

(1)

## コインとサイコロ，そして，大数の法則

コインを投げて，表の出る比率を考える．

... 経験から，まずは，想像して下さい ...

期待値「0.5」に対して，実現値はサマザマ，...

例えば，10回中3回表がでた場合，

... 表の出る比率（実現値）は， $3/10 = 0.3$


つまり，ある実現値は，1つの標本値であり，確率変数である．

具体的に実験してみよう．

ここでは，モンテカルロシミュレーションを行う．

（コンピュータにコインを投げさせる = 確率変動をコントロールできる．

実際に，人間がコインを投げる場合との違いを考えよ．）

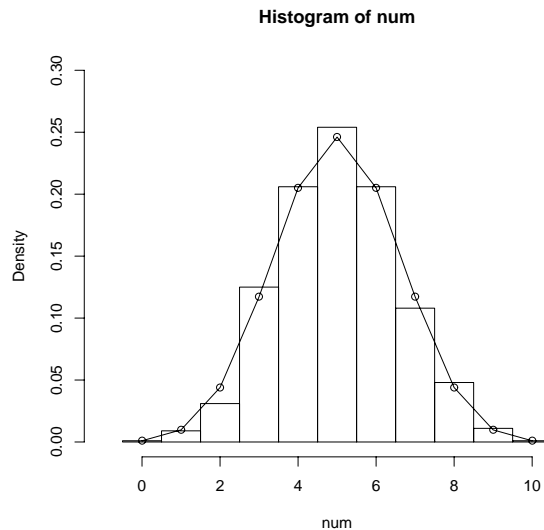



(2)

```
> # coin
> sample(c("omote","ura"), 1)
[1] "omote"
> sample(c("omote","ura"), 5, replace=TRUE)
[1] "omote" "ura"   "ura"   "omote" "ura"
>
> rbinom(1, size=1, prob=1/2) # 1 stands for "omote"; 0 for "ura".
[1] 0
> rbinom(5, size=1, prob=1/2)
[1] 1 0 1 0 0
> sum(rbinom(5, size=1, prob=1/2))
[1] 2
> rbinom(1, size=5, prob=1/2)
[1] 3
>
> rbinom(20, size=5, prob=1/2)
[1] 3 4 3 3 4 3 3 2 1 2 3 3 4 2 2 4 2 2 3 4
> dbinom(0:10, size=10, prob=1/2)
[1] 0.0009765625 0.0097656250 0.0439453125 0.1171875000 0.2050781250
[6] 0.2460937500 0.2050781250 0.1171875000 0.0439453125 0.0097656250
[11] 0.0009765625
```




コインのオモテの数は  
2項分布でモデル化できる

(3)



```
> table(num <- rbinom(1000, size=10, prob=1/2))
 0  1  2  3  4  5  6  7  8  9 10
 1  9 31 125 206 254 206 108 48 11 1
> hist(num)
> hist(num, breaks=0:11-.5, prob=TRUE, xlim=c(-1,11), ylim=c(0,.3))
> lines(0:10, dbinom(0:10, size=10, prob=1/2), type="o") # cf. Fig. 8.1
```

(4)



```
> par(mfrow=c(3,1))  
> hist(rbinom(1000, size=10, prob=1/2)/10, xlim=c(0,1))  
> hist(rbinom(1000, size=30, prob=1/2)/30, xlim=c(0,1))  
> hist(rbinom(1000, size=100, prob=1/2)/100, xlim=c(0,1))
```

(5)

**大数の法則** : (テキスト , p.157 の式(8.5) および p.160 の下段 )  
任意の大きさの  $\varepsilon$  に対して , 十分に大きな  $n$  をとれば ,  
平均値  $\bar{X}_n (= n^{-1} \sum_{i=1}^n X_i)$  は , 以下の関係を満足する .

$$\text{Prob.}(|\bar{X}_n - \mu| < \varepsilon) \rightarrow 1$$

大数の法則は , 以下の事項に基づく .

ある分布 ( 平均 =  $\mu$  , 分散 =  $\sigma^2$  ) から抽出された標本 ( サイズ  $n$  )  
の標本平均  $\bar{X}$  について , 以下が成立する .


$$E(\bar{X}_n) = \mu; \quad V(\bar{X}_n) = \frac{\sigma^2}{n}$$

大数の法則は , さらに精密化できる ( 中心極限定理 ) .


