インターネット計測とデータ解析 第 4 回

長 健二朗

2013 年 5 月 1 日

前回のおさらい

第 3 回 データの収集と記録 (4/24)

- 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

今日のテーマ

第 4 回 分布と信頼区間

- 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**

正規分布 (normal distribution) 1/2

- つりがね型の分布、ガウス分布とも呼ばれる
- 2 つの変数で定義: 平均 μ、分散 σ^2
- 乱数の和は正規分布に従う
- 標準正規分布: $\mu = 0, \sigma = 1$
- 正規分布ではデータの
  - 68%は $(mean \pm stddev)$
  - 95%は $(mean \pm 2stddev)$ の範囲に入る

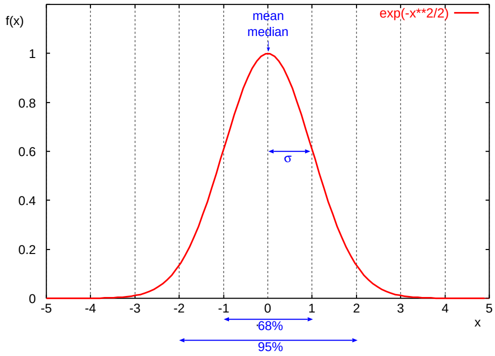

正規分布 (normal distribution) 2/2

確率密度関数 (PDF)

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-(x-\mu)^2/2\sigma^2}$$

累積分布関数 (CDF)

$$F(x) = \frac{1}{2}(1 + erf\frac{x-\mu}{\sigma\sqrt{2}})$$

$$\mu : mean, \sigma^2 : variance$$

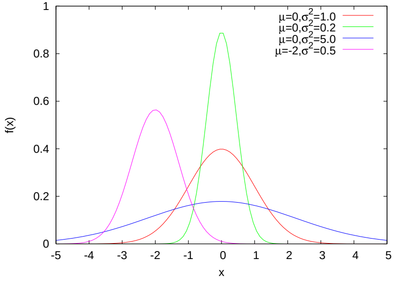

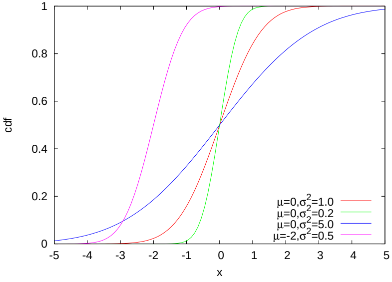

信頼区間 (confidence interval)

- 信頼区間 (confidence interval)
  - 統計的に真値に範囲を示す
  - 推定値の確かさ、不確かさを示す
- 信頼度 (confidence level) 有意水準 (significance level)

$$Prob\{c_1 \leq \mu \leq c_2\} = 1 - \alpha$$

$$\begin{array}{ll} (c1, c2): & confidence\ interval \\ 100(1-\alpha): & confidence\ level \\ \alpha: & significance\ level \end{array}$$

- 例: 信頼度 95% で、母平均は、$c1$ と $c2$ の間に存在
- 慣習として、信頼度 95% と 99% がよく使われる

95%信頼区間

正規母集団 $N(\mu, \sigma)$ から得られた標本平均 $\bar{x}$ は正規分布 $N(\mu, \sigma/\sqrt{n})$ に従う

95%信頼区間は標準正規分布の以下の部分を意味する

$$-1.96 \leq \frac{\bar{x} - \mu}{\sigma\sqrt{n}} \leq 1.96$$

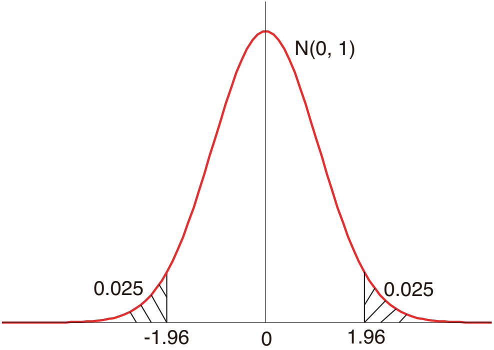

標準正規分布 N(0, 1)

