

# TILASTOLLISET MENETELMÄT TÄHTITIETEESSÄ

## IDL-harjoitus 3, Heikki Salo 27.3.2008

---

1. Luennolla on esitetty yhtälö ('error propagation equation'), jonka avulla voidaan arvioida satunnaissuureista johdettujen suureiden varianssia. Oletetaan, että satumaismuuttujat  $X$  ja  $Y$  noudattavat jakaumia, joilla on varianssit  $\sigma_x^2$  ja  $\sigma_y^2$ . Mikäli  $x$  ja  $y$  ovat riippumattomia, niin silloin funktion  $f = f(x, y)$  varianssia voidaan approksimoida

$$\sigma_f^2 = \left( \frac{\partial f}{\partial x} \right)^2 \sigma_x^2 + \left( \frac{\partial f}{\partial y} \right)^2 \sigma_y^2$$

Tutkitaan miten hyvin tämä approksimaatio päätee funktioille  $f(x, y) = xy$  ja  $f(x, y) = x/y$ .

Käytännössä: valitse esim.  $\bar{x} = \bar{y} = 1$ , ja  $\sigma_x = \sigma_y$ , ja tutki erilaisia suhteita  $\sigma_x/\bar{x} = 0, \dots, 0.8$ , käyttäen sekä Gaussista että tasaista jakaumaa  $x$ :lle ja  $y$ :lle.

---

Esim  $f(x, y) = xy \Rightarrow \frac{\partial f}{\partial x} = y$  ja  $\frac{\partial f}{\partial y} = x$

Siten  $\sigma_f^2 = y^2 \sigma_x^2 + x^2 \sigma_y^2 \Rightarrow (\sigma_f/f)^2 = (\sigma_x/x)^2 + (\sigma_y/y)^2$

Oletetaan  $x$  ja  $y$  noudattaa Gaussista jakaumaa ja luodaan satunnaisotokset  $X_i$  ja  $Y_i$ . Tarkistetaan etta eo. approksimaatio patee kun hajonnat pienia. Osittaisderivaatat lasketaan keskiarvojen  $y = \bar{y}$  ja  $x = \bar{x}$  kohdalla.

```
x=1.+ randomn(seed,10000)*.1  
y=2. + randomn(seed,10000)*.05  
z=x*y
```

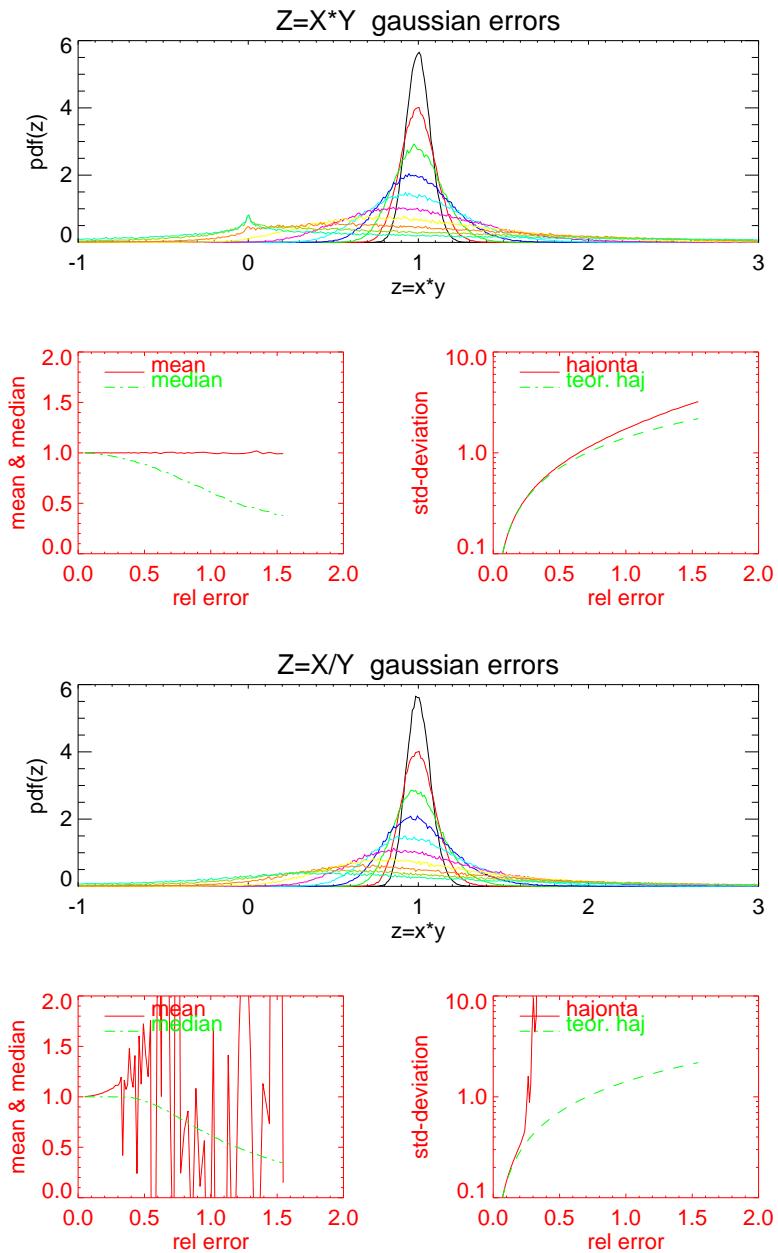
```
IDL> print,stdev(z)/mean(z)  
0.141812  
IDL> print,sqrt((stdev(x)/mean(x))^2+(stdev(y)/mean(y))^2)  
0.140881
```

Entä kun virheet (hajonnat) ovat isommat? Esim. 50%:

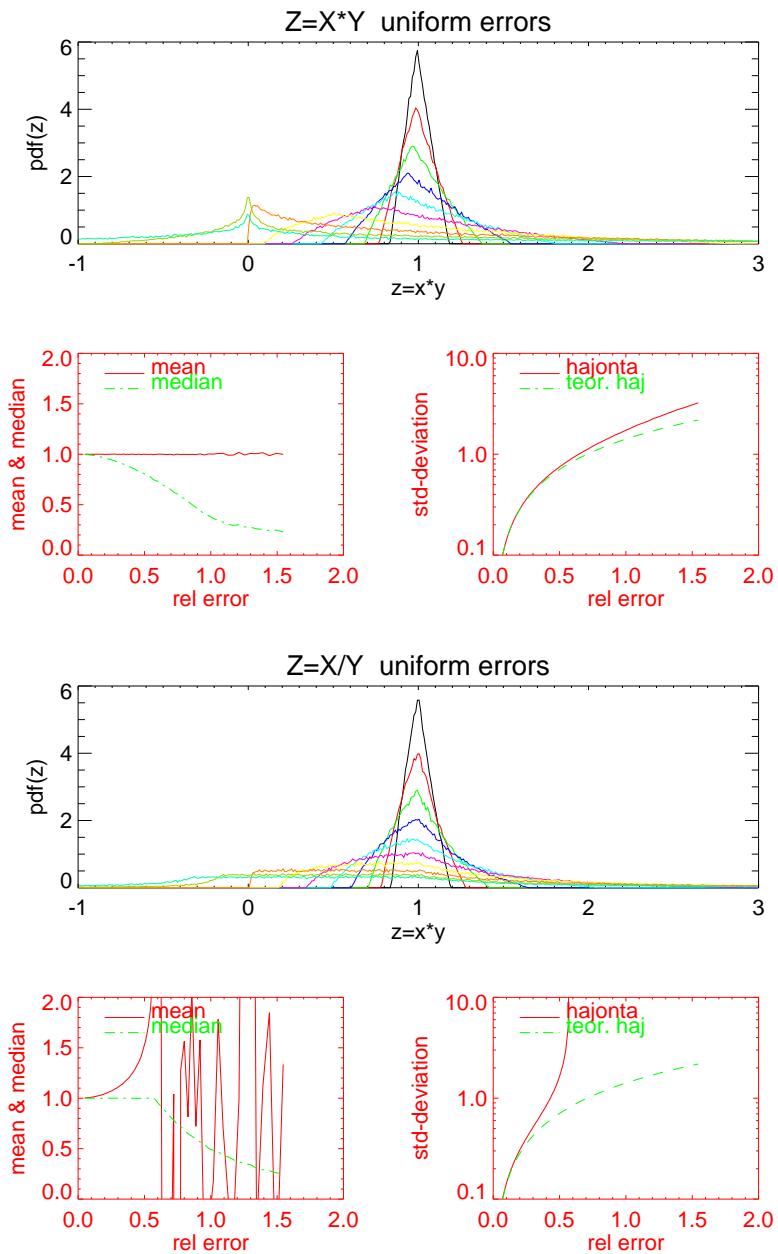
```
y=2. + randomn(seed,10000)*1.  
x=1.+ randomn(seed,10000)*.5  
z=x*y  
IDL> print,stdev(z)/mean(z)  
0.742651  
IDL> print,sqrt((stdev(x)/mean(x))^2+(stdev(y)/mean(y))^2)  
0.702376
```

Edellä olevan perusteella aproksimaatio pätee aika suurillekin virheille.

