

# Johdatus todennäköisyyslaskentaan

## Kevät 2015

Luento 10 / 13

Jukka Kohonen

Matematiikan ja tilastotieteen laitos

Helsingin yliopisto

# MUUNNOKSEN $Y=g(X)$ JAKAUMA

# Satunnaismuuttujan muunnoksia

- Satunnaismuuttujille voi tehdä monenlaisia laskutoimituksia.
- Jos  $X$  = huomina sademäärä (millimetreinä), meitä ehkä kiinnostaa 1000 neliön tontille kertyvä litramäärä  $Y = 1000 \cdot X$ , joka on uusi satunnaismuuttuja.
  - (mutta ei ollenkaan riippumaton  $X$ :stä, vaan **täysin** riippuva: tieto  $X$ :n arvosta määrää täsmälleen  $Y$ :n arvon)
- Toisaalta vesivoimainsinööriä kiinnostaa useiden eri paikkojen sademäärien **summa** = paljonko vettä tulee kertymään voimalaan yhteensä – taas uusi sm
- Muunnoksen jakauma määräytyy tavallisten todennäköisyyslaskennan sääntöjen mukaan:
$$P(Y \text{ on jotain}) = P(X \text{ on sellainen, että } Y \text{ on jotain})$$
- Usein kätevä työkalu tähän on kertymäfunktio.

# Kertymäfunktion ideasta

- Vaikka tiheysfunktio antaa intuitiivisemman käsityksen jakaumasta (mihin jakauma keskittyy), kertymäfunktio on keskeinen **laskennallinen** työkalu jakaumien käsittelyssä.
- **$F(x)$  vastaa kysymykseen ”mikä on tn, että  $X \leq x$ ”.**
- Esim. lämpötilalle  $F(25) = \frac{1}{2}$  tarkoittaa, että on  $\frac{1}{2}$  todennäköisyys sille, että lämpötila on enintään 25 astetta.
- Jos tämän tapahtuman (”lämpötila on enintään 25 astetta”) voi esittää joidenkin muiden tapahtumien avulla (esim. luettelemalla vaihtoehtoja, joilla se voi toteutua), niin se voidaan laskea sitä kautta.
- Olennaista: kertymäfunktion arvo ilmaisee **erään tapahtuman todennäköisyyttä**, ja kaikki tutut todennäköisyyksien kaavat pätevät edelleen – esimerkiksi additiivisuus ja komplementtisääntö.

# Sovellusesimerkki

- Pitkulainen esine (pituus =  $L$ ) nähdään kaukaa satunnaisessa kulmassa ( $\theta$ ).
  - Nähty projektio =  $X = L \cdot \cos \theta$
  - Projektion jakauma:  $X \sim ?$
  - Pitää siis osata ratkaista  $\theta$ :n muunnoksen jakauma.
- **Käänteisongelma:** Sama pitkulainen esine (pituus tuntematon) nähdään monta kertaa satunnaisissa kulmissa.
  - Tunnetaan nähtyjen projektioden jakauma
  - Mikä on pituuden jakauma?
  - Sovelletaan esim. Bayesin kaavaa.
- Epäsäännöllisen muotoinen asteroidi nähdään satunnaisissa kulmissa.
  - Tunnetaan nähtyjen (asteroidin heijastamien) kokonaiskirkkauksien jakauma ja/tai kehitys ajan kuluessa (kun asteroidi pyörii ja liikkuu)
  - Mikä on asteroidin muoto?

# Erilaisia muunnostehtäviä

1. Tunnetaan **kertymäfunktio**  $F_X$  ja muunnosfunktio  $Y = g(X)$ .  
Mikä on  $Y$ :n kertymäfunktio?  
→ Periaatteessa **helppo** tehtävä: Ratkaistaan  $P(Y \leq y)$
2. Tunnetaan **tiheysfunktio**  $f_X$  ja muunnosfunktio  $Y = g(X)$ .  
Mikä on  $Y$ :n tiheysfunktio?  
→ **Ei aivan triviaalia**.  
On olemassa tiheysfunktion muuntokaava (ei käsitellä tällä kurssilla, mutta esim. syksyn kurssilla *Todennäköisyyslaskenta*).
3. Osataan **simuloida**  $X_1 \dots X_n$  iid samasta jakaumasta kuin  $X$ , ja tunnetaan muunnosfunktio  $Y = g(X)$ .  
Miten simuloidaan  $Y$ :n jakaumasta?  
→ **Todella helppoa**: lasketaan  $Y_i = g(X_i)$

Kokeilemme muutamaa yksinkertaista muunnosta menetelmällä 3.

# Muunnos: vakion lisääminen



$$X \sim \text{Tas}(0, 5)$$

$$Y = X + 10$$

$$Y \sim ?$$

Ilmeisesti Y:in on tasajakautunut.

Millä parametreilla?