信頼区間の意味

- 信頼度 90% とは、90% の確率で母平均が信頼区間内に存在すること

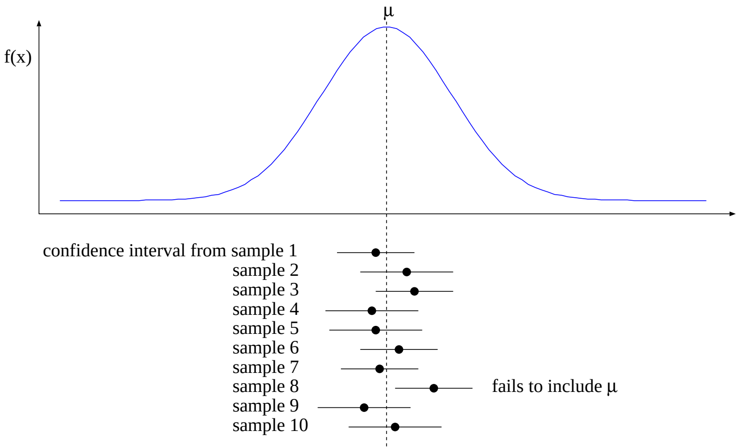

平均値の信頼区間

サンプルサイズが大きければ、母平均の信頼区間は、

$$\bar{x} \mp z_{1-\alpha/2}\, s/\sqrt{n}$$

ここで、$\bar{x}$:標本平均 s:標本標準偏差 n:標本数 α:有意水準
$z_{1-\alpha/2}$:標準正規分布における $(1-\alpha/2)$ 領域の境界値

- 信頼度 95% の場合: $z_{1-0.05/2} = 1.960$
- 信頼度 90% の場合: $z_{1-0.10/2} = 1.645$
- 例: TCP スループットを 5 回計測
  - 3.2, 3.4, 3.6, 3.6, 4.0Mbps
  - 標本平均:$\bar{x} = 3.56$Mbps 標本標準偏差:$s = 0.30$Mbps
  - 95%信頼区間:

$$\bar{x} \mp 1.96(s/\sqrt{n}) = 3.56 \mp 1.960 \times 0.30/\sqrt{5} = 3.56 \mp 0.26$$

  - 90%信頼区間:

$$\bar{x} \mp 1.645(s/\sqrt{n}) = 3.56 \mp 1.645 \times 0.30/\sqrt{5} = 3.56 \mp 0.22$$

平均値の信頼区間とサンプル数

サンプル数が増えるに従い、信頼区間は狭くなる

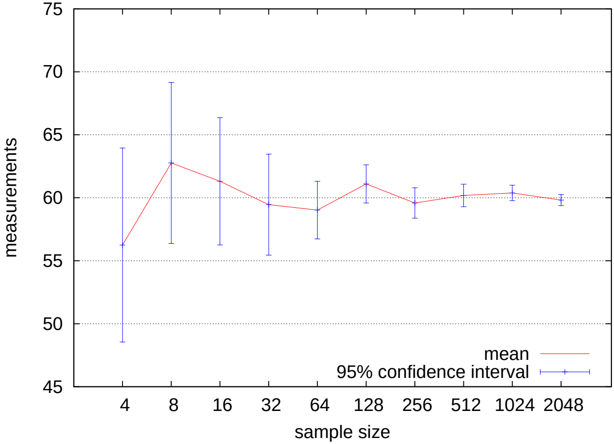

平均値の信頼区間のサンプル数による変化

サンプル数が少ない場合の平均値の信頼区間

サンプル数が少ない (< 30) 場合、母集団が正規分布に従う場合に限って、信頼区間を求める事ができる

- 正規分布からサンプルを取った場合、標準誤差 $(\bar{x}-\mu)/(s/\sqrt{n})$ は $t(n-1)$ 分布となる

$$\bar{x} \mp t_{[1-\alpha/2;n-1]}\, s/\sqrt{n}$$

ここで、$t_{[1-\alpha/2;n-1]}$ は 自由度 $(n-1)$ の t 分布における $(1-\alpha/2)$ 領域の境界値

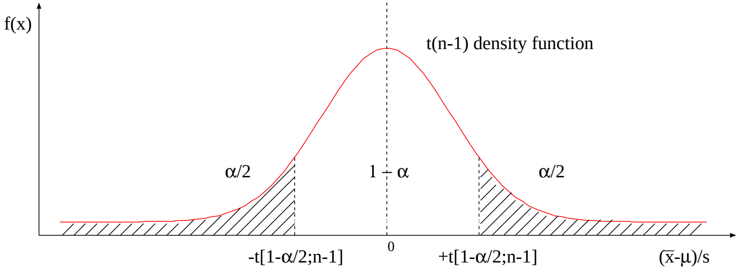

サンプル数が少ない場合の平均値の信頼区間の例

- 例: 前述の TCP スループット計測では、$t(n-1)$ 分布を使った信頼区間の計算をする必要
  - 95%信頼区間 $n = 5$: $t_{[1-0.05/2,4]} = 2.776$