Esimerkki-ohjelma `idlharj3_error_propagation.pro` tutkii tulon  $xy$  ja osamäärään  $x/y$  virheiden käyttäytymistä, kun suureiden  $x$  ja  $y$  suhteellinen virhe on 0.05 - 1.54 (100 logaritmista valittua arvoa). Hajonnan ja kesiarvon lisäksi se tulostaa myös suureiden jakaumat



Kuten edellä, paitsi että x ja y tasaisesti jakautuneet.



```

;-----
;----- program0='idlharj3_error_propagation' & ps=-1
;----- mu_x=1.d0 & mu_y=1.d0
;----- reltab=0.05*2^(findgen(100)/20.)

for icase=1,4 do begin
  if(icase eq 1) then title='Z=X*Y gaussian errors'
  if(icase eq 2) then title='Z=X/Y gaussian errors'
  if(icase eq 3) then title='Z=X*Y uniform errors'
  if(icase eq 4) then title='Z=X/Y uniform errors'
  if(icase eq 1) then program=program0+'_a'
  if(icase eq 2) then program=program0+'_b'
  if(icase eq 3) then program=program0+'_c'
  if(icase eq 4) then program=program0+'_d'

psdirect,program,ps,color=1
nwin & !p.multi=[0,1,2]
meantab=reltab*0. & medtab=reltab*0. & sttab=reltab*0.

for i=0,n_elements(reltab)-1 do begin
  relx=reltab(i)
  sigma_x=mu_x*relx
  rely=relx
  sigma_y=mu_y*rely

N=1000001
if(icase eq 1 or icase eq 2) then begin
  x=randomn(seed,n)*sigma_x+mu_x
  y=randomn(seed,n)*sigma_y+mu_y
endif
if(icase eq 3 or icase eq 4) then begin
  x=(randomu(seed,n)-0.5)*sqrt(12.)*sigma_x+mu_x
  y=(randomu(seed,n)-0.5)*sqrt(12.)*sigma_y+mu_y
endif
if(icase eq 1 or icase eq 3) then z=x*y
if(icase eq 2 or icase eq 4) then z=x/y

meantab(i)=mean(z)
medtab(i)=median(z)
sttab(i)=stdev(z)

if(i mod 10 eq 0) then begin
  histo_f,z,-1,3,.01,xx,yy
  if(i eq 0) then plot,xx,yy,yr=[0,6],xtitle='z=x*y',ytitle='pdf(z)',title=title
  if(i ne 0) then oplot,xx,yy,col=i*.1+1
endif
endfor

!p.multi=[2,2,2]
plot,reltab,meantab,yr=[0,2],xtitle='rel error',ytitle='mean & median',col=2
oplot,reltab,medtab,lines=3,col=3
label_data,0.1,0.9,['mean','median'],lines=[0,3],col=[2,3]

plot,reltab,sttab,/ylog,yr=[0.1,10],xtitle='rel error',ytitle='std-deviation',col=2
oplot,reltab,reltab*sqrt(2),lines=2,col=3
label_data,0.1,0.9,['hajonta','teor. haj'],lines=[0,3],col=[2,3]

psdirect,program,ps,color=1,/stop
endfor
end

```

2. Tutkitaan 'poikkeavien havaintojen' (outlier) vaikutusta jakauman leveyden arvioinnissa eri tilastollisia tunnuslukuja käytettäessä. Mikä seuraavista tunnusluvuista on 'vakain' mittaa jakauman leveydelle (most robust), eli vähiten riippuvainen poikkeavista arvoista?

i) Neliöllisen poikkeaman keskiarvo

$$RMS = \sqrt{\frac{\sum(X - \bar{X})^2}{N}}$$

ii) keskipoikkeama

$$\Delta\bar{X} = \sqrt{\frac{\sum |X - \bar{X}|}{N}}$$

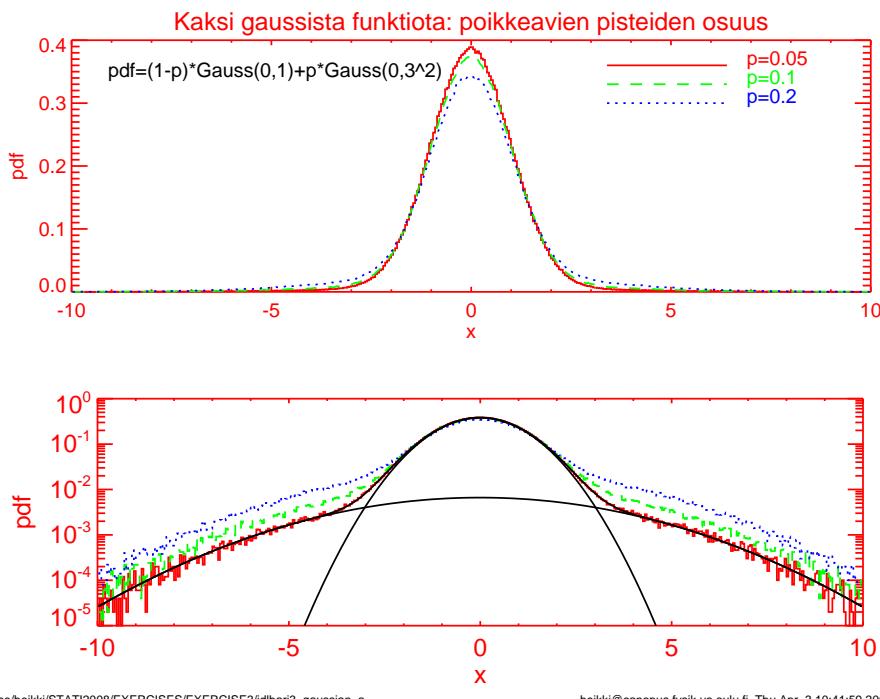
iii) keskimmäiset 50% arvoista sisältävän välin leveys  $c_{50}$

Luodaan outlier-havaintoja sisältävä satunnaisjakauma summaamalla kaksi Gaussista tiheysjakaumaa:

$$f(x) = (1-p)f_G(\mu, \sigma) + p f_G(\mu, 3\sigma)$$

Jakaumilla sama  $\mu$  mutta hajonnat poikkeavat tekijällä 3. Parametri  $p \ll 1$  mittaa poikkeavien havaintojen osuutta.

a) Plottaa eo. jakauma eri  $p$ :n arvoilla. Millainen koordinaatisto havainnollistaa parhaiten poikkeavia pisteitä (jakauman häntiä)?

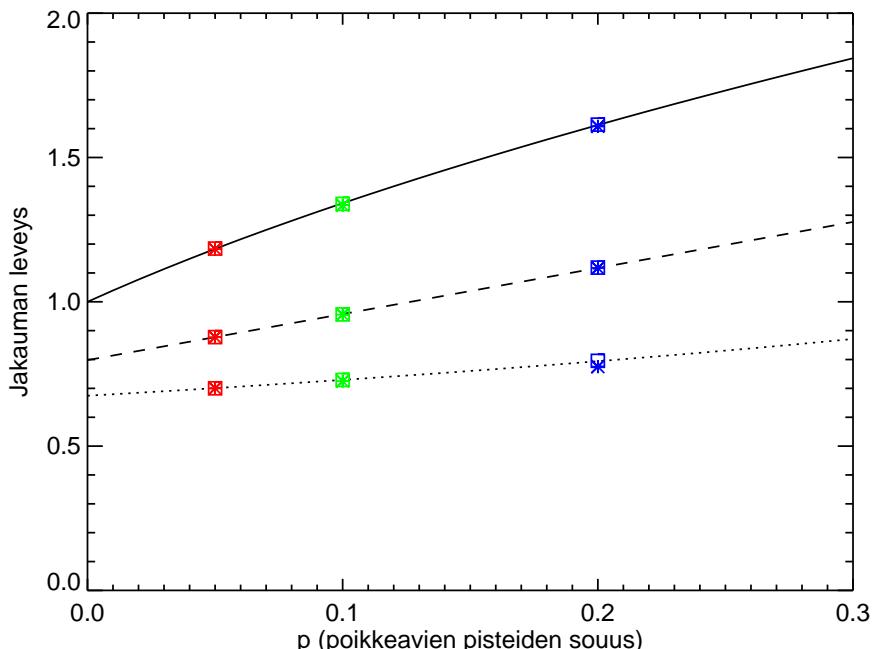


/home/heikki/STATI2008/EXERCISES/EXERCISE3/idharj3\_gaussian\_a heikki@canopus.fysik.yo.oulu.fi Thu Apr 3 10:41:59 2008

b) Totea RMS-poikkeaman riippuvuus  $p$ :stä, luomalla eo. jakauman mukaisia satunnaislukuja, ja laskemalla otoksiens RMS. (teoreettinen tulos  $RMS = \sigma \sqrt{1 + 8p}$ )

c) Toista sama käyttäen keskipoikkeamia. (teoreettinen tulos  $\bar{\Delta X} = \sqrt{2/\pi}(1 + 2p)$ )

d) Ja käyttäen keskimmäästä 50% pisteistä (teoreettinen ratkaisu saadaan numeerisesti yhtälöstä  $(1 - p)2\Phi(C_{50}) + p2\Phi(C_{50}/3) - 0.5 = 0$ , joka voidaan ratkaista esim. Newtonin iteratiomenetelmällä.