(6)



試行回数の増加とともに，母比率に近付く様子（テキスト p.158）




```
> par(mfrow=c(1,1))
> rat <- numeric(0)
> for (trial in seq(100, 20000, by=100)) {
+   rat <- c(rat, rbinom(1, size=trial, prob=0.4)/trial)}
> plot(seq(100, 20000, by=100), rat, type="l")
> abline(h=0.4, col="red") # cf. Fig. 8.2 ~ 8.5
```



次に、「サイコロの目の和」について、考える。

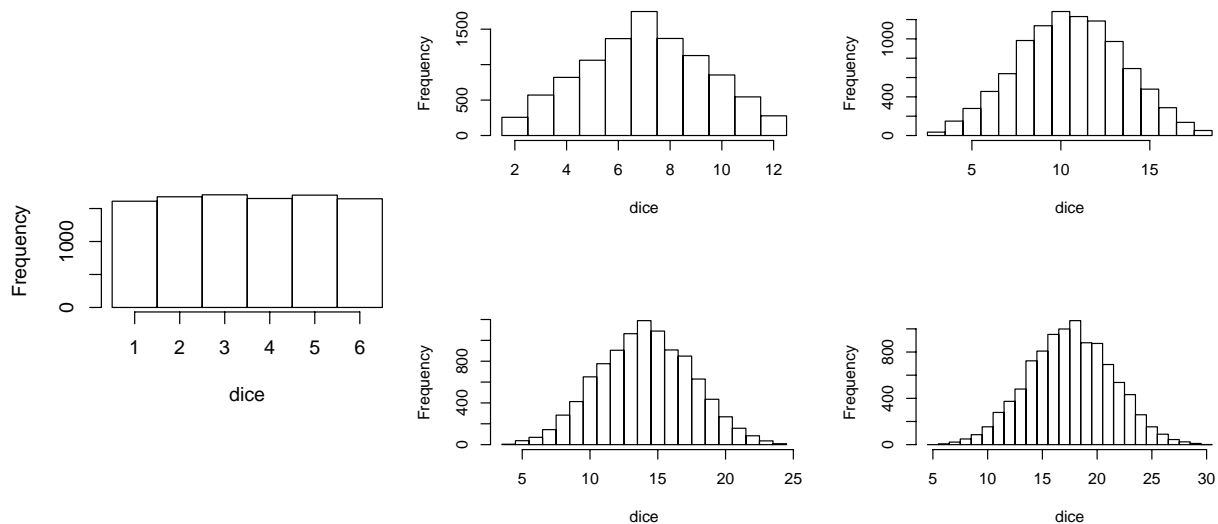
1コ： = 1

2コ： +  = 8

3コ： +  +  = 12

(8)

```
> par(mfrow=c(2,2))  
> hist(dice <- dice + sample(1:6, 10000, replace=T), breaks=1:12+.5)  
> hist(dice <- dice + sample(1:6, 10000, replace=T), breaks=2:18+.5)  
> hist(dice <- dice + sample(1:6, 10000, replace=T), breaks=3:24+.5)  
> hist(dice <- dice + sample(1:6, 10000, replace=T), breaks=4:30+.5)  
> # cf. Fig. 8.7 ~ 8.10
```





(9)

**中心極限定理** : (テキスト , p.162 の式(8.6) および p.164, 165 も見よ)

総和  $S_n (= \sum_{i=1 \sim n} X_i)$  に対して ,  $S_n \sim N(n\mu, n\sigma^2)$

平均  $\bar{X}_n (= S_n/n = n^{-1} \sum_{i=1 \sim n} X_i)$  に対して ,  $\bar{X}_n \sim N(\mu, \sigma^2/n)$

として , **正規分布** に従うことである .

中心極限定理は , 略して , CLT ( Central Limit Theorem ) と呼ばれる .  
中心極限定理を大数の法則と対比して , 表現すれば ,

$$\text{Prob.}(|\bar{X}_n - \mu| < 1.96 \sigma \sqrt{n}) = 0.95$$

となる . つまり , 大数の法則では , “ 記号で表現 ” されていた箇所が ,  
“ 値として具体的に ” 示されている ( それは , 精密化されたから ) .

cf. 大数の法則 ( 再表示 ) :

$$\text{Prob.}(|\bar{X}_n - \mu| < \varepsilon) \rightarrow 1$$

中心極限定理の式表現は，サマザマに可能である．

$$1) \text{ Prob.} \left( \left| \frac{\bar{X}_n - \mu}{\sigma / \sqrt{n}} \right| < 1.96 \right) = 0.95$$

$$2) \text{ Prob.} \left( \frac{\bar{X}_n - \mu}{\sigma / \sqrt{n}} < -1.96 \text{ or } 1.96 < \frac{\bar{X}_n - \mu}{\sigma / \sqrt{n}} \right) = 0.05$$

$$3) \text{ Prob.} \left( 2.33 < \frac{\bar{X}_n - \mu}{\sigma / \sqrt{n}} \right) = 0.01$$

$$4) \text{ Prob.} \left( a < \frac{\bar{X}_n - \mu}{\sigma / \sqrt{n}} < b \right) \rightarrow \frac{1}{\sqrt{2\pi}} \int_a^b \exp(-x^2/2) dx$$





...