$$\bar{x} \mp 2.776(s/\sqrt{n}) = 3.56 \mp 2.776 \times 0.30/\sqrt{5} = 3.56 \mp 0.37$$

  - 90%信頼区間 $n = 5$: $t_{[1-0.10/2,4]} = 2.132$

$$\bar{x} \mp 2.132(s/\sqrt{n}) = 3.56 \mp 2.132 \times 0.30/\sqrt{5} = 3.56 \mp 0.29$$

他の信頼区間

- 母分散:
  - 自由度 $(n-1)$ の χ^2 分布
- 標本分散の比:
  - 自由度 (n_1-1, n_2-1) の F 分布

信頼区間の応用

応用例

- 平均値の推定範囲を示す
- 平均と標準偏差から、必要な信頼区間を満足するために何回試行が必要か求める
- 必要な信頼区間を満足するまで計測を繰り返す

平均を得るために必要なサンプル数

- 信頼度 $100(1-\alpha)$ で $\pm r\%$ の精度で母平均を推定するためには何回の試行 n が必要か？
- 予備実験を行い 標本平均 $\bar{x}$ と 標準偏差 s を得る
- サンプルサイズ n、信頼区間 $\bar{x} \mp z\frac{s}{\sqrt{n}}$、必要な精度 $r\%$

$$\bar{x} \mp z\frac{s}{\sqrt{n}} = \bar{x}(1 \mp \frac{r}{100})$$

$$n = (\frac{100zs}{r\bar{x}})^2$$

- 例: TCP スループットの予備計測で、標本平均 3.56Mbps、標本標準偏差 0.30Mbps を得た。
信頼度 95%、精度 (<0.1Mbps) で平均を得るためには何回測定する必要があるか？

$$n = (\frac{100zs}{r\bar{x}})^2 = (\frac{100 \times 1.960 \times 0.30}{0.1/3.56 \times 100 \times 3.56})^2 = 34.6$$

推定と仮説検定

仮説検定 (hypothesis testing) の目的

- 母集団について仮定された命題を標本に基づいて検証

推定と仮説検定は裏表の関係

- 推定: ある範囲に入ることを予想
- 仮説検定: 仮説が採用されるか棄却されるか
    - 母集団に入るという仮説を立て、その仮説が 95%信頼区間に入るかを計算
    - 区間内であれば仮説は採用される
    - 区間外では仮説は棄却される

検定の例

N 枚のコインを投げて表が 10 枚でた。 この場合の N として 36 枚はあり得るか？ (ただし分布は $\mu = N/2, \sigma = \sqrt{n}/2$ の正規分布にしたがうものとする)

- 仮説: $N = 36$ で表が 10 枚出る
- 95%信頼度で検定

$$-1.96 \leq (\bar{x} - 18)/3 \leq 1.96 \quad 12.12 \leq \bar{x} \leq 23.88$$

10 は 95%区間の外側にあるので 95%信頼度では $N = 36$ という仮説は棄却される

外れ値の除外

測定値に異常と思われるデータがあった場合、むやみに棄却してはいけない。
(ときには、有益な発見に繋がる可能性)

- Chauvenet の判断基準: 外れ値を棄却するための経験則
  - サンプルサイズ n から、標本平均を標本標準偏差を計算
  - 正規分布を仮定して、その値の出現確率 p を求める
  - もし $n \times p < 0.5$ ならその値を棄却してもよい
  - 注: $n < 50$ の場合は信頼性が低い。この方法は繰り返し用いてはいけない。
- 例: 10 回の遅延計測値: 4.6, 4.8, 4.4, 3.8, 4.5, 4.7, 5.8, 4.4, 4.5, 4.3 (sec). 5.8 秒は異常値として棄却できるか?
  - $\bar{x} = 4.58, s = 0.51$
  - $t_{sus} = \frac{x_{sus} - \bar{x}}{s} = \frac{5.8 - 4.58}{0.51} = 2.4\ s$ より 2.4 倍大きい
  - $P(|x - \bar{x}| > 2.4s) = 1 - P(|x - \bar{x}| < 2.4s) = 1 - 0.984 = 0.016$
  - $n \times p = 10 \times 0.016 = 0.16$
  - $0.16 < 0.5$: 5.8 秒というデータは棄却できる

