプルコード

```
# regular expression to read chiptime
re = /^\d+\s+F?\d+\s+(\d{1,2}:\d{2}:\d{2})\s+/

ARGF.each_line do |line|
  if re.match(line)
    puts "#{$1}"
  end
end
```

前回の演習: CCDF のプロット

第 3 回演習で使った JAIST サーバのアクセスログのコンテンツ毎のアクセス数分布を CCDF プロットにする

```
% ./count_contents.rb sample_access_log > contents.txt
% ./make_ccdf.rb contents.txt > ccdf.txt
```

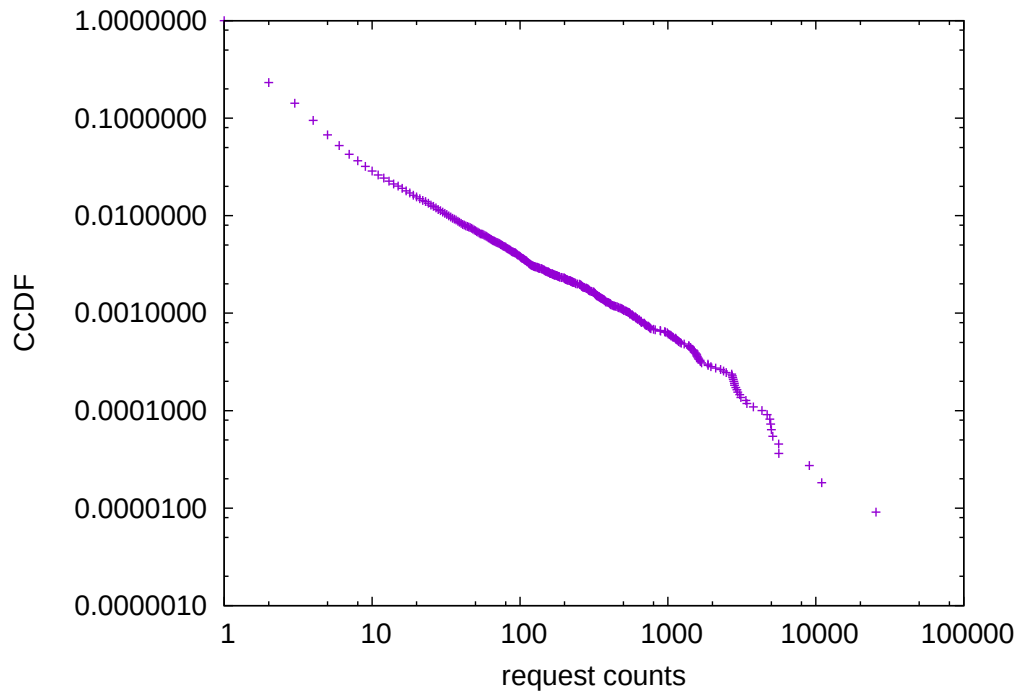

コンテンツ毎のアクセス数抽出スクリプト

```
# output: URL req_count byte_count
# regular expression for apache combined log format
#   host ident user time request status bytes referer agent
re = /^(\S+) (\S+) (\S+) \[(.*?)\] "(.*?)" (\d+) (\d+|-) "(.*?)" "(.*?)"/
# regular expression for request: method url proto
req_re = /(\w+) (\S+) (\S+)/
contents = 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, referer, agent = $~.captures
    # ignore if the status is not success (2xx)
    next unless /2\d{2}/.match(status)
    if req_re.match(request)
      method, url, proto = $~.captures
      # ignore if the method is not GET
      next unless /GET/.match(method)
      parsed += 1
      # count contents by request and bytes
      contents[url] = [contents[url][0] + 1, contents[url][1] + bytes.to_i]
    else
      # match failed.  print a warning msg
      $stderr.puts("request match failed at line #{count}: #{line.dump}")
    end
  else
    $stderr.puts("match failed at line #{count}: #{line.dump}") # match failed.
  end
end
contents.sort_by{|key, value| -value[0]}.each do |key, value|
  puts "#{key} #{value[0]} #{value[1]}"
end
$stderr.puts "# #{contents.size} unique contents in #{parsed} successful GET requests"
$stderr.puts "# parsed:#{parsed} ignored:#{count - parsed}"
```