/home/heikki/STATI2008/EXERCISES/EXERCISE3/idlharj3\_gaussian\_b heikki@canopus.fysik.yo.oulu.fi Thu Apr 3 10:42:01 2008

```
;-----
;idlharj3_gaussian.pro
;Poikkeavien havaintojen vaikutus (2005/3.3.2008)
;-----

;-----
;aliohjelma jota käytetään c50-laskemiseen (inner quartile)
;-----
function newton_c50, c50

;p:n arvo tuodaan aliohjelman common-lauseen kautta
 common newton_c50_common,pcom
 p=pcom

;seuraavat lausekkeet antavat saman tuloksen
;1) using IDL cumulative function of normalized gaussian
 func=(1.-p)*(gauss_pdf(c50)-gauss_pdf(-c50))+$ 
      p*(gauss_pdf(c50/3.)-gauss_pdf(-c50/3.))$ 
      -0.5
```

```

;2) error-funktion avolla
func=(1-p)*erf(c50/sqrt(2.))+$ 
    p*erf(c50/sqrt(2.)/3.)$ 
    -0.5
return,func
end

;-----
;paaohjelma
;-----
common newton_c50_common,pcom

program='idlharj3_gaussian'
ps=0

;Havainnollista poikkeavien pisteen vaikutus
;tutkimalla jakaumaa joka on kahden Gaussian funktion summa
;hajonnat sigma=1 ja sigma=3
;(varianssit sigma^2=1 ja 9)
;sigma=3 jakauman osuuus (=poikkeavat pistleet) maaratyy parametrista p
; g1=1./sqrt(2*pi)*exp(-0.5*x^2)
; g2=1./sqrt(2*pi)/3.*exp(-0.5*x^2/3.^2)
; g=(1-p)*g1 + p*g2

;-----
;a) Luodaan jakaumat ja plotataan histogrammeina
;-----
psdirect,program+'_a',ps,/color
!p.multi=[0,1,2]
nwin

;-----
;ensin p=0.05

N=10000001           ; number of points
p=0.05
N1=(1.-p)*N
N2=p*N
X1=[randomn(seed,N1),3*randomn(seed,N2)] 

;plot results with histo_f procedure:
; x1=minimum of tabulation
; x2=maximum of tabulation
; dx=binsize of tabulation
; xbin = centers of bins
; ybin = number of points in the bin
; /noscale keyword ->
;         histo_f returns yt =ybin
;         probability density pdf = yt/(dx*N)

xmin=-10.
xmax= 10.
dx=0.05
histo_f,X1,xmin,xmax,dx,xt1,yt1,/noscale
pdf1=1.*yt1/(n_elements(x1)*dx)
plot,xt1, pdf1,psym=10,xtitle='x',ytitle='pdf',col=2,$
      title='Kaksi gaussista funktioita: poikkeavien pisteen osuuus',chars=0.8

;-----
; samalla tavalla p=0.1 and p=0.2

p=0.10

```

```

N1=(1.-p)*N
N2=p*N
X2=[randomn(seed,N1),3*randomn(seed,N2)]
histo_f,X2,xmin,xmax,dx,xt2,yt2,/noscale
pdf2=1.*yt2/(n_elements(x2)*dx)
oplot,xt2, pdf2,col=3,lines=2

p=0.20
N1=(1.-p)*N
N2=p*N
X3=[randomn(seed,N1),3*randomn(seed,N2)]
histo_f,X3,xmin,xmax,dx,xt3,yt3,/noscale
pdf3=1.*yt3/(n_elements(x3)*dx)
oplot,xt3, pdf3,col=4,lines=1

xyouts,0.15,.9,'pdf=(1-p)*Gauss(0,1)+p*Gauss(0,3^2)',/normal,chars=.8
label_data,0.67,.9,['p=0.05','p=0.1','p=0.2'],lines=[0,2,1],col=[2,3,4],size=.8

;-----
;plotataan sama logaritmisessa y-skaalassa
;+ teoreettinen jakauma p=0.05
nwIn
plot,xt1, pdf1,psym=10,/ylog,yr=[1d-5,1],col=2,xtitle='x',ytitle='pdf'
oplot,xt2, pdf2,psym=10,col=3,lines=2
oplot,xt3, pdf3,psym=10,col=4,lines=1

;teoreettinenp=0.05
xarg=xt1
p=0.05
g1=1./sqrt(2*!pi)*exp(-0.5*xarg^2)
g2=1./sqrt(2*!pi)/3.*exp(-0.5*xarg^2/3.^2)
oplot,xarg,(1.-p)*g1
oplot,xarg,p*g2
oplot,xarg,(1.-p)*g1+p*g2,lines=0

!p.multi=0
psdirect,program+'_a',ps,/stop

;-----
;b,c,d)
;Verrataan miten erilaiset jakauman leveyden mitat
; RMS
; keskipoikkeama
; keskimmaiset 50% (C50 inner quartile width)
; riippuvat poikkeavien pisteen maaasta
;-----
psdirect,program+'_b',ps,/col

;-----
;Analyyttiset lausekkeet arvoille p 0 - 0.3
;-----
parg=findgen(31)*.01

;root-mean-square: integral of x^2g(x)
RMS=sqrt((1.-parg)+parg*3.^2)

;mean (absolute) deviation: integral of abs(x)g(x)
MAD=2./sqrt(2.*!pi)*((1.-parg)*1. +parg/3.*9.)

;interquartile width c50: integral from -c50 to c50 g(x) equals 0.5
;need to solve numerically (G is the cumulative distribution of gaussian)

```

```

; (1-p)*(G1(c50)-G1(-c50))+p*(G2(c50)-G2(-c50))=0.5

;use Newton's method to find the root of
; f(c50;p)=(1-p)*(G1(c50)-G1(-c50))+p*(G2(c50)-G2(-c50))-0.5
;this function f(c50;p) is returned by
;the function-procedure newton_c50(c50)
; p is passed to the function via a common block

c50=parg*0
for i=0,n_elements(parg)-1 do begin
  pcom=parg(i) ;passed via common to newton_c50
  p_ini=0. ;initial guess for iteration
  c50(i)=newton(p_ini,'newton_c50')
endfor

nwin
plot,parg,rms,lines=0,xtitle='p (poikkeavien pisteen souus)',ytitle='Jakauman leveys'
oplot,parg,mad,lines=2
oplot,parg,c50,lines=1

;-----
;Numeerisesti luotujen jakaumien avulla
;-----;
;for p=0.05,0.1,0.2

for ip=1,3 do begin
  if(ip eq 1) then begin
    p=0.05
    pdf=pdf1
    x=x1
    xt=xt1
  endif
  if(ip eq 2) then begin
    p=0.1
    pdf=pdf2
    x=x2
    xt=xt2
  endif
  if(ip eq 3) then begin
    p=0.2
    pdf=pdf3
    x=x3
    xt=xt3
  endif
end

;Luodun otoksen perusteella:
rms=sqrt(mean(x^2))
mad=mean(abs(x))
x=x(sort(x))
c50=0.5*(x(N*0.75)-x(N*0.25))

plots,[p,rms],psym=6,col=ip+1
plots,[p,mad],psym=6,col=ip+1
plots,[p,c50],psym=6,col=ip+1

;taulukoidun tiheysfunktion avulla

rms=sqrt(mean(xt^2*pdf)/mean(pdf))
mad=mean(abs(xt)*pdf)/mean(pdf)
sum=pdf*0.
for ii=1,n_elements(xt)-1 do begin

```

```

        sum(ii)=sum(ii-1)+pdf(ii)*dx
    endfor

    ind=where(sum gt 0.25)
    ind25=ind(0)
;0.25 attained between xt(ind25) and xt(ind25-1)
;weighted mean
    c50m=(sum(ind25-1)*xt(ind25)+sum(ind25)*xt(ind25-1))/$
           (sum(ind25)+sum(ind25-1))+0.5*dx

    ind=where(sum gt 0.75)
    ind75=ind(0)
;0.75 attained between xt(ind75) and xt(ind75-1)
;weighted mean
    c50p=(sum(ind75-1)*xt(ind75)+sum(ind75)*xt(ind75-1))/$
           (sum(ind75)+sum(ind75-1))+0.5*dx

    print,c50m,c50p
    c50=(c50p-c50m)/2.
    plots,[p,rms],psym=2,col=ip+1
    plots,[p,mad],psym=2,col=ip+1
    plots,[p,c50],psym=2,col=ip+1

endfor

label_data,0.1,.9,['RMS','MD','C50'],lines=[0,2,1]

psdirect,program+'_b',ps,/stop

end

```

---

3. Luo Poisson tiheysjakaumaa noudattavia satunnaismuuttujia, siten että teoreettinen keskiarvo  $\mu = 9$  ja  $\mu = 81$ . Tutki  $N_{sample} = 10$  ja  $N_{sample} = 100$  luvun muodostamien otoskien keskiarvoa  $\bar{X}$  ja otoshajontaa  $\sigma_s$ .