正確度と精度、誤差

正確度 (accuracy): 測定値と真値とのずれ
精度 (precision): 測定値のばらつきの幅
誤差 (error): 真値からのずれ、その不確かさの範囲

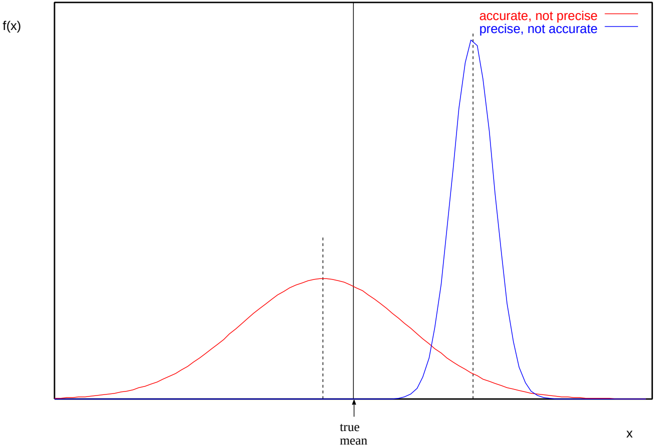

いろいろな誤差

測定誤差

- 系統誤差 (条件を把握できれば補正可能)
  - 器械的誤差、理論的誤差、個人的誤差
- 偶然誤差 (ノイズ、観測を繰り返せば精度向上)

計算誤差

- まるめ誤差
- 打ち切り誤差
- 情報落ち
- 桁落ち
- 誤差の伝搬

サンプリング誤差

- 標本調査を行う場合、普通は真値は不明
- 標本誤差: 真値との差の確率的なばらつきの幅

有効数字と有効桁数

1.23 の有効数字は 3 桁 ($1.225 \leq 1.23 < 1.235$)

表記

表記	有効桁数	
12.3	3	
12.300	5	
0.0034	2	
1200	4	(あいまい、1.200×10^3)
2.34×10^4	3	

計算

- 計算途中は桁数が大きいまま計算
  - 筆算などの場合は 1 桁多く取ればよい
- 最終的な数字に有効桁数を適用

基本ルール

- 加減算: 桁数が少ないものに合わせる
  - $1.23 + 5.724 = 6.954 \Rightarrow 6.95$
- 乗除算: もとの有効数字が最も少ないものに合わせる
  - $4.23 \times 0.38 = 1.6074 \Rightarrow 1.6$

コンピュータの計算精度

- integer (32/64bits)
  - 32bit signed integer (2G までしかカウントできない)
- 32bit floating point (IEEE 754 single precision): 有効桁数 7
  - sign:1bit, exponent:8bits, mantissa:23bits
  - $16,000,000 + 1 = 16,000,000!!$
- 64bit floating point (IEEE 754 double precision): 有効桁数 15
  - sign:1bit, exponent:11bits, mantissa:52bits

前回の演習: Web アクセスログ サンプルデータ

- apache log (combined log format)
- 米国 Splunk 社のチュートリアル用疑似データ (24 時間分)
- 約 500KB(zip 圧縮)、 解凍後は約 9MB