コンテンツ毎のアクセス数

```
% cat contents.txt
/project/linuxonandroid/Ubuntu/12.04/full/ubuntu1204-v4-full.zip 25535 17829045
/project/morefont/xiongmaozhongwen.apk 10949 13535294486
/project/morefont/zhongguoxin.apk 9047 9549531354
/project/honi/some_software/Windows/Office_Plus_2010_SP1_W32_xp911.com.rar 5616
/project/morefont/fangzhengyouyijian.apk 5609 2879391721
/pub/Linux/CentOS/5.9/extras/i386/repodata/repomd.xml 5121 12213484
/pub/Linux/CentOS/5.9/updates/i386/repodata/repomd.xml 5006 10969621
/pub/Linux/CentOS/5.9/os/i386/repodata/repomd.xml 4953 6832653
/project/npppluginmgr/xml/plugins.md5.txt 4881 1369547
/project/winpenpack/X-LenMus/releases/X-LenMus_5.3.1_rev5.zip 4689 990250462

...

/pub/Linux/openSUSE/distribution/12.3/repo/oss/suse/x86_64/gedit-3.6.2-2.1.2.x8
/pub/sourceforge/n/nz/nzbcatcher/source/?C=D;O=A 1 1075
/ubuntu/pool/universe/m/mmass/mmass_5.4.1.orig.tar.gz 1 3754849
```

アクセス数を CCDF にするスクリプト

```
#!/usr/bin/env ruby

re = /^\S+\s+(\d+)\s+\d+/

n = 0
counts = Hash.new(0)
ARGF.each_line do |line|
  if re.match(line)
    counts[$1.to_i] += 1
    n += 1
  end
end

cum = 0
counts.sort.each do |key, value|
  comp = 1.0 - Float(cum) / n
  puts "#{key} #{value} #{comp}"
  cum += value
end
```

アクセス数の相補累積度数

```
% cat ccdf.txt
1 84414 1.0
2 9813 0.2315731022366253
3 5199 0.1422446360135818 4
4 3034 0.0949177537254331
5 1636 0.0672990268813779
6 1083 0.0524063976404831 6
7 663 0.0425477683813824 1
8 495 0.0365124302476946 8
9 367 0.0320064085641721 4
10 274 0.0286655803664898 07

...

5616 1 3.6412296432475344e-05
9047 1 2.730922232441202e-05
10949 1 1.8206148216237672e-05
25535 1 9.103074108174347e-06
```

gnuplot スクリプト

```
set logscale
set xlabel "request counts"
set ylabel "CCDF"

plot "ccdf.txt" using 1:3 notitle with points
```

