

大数の法則

前回はデータ(標本)の分布を知るためのモーメント(平均、分散、歪度、尖度)について紹介しました。実際にEViewsのコマンドを利用して正規分布や対数正規分布の標本を、乱数機能でたくさん生成しました。今回は1次のモーメントである「平均」について少し丁寧に考えてみましょう。

我々の興味関心は、今、小学6年生の平均身長を推定するところにあるものとします。「日本全国」の小学6年生の平均身長に興味があるとすれば、母集団は「日本全国の小学6年生」ということになります。確率変数 X は全国の小学6年生の身長であり、その母平均を μ 、母分散 σ^2 とします(分布は特定しません)。ただ、我々には費用と時間の制約がありますので、ランダムサンプリング¹により、 n 人の小学6年生を選び、身長を計測することにします。この時の n 人の平均値を \bar{X} と書くことにします。

$$\bar{X} = \frac{x_1 + \dots + x_n}{n} \quad (1)$$

n が小さいと、バラツキによって \bar{X} と μ は少し離れた値になりそうですが、 n が大きくなるほど、 \bar{X} が μ に近づくことが想像できます。手元に収集した標本 x_i の個数が増えると、一次のモーメントである平均(推定値)は X の母平均 μ に限り無く近づきます。この事を「大数(たいすう)の法則」(Law of Large Numbers)と呼び、式で示すと次のようになります。

$$\Pr\{|\bar{x} - \mu| > \epsilon\} \rightarrow 0 \quad (n \rightarrow \infty) \quad (2)$$

ϵ は $\epsilon > 0$ を満たすものとします。2式は、「 n が大きくなるにつれ、標本平均 \bar{x} と母平均 μ の差の絶対値が ϵ より大きくなる確率は、ゼロに収束する」と事を意味しています。計量経済学の論文では2式を $\bar{x} \xrightarrow{P} \mu$ と書くこともあります。

それではここでEViewsのプログラミング機能を利用して、大数の法則をシミュレーションしてみましょう。仮に小学6年生の身長 X は $N(145, 10^2)$ に従うものとします。

注意: ここではコンピュータによるシミュレーションの都合上、皆さんに馴染みのある正規分布を利用して標本を生成しますが、前述のように分布はどんなものであってもかまいません。

次のプログラムを記述してください。

```
' 標本数  $n$  が増えると、標本平均  $\bar{X}$  は母平均  $\mu$  に収束する」ことを見て学ぶ
'550個の標本を利用します。ワークファイル名は height にします
wfcreate(wf=height) u 550

' 行列オブジェクト lln には 10, 50, 100, ..., 550 人の身長データが入ります
matrix(550,12) lln

' mean には 10, 50, 100, ..., 550 人の身長データの平均が入ります
matrix(12,2) mean

' 乱数発生キーを 12 にします。
rndseed 12
```

¹ランダムサンプリングは容易ではありません。

550 人分の身長データを x として一括作成します

```
series x=145+10*nrnd
```

x の先頭から 10 行目までのデータを lln の 1 列目にコピーします

```
for !i=1 to 10
  lln(!i,1)=x(!i)
next
```

1 列目の 11 行目から 550 行目まで NA(欠損値) を入力します。

これを入力しないと最後のグラフ化がきれいにできません

```
for !i=11 to 550
  lln(!i,1)=na
next
```

先頭から 50, 100, ..., 550 行までのデータを lln の 2 列目から 12 列目まで x の値をコピーし、その下に NA を入力します

```
for !k=2 to 12
  for !i2=1 to 50*(!k-1)
    lln(!i2,!k)=x(!i2)
  next
  for !i2=50*(!k-1)+1 to 550
    lln(!i2,!k)=na
  next
next
```

lln において、標本数が 10, 50, 100, ..., 550 となっている各列のヒストグラムを作成します

標本数が増えるにしたがって、棒の数が増えます。

プログラムの先頭からここまでの狙いは、標本数が徐々に増えていく処理を行う事です

まだ、大数の法則のシミュレーションではありません

```
lln.distplot hist theory(dist=normal)
```

それぞれのヒストグラムに対応する平均値 (推定値) \bar{X} を求めます

最初に先頭 10 人分の平均値を求め、行列 $mean$ の 1 行 2 列目にコピーします

```
smpl 1 10
mean(1,1)=10
mean(1,2)=@mean(x)
```

同じ処理を 50, 100, ..., 550 人で行います。

```
for !j=2 to 12
  !end=50*(!j-1)
  smpl 1 !end
  mean(!j,1)!=end
```

```
mean(!j,2)=@mean(x)
next
```

- ’ 求めた 12 個の標本平均の値をグラフ化します。
- ’ 標本数が増えるにしたがって、徐々に $\mu (= 145)$ に近づいていますか？
- ’ このところが、大数の法則の視覚化です

```
mean.xyline(o=reverse)
smp1 @all
```




図 1.12 個の \bar{X} のグラフ. 横軸は標本数

標本数が増えるごとに \bar{X} が 145 に近づく様子が見てとれます。標本数が 10 の時の平均は 142.5 より若干小さい程度になっていますが、この値を生成しているのは、行列オブジェクト LLN の左上のグラフです。