`http://www.iijlab.net/~kjc/classes/sfc2013s-measurement/access_combined.zip`

サンプルアクセスログ

```
10.32.1.43 - - [10/Apr/2013:00:07:00] "GET /flower_store/product.screen?product_id=FL-DLH-02 HTTP/1.1" \
  200 10901 "http://mystore.splunk.com/flower_store/category.screen?category_id=GIFTS&JSESSIONID=SD7SL1FF9
  "Mozilla/5.0 (X11; U; Linux i686; en-US; rv:1.8.0.10) Gecko/20070223 CentOS/1.5.0.10-0.1.el4.centos Fire
  4361 3217
10.32.1.43 - - [10/Apr/2013:00:07:00] "GET /flower_store/category.screen?category_id=GIFTS HTTP/1.1" \
  200 10567 "http://mystore.splunk.com/flower_store/cart.do?action=purchase&itemId=EST-12&JSESSIONID=SD7SI
  "Mozilla/5.0 (X11; U; Linux i686; en-US; rv:1.8.0.10) Gecko/20070223 CentOS/1.5.0.10-0.1.el4.centos Fire
  1685 2466
177.23.21.50 - - [10/Apr/2013:00:07:45] "GET /flower_store/category.screen?category_id=PLANTS HTTP/1.1" \
  200 10567 "http://mystore.splunk.com/flower_store/cart.do?action=purchase&itemId=EST-18&JSESSIONID=SD7SI
  "Mozilla/5.0 (X11; U; Linux i686; en-US; rv:1.8.0.10) Gecko/20070223 CentOS/1.5.0.10-0.1.el4.centos Fire
  2526 482
177.23.21.50 - - [10/Apr/2013:00:07:45] "GET /flower_store/category.screen?category_id=PLANTS HTTP/1.1" \
  200 10567 "http://mystore.splunk.com/flower_store/cart.do?action=purchase&itemId=EST-18&JSESSIONID=SD7SI
  "Mozilla/5.0 (X11; U; Linux i686; en-US; rv:1.8.0.10) Gecko/20070223 CentOS/1.5.0.10-0.1.el4.centos Fire
  2623 2099
233.77.49.54 - - [10/Apr/2013:00:07:58] "GET /flower_store/category.screen?category_id=FLOWERS HTTP/1.1" \
  200 10567 "http://mystore.splunk.com/flower_store/cart.do?action=purchase&itemId=EST-11&JSESSIONID=SD7SI
  "Mozilla/5.0 (X11; U; Linux i686; en-US; rv:1.8.0.10) Gecko/20070223 CentOS/1.5.0.10-0.1.el4.centos Fire
  662 2486
10.2.91.32 - - [10/Apr/2013:00:08:00] "GET /flower_store/category.screen?category_id=BALLOONS HTTP/1.1" \
  200 10567 "http://mystore.splunk.com/flower_store/cart.do?action=purchase&itemId=EST-11&JSESSIONID=SD7SI
  "Mozilla/5.0 (X11; U; Linux i686; en-US; rv:1.8.0.10) Gecko/20070223 CentOS/1.5.0.10-0.1.el4.centos Fire
  431 4899
10.2.91.32 - - [10/Apr/2013:00:08:00] "GET /flower_store/category.screen?category_id=BALLOONS HTTP/1.1" \
  200 10567 "http://mystore.splunk.com/flower_store/cart.do?action=purchase&itemId=EST-11&JSESSIONID=SD7SI
  "Mozilla/5.0 (X11; U; Linux i686; en-US; rv:1.8.0.10) Gecko/20070223 CentOS/1.5.0.10-0.1.el4.centos Fire
  3276 322
10.32.1.37 - - [10/Apr/2013:00:08:26] "GET /flower_store/category.screen?category_id=FLOWERS HTTP/1.1" \
  200 10567 "http://mystore.splunk.com/flower_store/cart.do?action=purchase&itemId=EST-17&JSESSIONID=SD7SI
  "Mozilla/5.0 (X11; U; Linux i686; en-US; rv:1.8.0.10) Gecko/20070223 CentOS/1.5.0.10-0.1.el4.centos Fire
  1494 4680
192.168.11.38 - - [10/Apr/2013:00:08:49] "GET /flower_store/category.screen?category_id=FLOWERS HTTP/1.1"
  200 10567 "http://mystore.splunk.com/flower_store/cart.do?action=purchase&itemId=EST-13&JSESSIONID=SD7SI
  "Mozilla/5.0 (X11; U; Linux i686; en-US; rv:1.8.0.10) Gecko/20070223 CentOS/1.5.0.10-0.1.el4.centos Fire
```