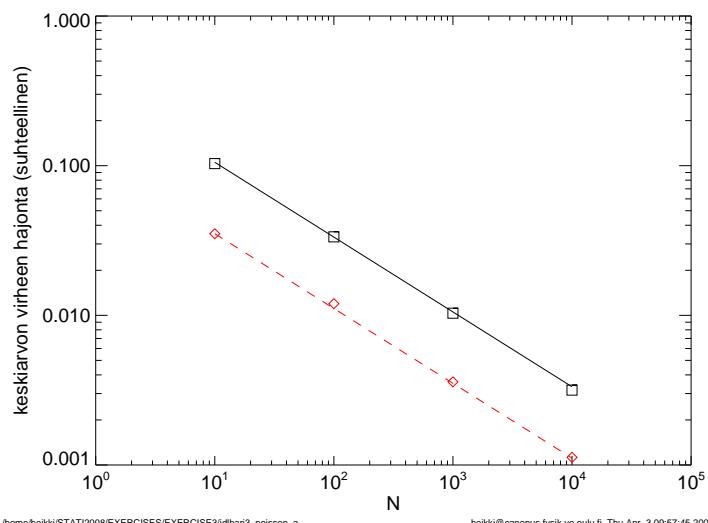
a) Totea, että otoskeskiarvo  $\bar{X}$  approksimoi jakauman keskiarvoa  $\mu$ , ja että  $\bar{X}$ :n hajonta on yhtäpitävä teoreettisen arvon  $\sigma_{\bar{X}} = \sigma / \sqrt{N_{sample}}$  kanssa, jossa  $\sigma = \sqrt{\mu}$  on perusjakauman hajonta. Suhteellinen virhe

$$\frac{\sigma_{\bar{X}}}{\mu} = \frac{1}{\sqrt{\mu N_{sample}}}$$


---

```
IDL> x=randomu(seed,10000,poisson=10)
IDL> print,mean(x),10.
      9.97360      10.0000
IDL> print,stdev(x),sqrt(10)
      3.17100      3.16228
IDL> print,sqrt(mean(x)),sqrt(10)
      3.15987      3.16228
```

Tutkitaan otoskeskiarvon suhteellista virhetta eri  $N$  arvoilla (**idlharj3\_poisson.pro**). Käytetään kuten pitaakin: Suhteellinen virhe verrannollinen  $1/\sqrt{N}$  ja  $1/\sqrt{\mu}$ . Kuvassa neliot  $\mu=9$ , vinoneliot  $\mu=81$ ; jalkimaisessa tapauksessa virhe 3 kertaa pienempi.

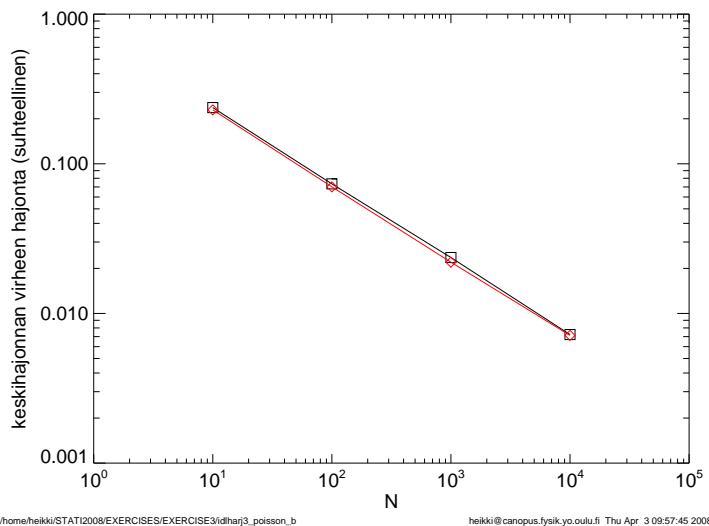


b) Miten hyvin otoshajonta

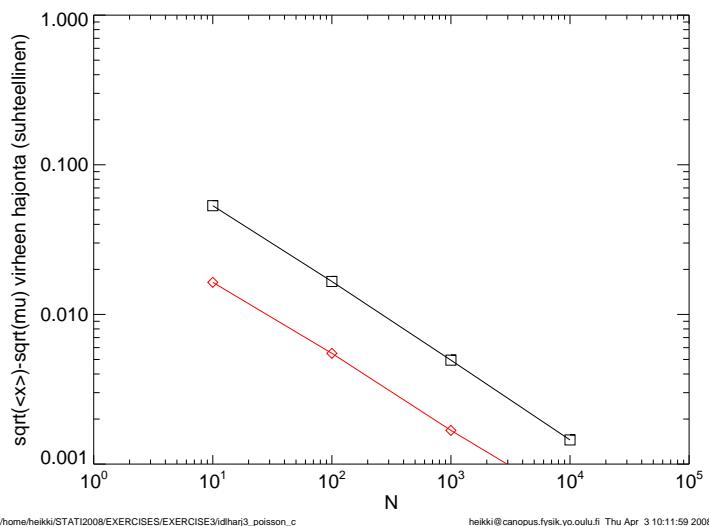
$$\sigma_s = \sqrt{\frac{\sum(X - \bar{X})^2}{N - 1}}$$

ja otoskeskiarvon neliöjuuri  $\sqrt{\bar{X}}$  approksimoivat jakauman teoreettista hajontaa  $\sqrt{\mu}$ ?

Otoshajonnan suhteellinen virhe eri  $N$  arvoilla (**idlharj3\_poisson.pro**). Huom ei riipu  $\mu$ 'sta. Kuvassa neliot mu=9, vinoneliot mu=81; virhe sama ja verrannollinen  $1/\sqrt{N}$ .



Erotuksen  $\sqrt{\bar{X}} - \sqrt{\mu}$  suhteellinen virhe eri  $N$  arvoilla:



```

;-----
program='idlharj3_poisson' & ps=0
;-----

;-----
;Poisson prosessi mu=9 ja mu=81 tapausta/aikayksikko
;Jakauman teoreettinen keskiarvo mu, keskijahonta sqrt(mu)

;Arviodaan otoskeskiarvon ja otoshajonnan
;poikkeamat teoreettisista arvoista eri otoskoolla Nsample
;kayetaan Nsample=10,100,1000,10000

;kuten aiemmin, arviodaan poikkeamien kayttaytymistä
;muodostamalla M:n otoksen otos ja laskemalla niiden otoshajonnat
;M=100
;-----


nsample=[10,100,1000,10000]
M=100

;talletetaan dev_sample_mean = hajonta (<x>-mu)
;talletetaan dev_sample_haj = hajonta (haj(x)-\sqrt(mu))
;talletetaan dev_sample_sqrt = hajonta (\sqrt(<x>) - \sqrt(mu))
dev_sample_mean=fltarr(m)
dev_sample_haj=fltarr(m)
dev_sample_sqrt=fltarr(m)

;-----
mu=9.

for i=0L,n_elements(nsample)-1 do begin
  n=nsample(i)
  meanit=fltarr(m)
  hajot=fltarr(m)
  sqrtt=fltarr(m)
  for j=0,m-1 do begin
    x=randomu(seed,n,poisson=mu)
    meanit(j)=mean(x)-mu
    HAJOT(j)=STDEV(x)-SQRT(mu)
    sqrtt(j)=sqrt(mean(x))-SQRT(mu)
  endfor
  dev_sample_mean(i)=stdev(meanit)
  dev_sample_haj(i)=stdev(hajot)
  dev_sample_sqrt(i)=stdev(sqrtt)
endfor
dev_sample_mean_9=dev_sample_mean
dev_sample_haj_9=dev_sample_haj
dev_sample_sqrt_9=dev_sample_sqrt

;-----
mu=81.

for i=0L,n_elements(nsample)-1 do begin
  n=nsample(i)
  meanit=fltarr(m)
  hajot=fltarr(m)
  sqrtt=fltarr(m)
  for j=0,m-1 do begin
    x=randomu(seed,n,poisson=mu)
    meanit(j)=mean(x)-mu
    HAJOT(j)=STDEV(x)-SQRT(mu)
  endfor