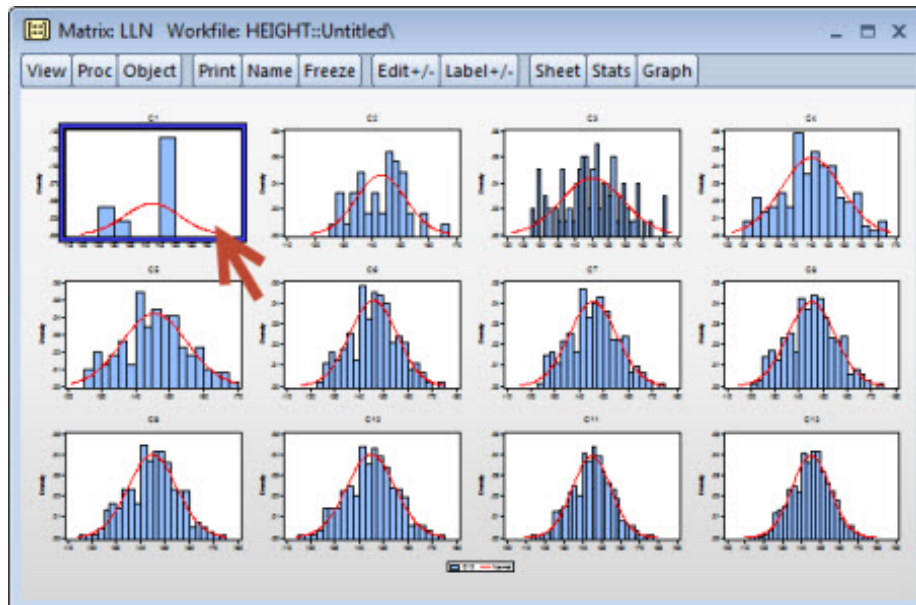


図 2.10, ..., 550 個の標本によるヒストグラム

12 個のグラフを左上から、右下に向かって 1 行ごとに眺めていくと、標本数が増え、ヒストグラムの形状が分布曲線に近くなり、ヒストグラムの平均値が母平均に近くなっています。最後に EViews の機能の一つをご紹介します。行列オブジェクトによる図 2 のグラフや、一般的なグループオブジェクトで同様のグラフを作成すると、グラフの個数が多すぎて、個々のグラフが非常に小さくなってしまふ場合があります。そのような場合は、図 2 で目的のグラフをクリックし、サブメニューから Extract selected graph コマンドを実行します。

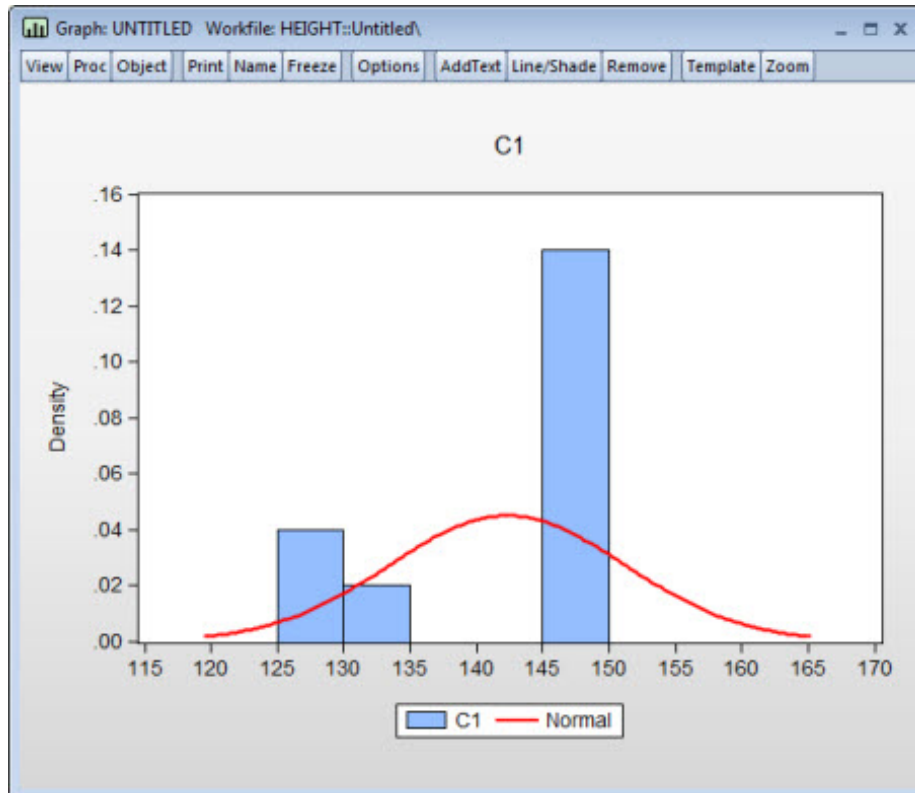


図 3.Extract selected graph コマンドで取り出したグラフ

このコマンドを利用すると、目的のグラフだけを単独の Graph オブジェクトとして取り出すことができます。

前回まで、賃金や株価など観測したデータについての分布についてモーメントという角度から、EViews を利用して学んできました。お話を確率分布の一つである t 分布に進める前に、今回は平均値（一次のモーメント）について、非常に重要な特徴を解説しました。「データの分布」から「推定値の分布」にトピックを移していきます。

次回は平均値（推定値）の分布に関する中心極限定理について、やはり EViews のプログラミング機能を活用して、ご解説したいと思います。

参考文献：東京大学教養学部統計学教室 編 「統計学入門」 東京大学出版会