前回の演習: 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 access_combined.log > access-5min.txt
% more access-5min.txt
2013-04-10T00:05 11 116664
2013-04-10T00:10 12 137116
2013-04-10T00:15 15 168736
2013-04-10T00:20 9 102072
2013-04-10T00:25 10 105680
2013-04-10T00:30 13 139694
2013-04-10T00:35 12 129011
2013-04-10T00:40 9 95103
...
% gnuplot
gnuplot> load 'access.plt'
```

前回の演習: 5 分間隔でリクエスト数と転送数を抽出

```
#!/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 request is not "GET"
    next unless request.match(/GET\s.*/)
    # ignore if the status is not success (2xx)
    next unless status.match(/2\d{2}/)
    parsed += 1
    # parse timestamp
    ts = DateTime.strptime(time, '%d/%b/%Y:%H:%M:%S')
    # 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

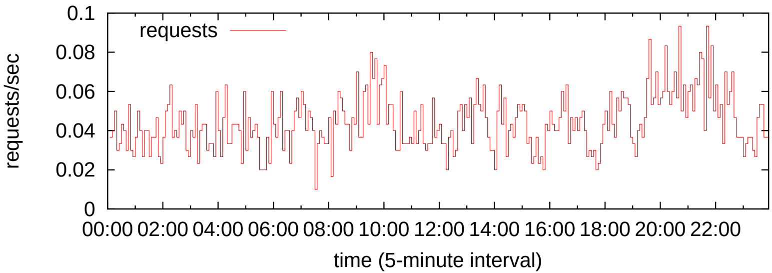

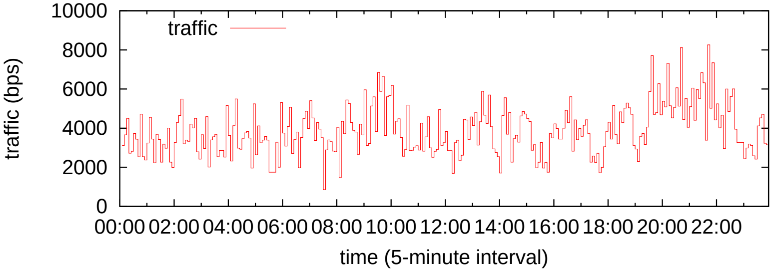

gnuplot script

- multiplot 機能で 2 つのプロットをまとめる

```
set terminal postscript eps color solid 18
set xlabel "time (5-minute interval)"
set xdata time
set format x "%H:%M"
set timefmt "%Y-%m-%dT%H:%M"
set xrange ['2013-04-10T00:00':'2013-04-10T23:55']
set key left top

set multiplot layout 2,1

set yrange [0:0.1]
set ylabel "requests/sec"
plot "access-5min.txt" using 1:($2/300) title 'requests' with steps

set yrange [0:10000]
set ylabel "traffic (bps)"
plot "access-5min.txt" using 1:($3*8/300) title 'traffic' with steps

unset multiplot
```

演習: 正規乱数の生成

- 正規分布に従う疑似乱数の生成
  - 一様分布の疑似乱数生成関数 (ruby の rand など) を使って、平均 u、標準偏差 s を持つ疑似乱数生成プログラムを作成
- ヒストグラムの作成
  - 標準正規分布に従う疑似乱数を生成し、そのヒストグラム作成、標準正規分布であることを確認する
- 信頼区間の計算
  - サンプル数によって信頼区間が変化することを確認
    疑似正規乱数生成プログラムを用いて、平均 60, 標準偏差 10 の正規分布に従う乱数列を 10 種類作る。サンプル数 n = 4, 8, 16, 32, 64, 128, 256, 512, 1024, 2048 の乱数列を作る。
  - 標本から母平均の区間推定
    この 10 種類の乱数列のそれぞれから、母平均の区間推定を行え。信頼度 95%で、信頼区間 "$\pm 1.960 \frac{s}{\sqrt{n}}$" を用いよ。10 種類の結果をひとつの図にプロットせよ。 X 軸にサンプル数を Y 軸に平均値をとり、それぞれのサンプルから推定した平均とその信頼区間を示せ

box-muller 法による正規乱数生成

basic form: creates 2 normally distributed random variables, z_0 and z_1, from 2 uniformly distributed random variables, u_0 and u_1, in $(0, 1]$

$$z_0 = R\cos(\theta) = \sqrt{-2\ln u_0}\cos(2\pi u_1)$$
$$z_1 = R\sin(\theta) = \sqrt{-2\ln u_0}\sin(2\pi u_1)$$