```

```

        sqrtt(j)=sqrt(mean(x))-SQRT(mu)
    endfor
    dev_sample_mean(i)=stdev(meanit)
    dev_sample_haj(i)=stdev(hajot)
    dev_sample_sqrt(i)=stdev(sqrtt)
endfor
dev_sample_mean_81=dev_sample_mean
dev_sample_haj_81=dev_sample_haj
dev_sample_sqrt_81=dev_sample_sqrt

;-----
;poikkeamat teoreettisesta keskiarvosta:

psdirect,program+'_a',ps,/color
nwin
plot,nsample,dev_sample_mean_9/9.,/xlog,/ylog,xtitle='N',$
    ytitle='keskiarvon virheen hajonta (suhteellinen)',psym=6,xr=[1,100000]
oplot,nsample,sqrt(9./nsample)/9.

oplot,nsample,dev_sample_mean_81/81.,psym=4,col=2
oplot,nsample,sqrt(81./nsample)/81.,lines=2,col=2
psdirect,program+'_a',ps,/color,/stop

;-----
;poikkeamat teoreettisesta hajonnasta

psdirect,program+'_b',ps,/color
nwin
plot,nsample,dev_sample_haj_9/sqrt(9),/xlog,/ylog,xtitle='N',$
    ytitle='keskihajonnan virheen hajonta (suhteellinen)',psym=-6,xr=[1,100000]
oplot,nsample,dev_sample_haj_81/sqrt(81),psym=-4,col=2
psdirect,program+'_b',ps,/color,/stop

;-----
;poikkeamat sqrt(mean(x)) -sqrt(mu)

psdirect,program+'_c',ps,/color
nwin
plot,nsample,dev_sample_sqrt_9/sqrt(9),/xlog,/ylog,xtitle='N',$
    ytitle='sqrt(<x>)-sqrt(mu) virheen hajonta (suhteellinen)',psym=-6,xr=[1,100000],yr=[0.001,1]
oplot,nsample,dev_sample_sqrt_81/sqrt(81),psym=-4,col=2
psdirect,program+'_c',ps,/color,/stop

end

```

---

4. Studentin t-jakauma kuvailee Gaussisesta jakaumasta otetun otoksen keskiarvon poikkeamaa teoreettisesta keskiarvosta: suure

$$\frac{\bar{X} - \mu}{\sigma_s / \sqrt{N}}$$

noudattaa t-jakaumaa vapausasteella  $df=N-1$ . Tässä  $\bar{X}$  ja  $\sigma_s$  ovat  $N$ :n kappaleen otoksen keskiarvo ja otoshajonta. (HUOM: jos  $\sigma_s$  sijasta käytettäisiin jakauman teoreettista varianssia  $\sigma$  niin suure olisi Gaussisesti jakaantunut).

a) Piirrä Student'n t-jakaumia eri vapausasteilla  $df$ . Vertaa luennolla (WJ Table 2.1) annettua kaavaa ja IDL:n `T_pdf`-funktiota.

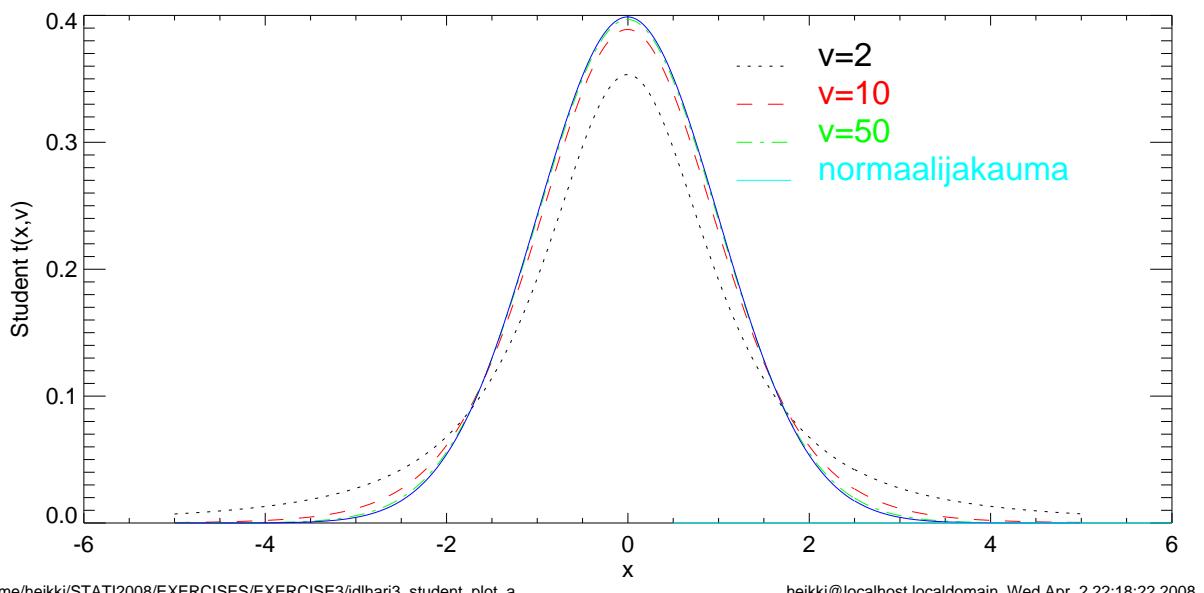
---

Oheisessa kuvassa (tehty ohjelmalla `idlharj3_student_plot.pro`) vapausasteiden määritelmä merkity suurella  $v$

Teoreettinen tiheysfunktio laskettu kaavalla:

$$f(x, v) = \Gamma\left(\frac{v+1}{2}\right) \frac{(1+x^2/v)^{-(v+1)/2}}{\sqrt{\pi v}/\Gamma(v/2)}$$

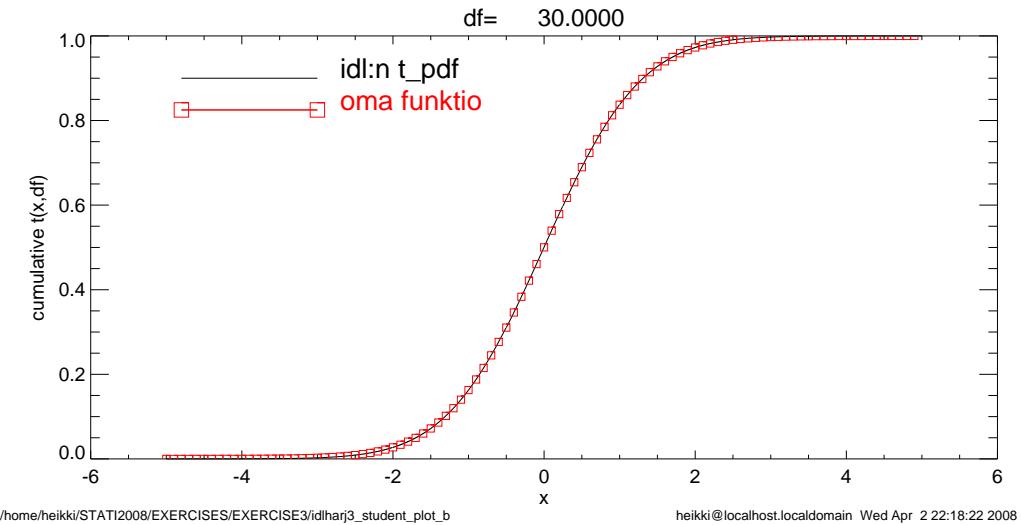
*Huomaa miten jakauma lähestyy nopeasti Gaussista jakaumaa kun vapausasteiden luku kasvaa. Pienillä vapausasteiden määräällä Student'n t-jakauma on hyvä malli jakaumalle jossa on Gaussista jakaumaa voimakkaammat hännät (paljon poikkeavia 'outlier' pisteitä).*



/home/heikki/STATI2008/EXERCISES/EXERCISE3/idlharj3\_student\_plot\_a

heikki@localhost.localdomain Wed Apr 2 22:18:22 2008

*Esimerkki Student'n t-jakaumaa vastaavaavasta kertymäfunktiosta ( $v=50$ ): Verrattu idl:n funktiota ja eo kaavasta yksinkertaisella numeerisella integroinnilla saatua tulosta:*



```
;-----
;student'n t-jakauman tiheysfunktion palauttava aliohjelma
;-----
function t_pdf_nocum,x,df
  pdf=gamma((df+1.)/2.)*(1.+x^2/df)^(-(df+1.)/2.)/sqrt(!pi*df)/gamma(df/2.)
  return,pdf
end

;paaohjelma
;-----
; a1) plot t-jakauma distribution with different degrees of freedom
;-----
program='idlharj3_student_plot'
ps=0
psdirect,program+'_a',ps,/color,xsize=16,ysize=8
col1=1 & if !d.name eq 'PS' then col1=0 ;(valkoinen mustaksi PS-tulostuksessa)

nwin
!p.multi=1

x=findgen(1000)*.01-5.
y2=t_pdf_nocum(x,2.)
y10=t_pdf_nocum(x,10.)
y50=t_pdf_nocum(x,50.)

plot,x,y2,xtitle='Student t(x,v)',ytitle='Student t(x,v)',xr=[-5,5],lines=1,col=col1
oplot,x,y10,col=2,lines=2
oplot,x,y50,col=3,lines=3
oplot,x,1./sqrt(2*!pi)*exp(-0.5*x^2),col=4

label_data,0.6,0.9,['v=2','v=10','v=50','normaalijakauma'],col=[col1,2,3,5],lines=[1,2,3,0] ,len=0.05
```

```

;-----
;plotataan viela samaan kuvaan jakauma, joka saadaan
;laskemalla normaalijakaumasta otettujen N=50 luvun otoksienv
;lukujen nelioiden summia. Tman pitaisi olla chi^2 jakautunut
;vapausasteella 50
m=10000
n=50
x2sum=findgen(m)
for i=0,1,m-1 do begin
  x2sum(i)=total(randomn(seed,n)^2)
endfor
histo_f,x2sum,0,100,1,xx,yy
oplot,xx,yy,psym=10,col=5
psdirect,program+'_a',ps,/stop

;-----
;verrataan idl t_pdf - funktioon joka antaa cumulatiivisen jakauman
;-----
psdirect,program+'_b',ps,/color,xsize=16,ysize=8

x=findgen(10000)*.001-5.
df=30.

;idl-funktio
fcumu=t_pdf(x,df)
plot,x,fcumu,xtitle='x',ytitle='cumulative t(x,df)',title='df='+string(df)

;oma funktioaliohjelma palauttaa tiheysfunktion --> cumulative
pdf=t_pdf_nocum(x,df)
dx=x(1)-x(0)
cpdf=total(pdf,/,cumu)*dx

;plotataan joka sadas
index=lindgen(n_elements(x)/100.)*100.
oplot,x(index),cpdf(index),psym=6,syms=.5,col=2
;teksti
label_data,0.1,.9,['idl:n t_pdf','oma funktio'],psym=[0,-6],col=[0,2],lines=[0,-1]

psdirect,program+'_b',ps,/stop
end