つまり，統計量のとらうる範囲を指定すれば，正規分布により，その確率を算定できる．

## 中心極限定理の応用 ( 1 ): 2 項分布の正規近似 ( コインの問題 , 再び )

```
> hist((rbinom(10000, size= 5, prob=0.1) - 5*0.1)/sqrt( 5*0.1*(1-0.1)))
> hist((rbinom(10000, size= 50, prob=0.1) - 50*0.1)/sqrt( 50*0.1*(1-0.1)))
> hist((rbinom(10000, size=100, prob=0.1) - 100*0.1)/sqrt(100*0.1*(1-0.1)))
> hist((rbinom(10000, size=500, prob=0.1) - 500*0.1)/sqrt(500*0.1*(1-0.1)))
> # Fig. 8.11 ~ 8.16
```

```
>
```



```
> pbinom(60, size=500, prob=0.1)
[1] 0.9381745
> pnorm(60, mean=50, sd=sqrt(500*0.1*(1-0.1)))
[1] 0.9319814
```

注：図の縦軸や図中の正規分布などを描画するには、追加コマンドが必要。

## 2 項分布の正規分布による近似：

2 項分布に従う標本  $X_i$  の総和  $S_n = X_1 + X_2 + \dots + X_i + \dots + X_n$  について，その平均および分散は， $E(S_n) = np$ ； $V(S_n) = np(1-p)$  である（成功率 =  $p$ ）。例えば，成功率 0.5 として，100 回の試行による成功回数が 40 回以上 60 回以下となる確率は，厳密には，

```
> pbinom(60,      size=100, prob=.5) -
+ pbinom(40 -1, size=100, prob=.5)
[1] 0.9647998
```


となるのに対し，以下のように，正規分布を用いて近似できるわけである．

```
> pnorm(60, m=.5*100, sd=sqrt(.5*(1-.5)*100)) -
+ pnorm(40, m=.5*100, sd=sqrt(.5*(1-.5)*100))
[1] 0.9544997
```

注意！！ 成功率  $p$ （場合によっては，失敗率）が 0.5 付近で近似の度合いは良好．しかし，成功率  $p$  が，ゼロあるいは 1 付近では，近似の度合いは悪し！この場合には，2 項分布はポアソン分布により近似する（小数の法則；テキスト p.114 を見よ）．


## 中心極限定理の応用 ( 2 ): 一様乱数から正規乱数を作る

```
> par(mfrow=c(1,1))
> val <- rep(-6, 250)
> for (h in 1:12) val <- val + runif(250)
> hist(val, prob=TRUE)
> curve(dnorm, -3,3, col="red", add=TRUE)
>
```



## ランダム・ウォーク (酔歩): テキストの練習問題 8.2




```
> walk <- (rbinom(100, size=1, prob=0.4) - 1/2)*2
> walk[1:10]
[1] 1 1 -1 1 -1 -1 1 1 1 1
> plot(1:100, cumsum(walk), type="S", ylim=c(-20,20))
> lines(1:100, cumsum((rbinom(100, size=1, prob=0.4) - 1/2)*2), type="S", lty=2)
> ...
```



```
> # for advanced use
> rwalk <- function() lines(1:100, cumsum((rbinom(100, size=1, prob=0.4) - 1/2)*2), type="S")
> rwalk()
```





余談：総和あるいは平均という操作に，中心極限定理（CLT）が適用される

```
> hist(rexp(10000), prob=TRUE)
> me <- numeric(10000)
> for (j in 1:10000) me[j] <- mean(rexp(3))
> hist(me, prob=TRUE)
> for (j in 1:10000) me[j] <- mean(rexp(10))
> hist(me, prob=TRUE)
> for (j in 1:10000) me[j] <- mean(rexp(30))
> hist(me, prob=TRUE)
```



余談 ( 続き ) : 最大値という操作には , CLT が適用されない . 別の定理が成立する .

```
> hist(rexp(10000), prob=TRUE)
> ma <- numeric(10000)
> for (j in 1:10000) ma[j] <- max(rexp(3))
> hist(ma, prob=TRUE)
> for (j in 1:10000) ma[j] <- max(rexp(10))
> hist(ma, prob=TRUE)
> for (j in 1:10000) ma[j] <- max(rexp(30))
> hist(ma, prob=TRUE)
```



注 : 正規分布として近似した赤線は , シミュレーション結果と異なる ( 青線は極値分布 ) .