polar form: 三角関数を使わない近似
u_0 and u_1: uniformly distributed random variables in $[-1, 1]$,
$s = u_0^2 + u_1^2$ (if $s = 0$ or $s \geq 1$, re-select u_0, u_1)

$$z_0 = u_0\sqrt{\frac{-2\ln s}{s}}$$

$$z_1 = u_1\sqrt{\frac{-2\ln s}{s}}$$

box-muller 法による正規乱数生成コード

```
# usage: box-muller.rb [n [m [s]]]
n = 1 # number of samples to output
mean = 0.0
stddev = 1.0

n = ARGV[0].to_i if ARGV.length >= 1
mean = ARGV[1].to_i if ARGV.length >= 2
stddev = ARGV[2].to_i if ARGV.length >= 3

# function box_muller implements the polar form of the box muller method,
# and returns 2 pseudo random numbers from standard normal distribution
def box_muller
  begin
    u1 = 2.0 * rand - 1.0  # uniformly distributed random numbers
    u2 = 2.0 * rand - 1.0  # ditto
    s = u1*u1 + u2*u2    # variance
  end while s == 0.0 || s >= 1.0
  w = Math.sqrt(-2.0 * Math.log(s) / s) # weight
  g1 = u1 * w  # normally distributed random number
  g2 = u2 * w  # ditto
  return g1, g2
end
# box_muller returns 2 random numbers.  so, use them for odd/even rounds
x = x2 = nil
n.times do
  if x2 == nil
    x, x2 = box_muller
  else
    x = x2
    x2 = nil
  end
  x = mean + x * stddev  # scale with mean and stddev
  printf "%.6f\n", x
end
```

正規乱数のヒストグラム作成

- 標準正規乱数のヒストグラムを作成し、正規分布であることを確認する
- 標準正規乱数を 10,000 個生成し、小数点 1 桁のビンでヒストグラムを作成

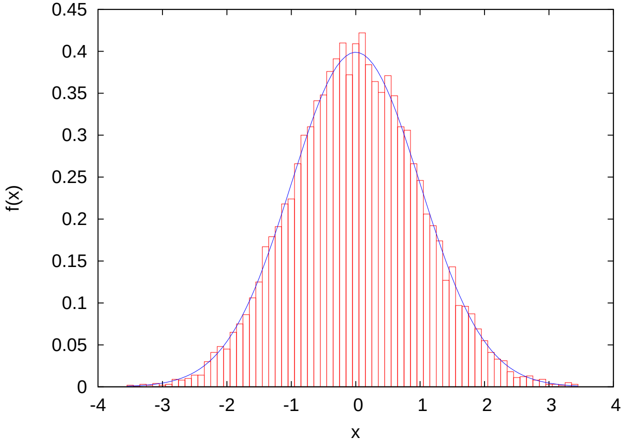

ヒストグラムの作成

- 少数点以下 1 桁でヒストグラムを作成する

```
#
# create histogram: bins with 1 digit after the decimal point
#

re = /(-?\d*\.\d+)/ # regular expression for input numbers

bins = Hash.new(0)

ARGF.each_line do |line|
  if re.match(line)
    v = $1.to_f
    # round off to a value with 1 digit after the decimal point
    offset = 0.5    # for round off
    offset = -offset if v < 0.0
    v = Float(Integer(v * 10 + offset)) / 10
    bins[v] += 1 # increment the corresponding bin
  end
end

bins.sort{|a, b| a[0] <=> b[0]}.each do |key, value|
  puts "#{key} #{value}"
end
```

正規乱数のヒストグラムのプロット

```
set boxwidth 0.1
set xlabel "x"
set ylabel "f(x)"
plot "box-muller-histogram.txt" using 1:($2/1000) with boxes notitle, \
     1/sqrt(2*pi)*exp(-x**2/2) notitle with lines linetype 3
```