```

---

b) Verifioi eo. otoskesiarvon jakaumaa kuvava kaava luomalla Gaussisesti jakaantuneita suureita. Käytä esim.  $N=10$  ja  $N=100$  otoskokoa. Muodosta histogrammit  $M=100000$  otoksen perusteella. ( $t$ -jakauman pitäisi olla eksakti)

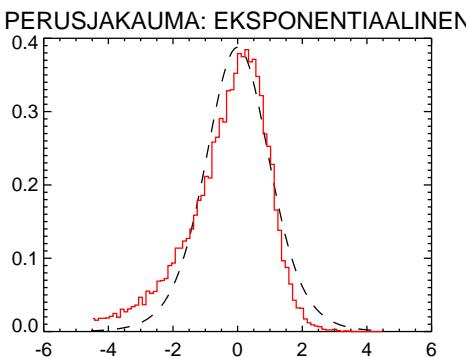
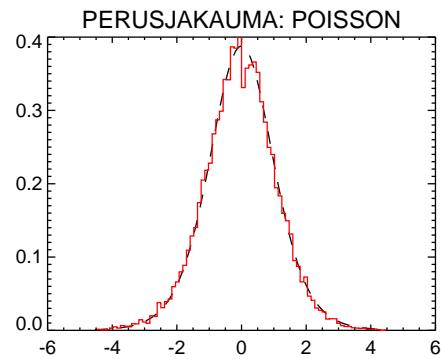
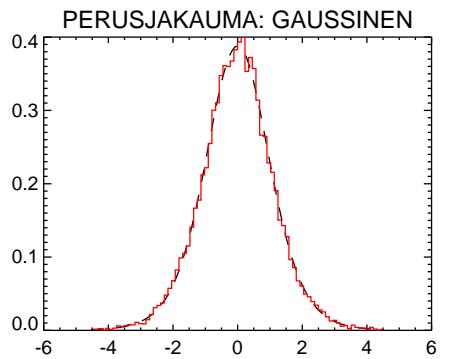
c) Toista sama luomalla otoksia Poisson-jakaantuneista suureista. Päteekö approksimaatio yhää?

d) Toista sama käyttäen eksponentiaalisesti jakaantuneita suureita. Entä nyt?

---

Esimerkkiohjelma **idlharj3\_student\_otos.pro** vertaa otosvarianssin jakaumaa eri perusjakaumille.

Ohessa  $N=10$  luvun otoksia (toistettu  $M=20000$  kertaa)

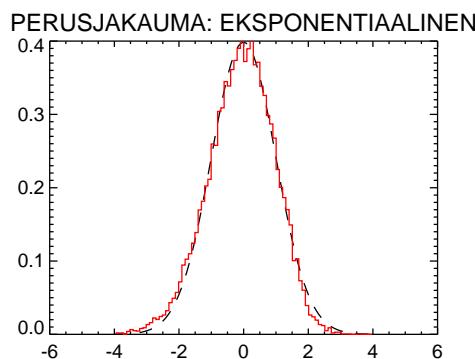
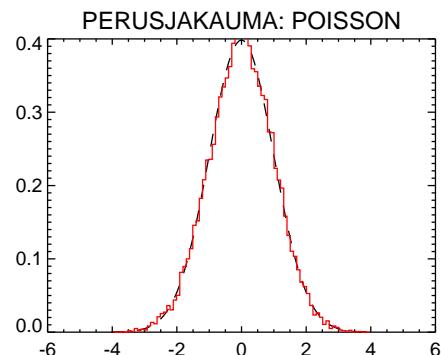
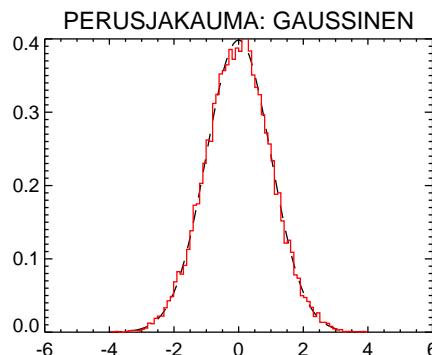


Suureen ( $\langle X \rangle - \mu$ ) / ( $\text{sig}_s / \sqrt{N}$ ) jakauma  
t(x,v) (katkoviiva)  
N= 10

/home/heikki/STATI2008/EXERCISES/EXERCISE3/idlharj3\_student\_otos

heikki@localhost.localdomain Wed Apr 2 22:59:41 2008

Ohessa  $N=200$  luvun otoksia (toistettu  $M=20000$  kertaa)



Suureen  $(\langle X \rangle - \mu) / (\sigma_s / \sqrt{N})$  jakauma  
t(x,v) (katkoviiva)  
 $N = 200$

/home/heikki/STATI2008/EXERCISES/EXERCISE3/idlharj3\_student\_otos

heikki@localhost.localdomain Wed Apr 2 22:58:53 2008

```
-----
program='idlharj3_student_otos' & ps=0
-----
psdirect,program,ps,/color

;Otetaan N-luvun otos
; Gaussisesta          icase=1
; Poisson-jakaumasta   icase=2
; eksponentiaalisesta  icase=3
;ja lasketaan otoskeskiarvon poikkeama teoreettisesta
;( $\langle X \rangle - \mu) / (\sigma_s / \sqrt{N})$ )
;toistetaan M kertaa --> saadaan otospoikkeaman jakauma
;verrataan teoreetiseen Student'n t-jakauman avulla lausuttuun
;(patee Gaussiselle)

N=10
m=200001
otos_dev_tab=fltarr(m)

nwin
!p.multi=[0,2,2]
!p.charsize=1.
if(!d.name eq 'PS') then !p.charsize=0.7
```

```

;olettetu teoreettinen keskiarvo
;Ei vaikuta tuloksiin
mu=100.

for icase=1,3 do begin
  for i=01,m-1 do begin
    if(icase eq 1) then x=randomn(seed,n)+mu
    if(icase eq 2) then x=randomn(seed,n,poisson=mu)
    if(icase eq 3) then x=-alog(randomu(seed,n))*mu
    if(icase eq 1) then title='PERUSJAKAUMA: GAUSSINEN'
    if(icase eq 2) then title='PERUSJAKAUMA: POISSON'
    if(icase eq 3) then title='PERUSJAKAUMA: EKSPONENTIAALINEN'
    otos_dev_tab(i)=(mean(x)-mu)/(stdev(x)/sqrt(N))
  endfor

;jakauman teoreettinen keskikohta ja keskihajonta -> plottausrajat
df=N-1.d0
xm=0.
xsig=sqrt(df/(df-2))
print,stdev(otos_dev_tab),xsig
x1=xm-4*xsig
x2=xm+4*xsig
dx=xsig/10.

;teoreettinen jakauma
xtab=x1+(x2-x1)*dindgen(101.)/100.
pdftab=gamma((df+1.)/2.)*(1.d0+xtab^2/df)^(-(df+1.)/2.)/sqrt(!dpi*df)/gamma(df/2.)
plot,xtab,pdftab,lines=2,title=title
;havaittu
histo_f,otos_dev_tab,x1,x2,dx,xx,yy
 oplot,xx,yy,psym=10,col=2
endfor

;tyhja tila teksteja varten = tyhja plotti (0,0) - (1,1)
plot,lindgen(2),lindgen(2),xs=15,ys=15,/nodata
xyouts,0.1,.8,'Suureen (<X>-mu)/(sig_s/sqrt(N)) jakauma',col=2
xyouts,0.1,.7,'t(x,v) (katkoviiva)'
xyouts,0.1,.6,'N='+string(N)

psdirect,program,ps,/color,/stop
!p.multi=0

end

```

5.  $\chi^2$  jakauma kuvailee normeeratusta normaalijakaumasta otettujen lukujen  $X_i$  neliöiden summan jakaumaa: suure  $\sum_{i=1}^N X_i^2$  noudattaa  $\chi^2$  jakaumaa vapausasteella  $df=N$ .