今回の演習: 相関係数の計算

- データの相関係数を計算する
  - correlation-data-1.txt, correlation-data-2.txt

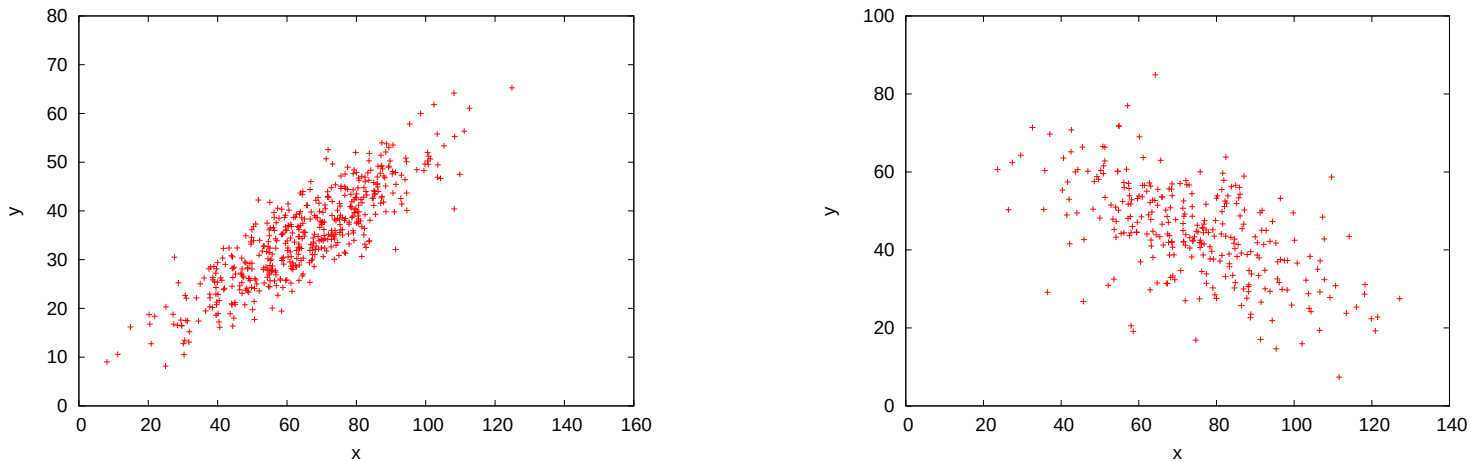

data-1:r=0.87 (left), data-2:r=-0.60 (right)

演習: 相関係数の計算スクリプト

```
#!/usr/bin/env ruby

# regular expression for matching 2 floating numbers
re = /([-+]?\d+(?:\.\d+)?)\s+([-+]?\d+(?:\.\d+)?)/

sum_x = 0.0 # sum of x
sum_y = 0.0 # sum of y
sum_xx = 0.0 # sum of x^2
sum_yy = 0.0 # sum of y^2
sum_xy = 0.0 # sum of xy
cc = 0.0 # correlation coefficient
n = 0 # the number of data

ARGF.each_line do |line|
    if re.match(line)
      x = $1.to_f
      y = $2.to_f
      sum_x += x
      sum_y += y
      sum_xx += x**2
      sum_yy += y**2
      sum_xy += x * y
      n += 1
    end
end

denom = (sum_xx - sum_x**2 / n) * (sum_yy - sum_y**2 / n)
if denom != 0.0
  cc = (sum_xy - sum_x * sum_y / n) / Math.sqrt(denom)
end

printf "n:%d r:%.3f\n", n, cc
```

今回の演習 2: 類似度計算

- データの類似度を計算する
  - 「集合知プログラミング」2 章の参考データ
  - 7 人のユーザの映画評価スコア: scores.txt

```
% cat scores.txt
# A dictionary of movie critics and their ratings of a small set of movies
'Lisa Rose': 'Lady in the Water': 2.5, 'Snakes on a Plane': 3.5, 'Just My Luck': 3.0, 'Superman Returns':
'Gene Seymour': 'Lady in the Water': 3.0, 'Snakes on a Plane': 3.5, 'Just My Luck': 1.5, 'Superman Returns
'Michael Phillips': 'Lady in the Water': 2.5, 'Snakes on a Plane': 3.0, 'Superman Returns': 3.5, 'The Nigh
'Claudia Puig': 'Snakes on a Plane': 3.5, 'Just My Luck': 3.0, 'The Night Listener': 4.5, 'Superman Returr
'Mick LaSalle': 'Lady in the Water': 3.0, 'Snakes on a Plane': 4.0, 'Just My Luck': 2.0, 'Superman Returns
'Jack Matthews': 'Lady in the Water': 3.0, 'Snakes on a Plane': 4.0, 'The Night Listener': 3.0, 'Superman
'Toby': 'Snakes on a Plane':4.5,'You, Me and Dupree':1.0,'Superman Returns':4.0
```

スコアデータ

- 簡単な例題: データが少なすぎる
- 一覧にすると以下のようになる

```
#name: 'Lady in the Water' 'Snakes on a Plane' 'Just My Luck' 'Superman Returns
Lisa Rose:           2.5 3.5 3.0 3.5 3.0
Gene Seymour:        3.0 3.5 1.5 5.0 3.0
Michael Phillips:    2.5 3.0  -  3.5 4.0
Claudia Puig:         -  3.5 3.0 4.0 4.5
Mick LaSalle:        3.0 4.0 2.0 3.0 3.0
Jack Matthews:       3.0 4.0  -  5.0 3.0
Toby:                 -  4.5  -  4.0  -
```