平均値の信頼区間とサンプル数の検証

サンプル数が増えるに従い、信頼区間は狭くなる

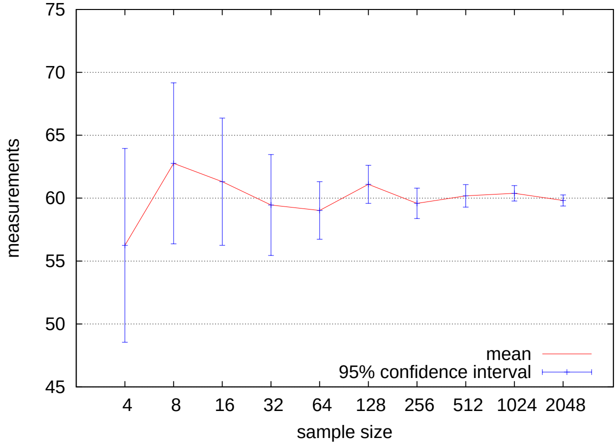

平均値の信頼区間のサンプル数による変化

課題 1: ホノルルマラソン完走時間のプロット

- ねらい: 実データから分布を調べる
- データ: 2012 年のホノルルマラソンの記録
  - http://results.sportstats.ca/res2012/honolulumarathon_m.htm
  - 完走者 24,070 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: 2013 年 5 月 16 日

ホノルルマラソンデータ

データフォーマット

```
      Chip     Pace                                                     Gender    Category       @10km  @21.1  @3
Place Time     /mi       #    Name                City          ST CNT Plce/Tot Plc/Tot Category Split1 Split2
---- -------- ---- ----- ------------------- ------------ -- --- --------- -------- ------ ----- ------- ---
   1 02:12:31 5:04     6 Kipsang, Wilson     Iten            KEN  1/12690  1/16   MElite 31:40 1:07:07 1:
   2 02:13:08 5:05     7 Geneti, Markos      Addis Ababa     ETH  2/12690  2/16   MElite 31:39 1:07:02 1:
   3 02:14:15 5:08    11 Kimutai, Kiplimo    Eldoret         KEN  3/12690  3/16   MElite 31:40 1:07:02 1:
   4 02:14:55 5:09     2 Ivuti, Patrick      Kangundo        KEN  4/12690  4/16   MElite 31:40 1:07:02 1:
   5 02:15:17 5:10    12 Arile, Julius       Kepenguria      KEN  5/12690  5/16   MElite 31:39 1:07:02 1:
   6 02:15:53 5:11     9 Bouramdane, Abderr  Champs De Cou   MAR  6/12690  6/16   MElite 31:40 1:07:01 1:
   7 02:18:27 5:17     8 Manza, Nicholas     Ngong Hills     KEN  7/12690  7/16   MElite 31:39 1:07:01 1:
   8 02:19:46 5:20     1 Chelimo, Nicholas   Ngong Hills     KEN  8/12690  8/16   MElite 31:40 1:07:02 1:
   9 02:25:23 5:33 20850 Harada, Taku        Nagoya-Shi   AI JPN  9/12690  1/1238 M25-29 31:54 1:09:52 1:
  10 02:27:12 5:37 25474 Hagawa, Eiichi      Matsumoto    NA JPN 10/12690  1/1501 M30-34 32:46 1:12:21 1:
...
```

- 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
  - "UK"が交じっているので注意
- 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

まとめ

第 4 回 分布と信頼区間

- 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**

次回予定

第 5 回 多様性と複雑さ (5/8)

- 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

参考文献

[1] Ruby official site. `http://www.ruby-lang.org/`

[2] gnuplot official site. `http://gnuplot.info/`

[3] Mark Crovella and Balachander Krishnamurthy. *Internet measurement: infrastructure, traffic, and applications*. Wiley, 2006.

[4] Pang-Ning Tan, Michael Steinbach and Vipin Kumar. *Introduction to Data Mining*. Addison Wesley, 2006.

[5] Raj Jain. *The art of computer systems performance analysis*. Wiley, 1991.

[6] Toby Segaran. (當山仁健 鴨澤眞夫 訳). 集合知プログラミング. オライリージャパン. 2008.

[7] Chris Sanders. (高橋基信 宮本久仁男 監訳 岡真由美 訳). 実践パケット解析 第 *2* 版 — *Wireshark* を使ったトラブルシューティング. オライリージャパン. 2012.

[8] あきみち、空閑洋平. インターネットのカタチ. オーム社. 2011.

[9] 井上洋, 野澤昌弘. 例題で学ぶ統計的方法. 創成社, 2010.

[10] 平岡和幸, 掘玄. プログラミングのための確率統計. オーム社, 2009.