Jos otetaan  $N$  satunnaismuuttujaan Gaussisesta jakaumasta, jolla hajonta  $\sigma$ , tällöin suure

$$(N - 1) \frac{\sigma_s^2}{\sigma^2}$$

noudattaa  $\chi^2$  jakaumaa vapausasteella  $df=N-1$

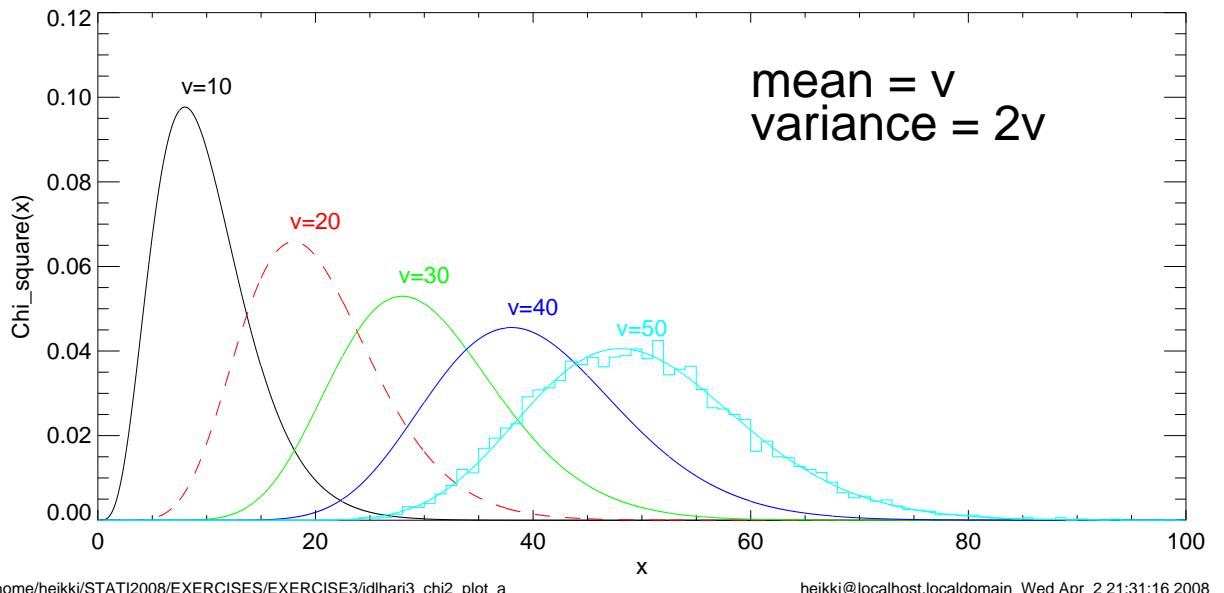
a) Piirrä  $\chi^2$ -jakaumia eri vapauasteilla. Vertaa luennolla (WJ Table 2.1) annettua kaavaa ja IDL:n `chisqr_pdf`-funktiota.

*Oheisessa kuvassa (tehty ohjelmalla **idlharj3\_chi2\_plot.pro**) vapausasteiden määritäminen merkityksellä  $v$*

*Teoreettinen tiheysfunktio laskettu kaavalla:*

$$f(x, v) = \frac{2^{-v/2}}{\Gamma(v/2)} x^{v/2-1} e^{-x/2}$$

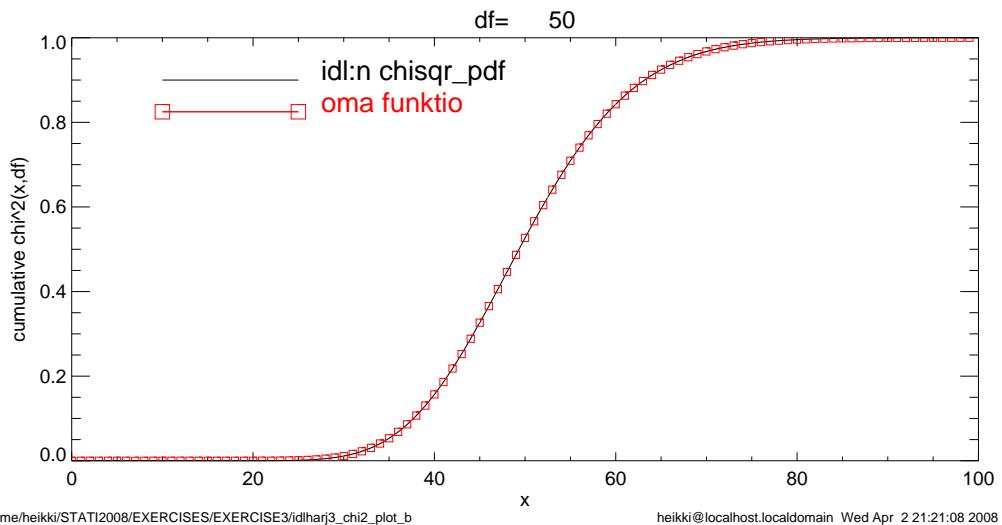
*Vapausasteella  $v=50$  on piirretty myös histogrammi, joka on saatu tutkimalla  $N=50$  gaussiseksi jakaantuneen luvun nelioiden summia ( $M=10000$  otos-otosta)*



Esimerkki  $\chi^2$ -jakaumaa vastaavaavasta kertymäfunktioista ( $v=50$ ): Verrattu idl:n funktiota ja eo kaavasta yksinkertaisella numeerisella integroinnilla saatua tulosta:

$$F(x, v) = \int_0^x \frac{2^{-v/2}}{\Gamma(v/2)} x^{v/2-1} e^{-x/2} dx \approx \Delta x \sum_{x_i \leq x} \frac{2^{-v/2}}{\Gamma(v/2)} x_i^{v/2-1} e^{-x_i/2}$$

jossa  $x_i$  on tasaisin välein  $\Delta x$  valituja pisteitä, joissa tiheysfunktion arvo lasketaan (HUOM: on olemassa myös paljon tehokkaampia tapoja numeeristen integraalien laskemiseen)



```
;-----
;chi^2 tiheysfuntion palauttava aliohjelma
;-----
function chisqr_pdf_nocum,x,df
  pdf=2.^(-df/2.)/gamma(df/2.)*x^(df/2.d0-1.)*exp(-x/2.)
  return, pdf
end

;paaohjelma
; -----
; a1) plot chi-square distribution with different degrees of freedom
; -----
program='idlharj3_chi2_plot'
ps=0
psdirect,program+'_a',ps,/color,xsize=16,ysize=8
nwin
!p.multi=1

x=findgen(10000)*.01
y10=chisqr_pdf_nocum(x,10.)
y20=chisqr_pdf_nocum(x,20.)
y30=chisqr_pdf_nocum(x,30.)
y40=chisqr_pdf_nocum(x,40.)
y50=chisqr_pdf_nocum(x,50.)
```

```

plot,x,y10,xtitle='x',ytitle='Chi_square(x)',yr=[0,.12]
oplot,x,y20,col=2,lines=2
oplot,x,y30,col=3
oplot,x,y40,col=4
oplot,x,y50,col=5

dy=0.003
xyouts,ali=.5,10,max(y10)+dy,'v=10'
xyouts,ali=.5,20,max(y20)+dy,'v=20',col=2
xyouts,ali=.5,30,max(y30)+dy,'v=30',col=3
xyouts,ali=.5,40,max(y40)+dy,'v=40',col=4
xyouts,ali=.5,50,max(y50)+dy,'v=50',col=5

xyouts,60,.10,'mean = v',chars=1.5
xyouts,60,.09,'variance = 2v',chars=1.5

;-----
;plotataan viela samaan kuvaan jakauma, joka saadaan
;laskemalla normaalijakaumasta otettujen N=50 luvun otoksienv
;lukujen nelioiden summia. Tman pitaisi olla chi^2 jakautunut
;vapausasteella 50
m=10000
n=50
x2sum=findgen(m)
for i=0l,m-1 do begin
  x2sum(i)=total(randomn(seed,n)^2)
endfor
histo_f,x2sum,0,100,1,xx,yy
oplot,xx,yy,psym=10,col=5
psdirect,program+'_a',ps,/stop

;-----
;verrataan idl chisq_pdf - funktioon joka antaa cumulatiivisen jakauman
;-----
psdirect,program+'_b',ps,/color,xsize=16,ysize=8

x=findgen(10000)*.01
df=50

;idl-funktio
fcumu=chisqr_pdf(x,df)
plot,x,fcumu,xtitle='x',ytitle='cumulative chi^2(x,df)',title='df='+string(df)

;oma funktioaliohjelma palauttaa tiheysfunktion --> cumulative
pdf=chisqr_pdf_nocum(x,df)
dx=x(1)-x(0)
cpdf=total(pdf,/,cumu)*dx

;plotataan joka sadas
index=lindgen(n_elements(x)/100.)*100.
oplot,x(index),cpdf(index),psym=6,syms=.5,col=2
;teksti
label_data,0.1,.9,['idl:n chisqr_pdf','oma funktio'],psym=[0,-6],col=[0,2],lines=[0,-1]

psdirect,program+'_b',ps,/stop
end

```

---

b) Verifioi otosvarianssin jakauma eri N arvoilla, käyttäen Gaussisesta jakaumasta otettuja muuttujia.