類似度計算の実行

- コサイン類似度を使ってユーザ間の類似度行列を作る

```
% ruby similarity.rb scores.txt
Lisa Rose:        1.000 0.959 0.890 0.921 0.982 0.895 0.708
Gene Seymour:     0.959 1.000 0.950 0.874 0.962 0.979 0.783
Michael Phillips: 0.890 0.950 1.000 0.850 0.929 0.967 0.693
Claudia Puig:     0.921 0.874 0.850 1.000 0.875 0.816 0.695
Mick LaSalle:     0.982 0.962 0.929 0.875 1.000 0.931 0.727
Jack Matthews:    0.895 0.979 0.967 0.816 0.931 1.000 0.822
Toby:             0.708 0.783 0.693 0.695 0.727 0.822 1.000
```

類似度計算スクリプト (1/2)

```
# regular expression to read data
# 'name': 'title0': score0, 'title1': score1, ...
re = /'(.+?)':\s+(\S.*)/
name2uid = Hash.new # keeps track of name to uid mapping
title2tid = Hash.new # keeps track of title to tid mapping
scores = Hash.new # scores[uid][tid]: score of title_id by user_id

# read data into scores[uid][tid]
ARGF.each_line do |line|
  if re.match(line)
    name = $1
    ratings = $2.split(",")

    if name2uid.has_key?(name)
      uid = name2uid[name]
    else
      uid = name2uid.length
      name2uid[name] = uid
      scores[uid] = {} # create empty hash for title and score pairs
    end
    ratings.each do |rating|
      if rating.match(/'(.+?)':\s*(\d\.\d)/)
        title = $1
        score = $2.to_f
        if title2tid.has_key?(title)
          tid = title2tid[title]
        else
          tid = title2tid.length
          title2tid[title] = tid
        end
        scores[uid][tid] = score
      end
    end
  end
end
```

類似度計算スクリプト (2/2)

```
# compute cosine similarity between 2 users
def comp_similarity(h1, h2)
  sum_xx = 0.0 # sum of x^2
  sum_yy = 0.0 # sum of y^2
  sum_xy = 0.0 # sum of xy
  score = 0.0 # similarity score

  h1.each do |tid, score|
    sum_xx += score**2
    if h2.has_key?(tid)
      sum_xy += score * h2[tid]
    end
  end
  h2.each_value do |score|
    sum_yy += score**2
  end
  denom = Math.sqrt(sum_xx) * Math.sqrt(sum_yy)
  if denom != 0.0
    score = sum_xy / denom
  end
  return score
end

# create n x n matrix of similarities between users
n = name2uid.length
similarities = Array.new(n) { Array.new(n) }
for i in 0 .. n - 1
  printf "%-18s", name2uid.key(i) + ':'
  for j in 0 .. n - 1
    similarities[i][j] = comp_similarity(scores[i], scores[j])
    printf "%.3f ", similarities[i][j]
  end
  print "\n"
end
```

より本格的なデータセット

- MovieLens:
  `http://grouplens.org/datasets/movielens/`
  - ミネソタ大学が公開している協調フィルタリング用データセット
  - ユーザの映画評価: 100K, 1M, 10M のスコアデータ
    - u.data: スコアデータ
    - 他にも各ユーザの属性情報や各映画の属性情報も含まれている

```
% head u.data
#user_id item_id rating timestamp
196     242     3       881250949
186     302     3       891717742
22      377     1       878887116
244     51      2       880606923
166     346     1       886397596
298     474     4       884182806
115     265     2       881171488
253     465     5       891628467
305     451     3       886324817
6       86      3       883603013
...
```

まとめ

第 6 回 相関

- オンラインお勧めシステム
- 距離と類似度
- 相関係数
- 演習: 相関

次回予定

第 7 回 多変量解析 (6/1)

- データセンシング
- 地理的位置情報 (geo-location)
- 線形回帰
- 主成分分析
- 演習: 線形回帰