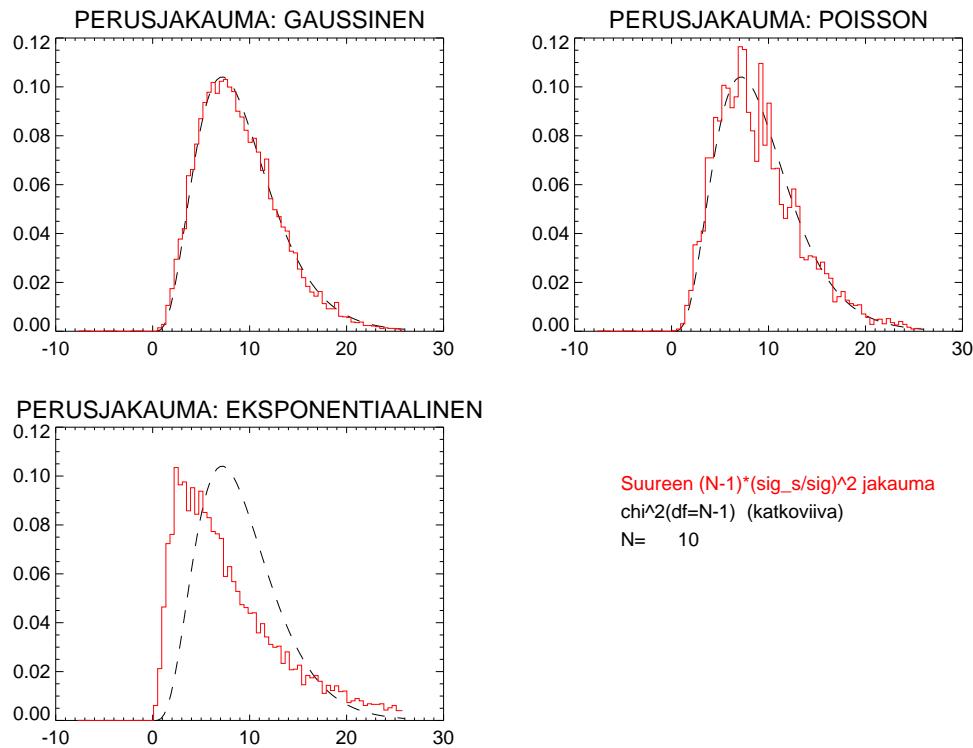
c) Toista Poisson-jakaantuneille muuttujille: miten hyvin otosvarianssin jakauma noudattaa eo. kaavaa?

d) Ja eksponentiaalisesti jakaantuneille muuttujille: miten hyvin otosvarianssin jakauma noudattaa eo. kaavaa?

---

Esimerkkiohjelma **idlharj3\_chi2\_otos.pro** vertaa otosvarianssin jakaumaa eri perusjakau-mille.

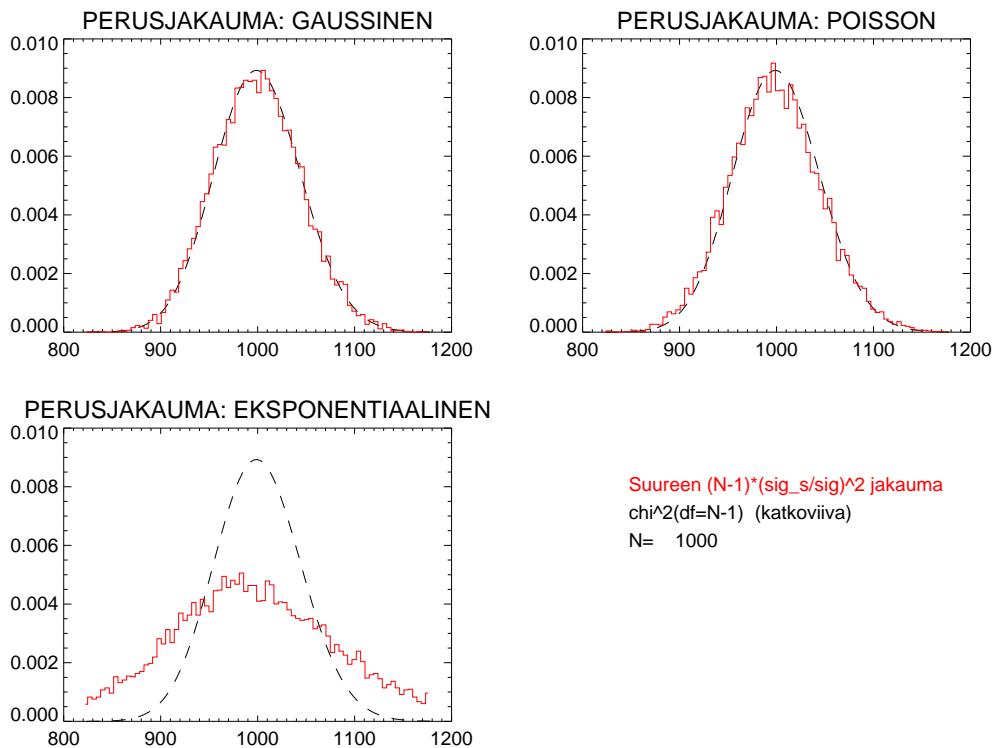
Ohessa  $N=10$  luvun otoksia (toistettu  $M=10000$  kertaa)



/home/heikki/STATI2008/EXERCISES/EXERCISE3/idlharj3\_chi2\_otos

heikki@localhost.localdomain Wed Apr 2 20:50:32 2008

Ohessa  $N=1000$  luvun otoksia (toistettu  $M=10000$  kertaa)



/home/heikki/STATI2008/EXERCISES/EXERCISE3/idlharj3\_chi2\_otos

heikki@localhost.localdomain Wed Apr 2 20:48:31 2008

```
-----
program='idlharj3_chi2_otos' & ps=0
-----

psdirect,program,ps,/color

;Otetaan N-luvun otos ja lasketaan varianssi
; Gaussisesta          icase=1
; Poisson-jakaumasta   icase=2
; eksponentiaalisesta  icase=3
;toistetaan M kertaa --> saadaan otosvarianssin jakauma
;verrataan teoreetiseen chi^2 avulla lausuttuun (patee gaussiselle)

N=10
m=100001
otos_sig_tab=fltarr(m)

;perusjoukon teoreettinen hajonta:
;poisson      sig_teo=sqrt(lambda)
;exponential  sig_teo=meanx

sig_teo=2.
```

```

nwin
!p.multi=[0,2,2]
!p.charsize=1.
if(!d.name eq 'PS') then !p.charsize=0.7

for icase=1,3 do begin
  for i=0,l-1 do begin
    if(icase eq 1) then x=randomn(seed,n)*sig_teo
    if(icase eq 2) then x=randomn(seed,n,poisson=sig_teo^2)
    if(icase eq 3) then x=-alog(randomu(seed,n))*sig_teo
    if(icase eq 1) then title='PERUSJAKAUMA: GAUSSINEN'
    if(icase eq 2) then title='PERUSJAKAUMA: POISSON'
    if(icase eq 3) then title='PERUSJAKAUMA: EKSPONENTIAALINEN'
    otos_sig_tab(i)=stdev(x)
  endfor

;jakauman teoreettinen keskikohta ja keskihajonta -> plottausrajat
xm=n-1
xsig=sqrt(2.*(n-1))
print,stdev(otos_sig_tab^2/sig_teo^2*(n-1)),xsig
x1=xm-4*xsig
x2=xm+4*xsig
dx=xsig/10.

;teoreettinen jakauma
df=n-1.
xtab=x1+(x2-x1)*findgen(101.)/100.
pdf=2.^(-df/2.)/gamma(df/2.)*xtab^(df/2.d0-1.)*exp(-xtab/2.)
plot,xtab,pdf,lines=2,title=title
;havaittu
histo_f,otos_sig_tab^2/sig_teo^2*(n-1.),x1,x2,dx,xx,yy
  oplot,xx,yy,psym=10,col=2
endfor

;tyhja tila teksteja varten = tyhja plotti (0,0) - (1,1)
plot,lindgen(2),lindgen(2),xs=15,ys=15,/nodata
xyouts,0.1,.8,'Suureen (N-1)*(sig_s/sig)^2 jakauma',col=2
xyouts,0.1,.7,'chi^2(df=N-1) (katkoviiva)'
xyouts,0.1,.6,'N='+string(N)

psdirect,program,ps,/color,/stop
!p.multi=0

end

```