# Muunnos: vakiolla kertominen

$$X \sim \text{Tas}(0, 5)$$

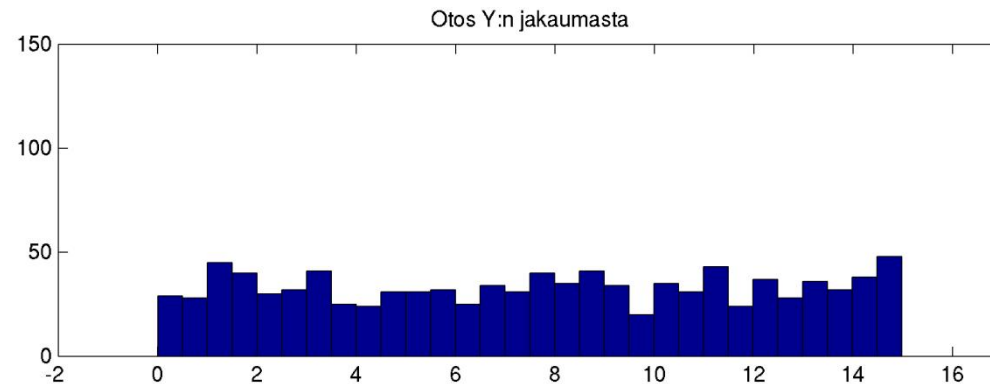
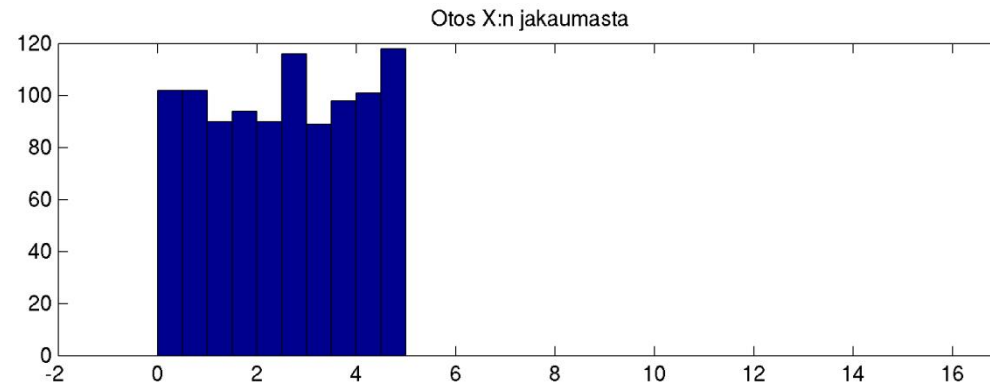
$$Y = 3 \cdot X$$

$$Y \sim ?$$

Ilmeisesti Y:in on tasajakautunut.

Millä parametreilla?

Huom. litistyminen, joka näkyy myös Y:n tiheysfunktiossa.





# Muunnos: logaritmi


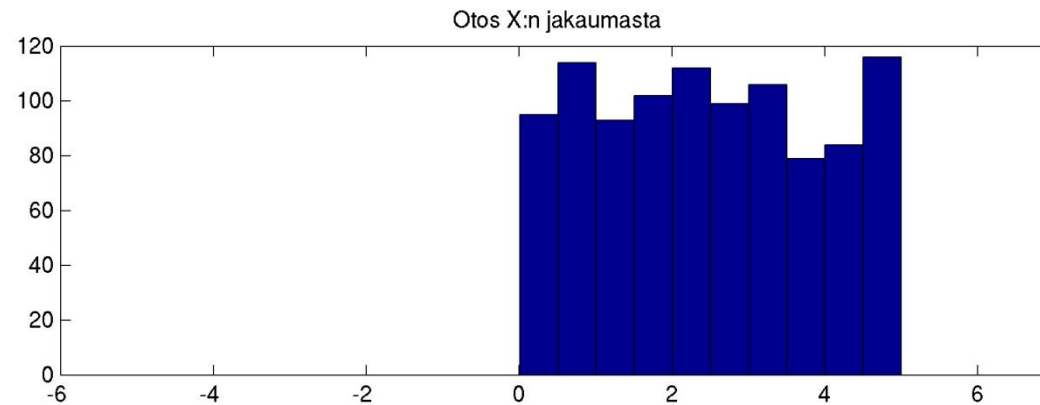
$$X \sim \text{Tas}(0, 5)$$

$$Y = \ln X$$

$$Y \sim ?$$

Y:llä on ilmeisesti  
joku erikoisempi  
jakauma.

Osataan kyllä laskea  
(Tuominen s. 74)



# Kertymäfunktion muuntaminen

Tuominen s. 74

$$X \sim \text{Tas}(0, 5)$$

$$Y = \ln X$$

$$Y \sim ?$$

Ratkaistaan  $Y$ :n kertymäfunktio.


$F_Y(a)$	$= P(Y \leq a)$	Kertymäfunktion määritelmä.
	$= P(\ln X \leq a)$	Koska $Y = \ln X$ .
	$= P(X \leq \exp(a))$	Eksponenttifunktio aidosti kasvava.
	$= F_X(\exp(a))$	Kertymäfunktion määritelmä
	$= \exp(a) / 5$	Tasajakauman kertymäfunktio.

Derivoimalla saadaan  $Y$ :n tiheysfunktio.

$$f_Y(a) = (1/5) \exp(a)$$

Huom. että  $Y$ :n jakauma sijoittuu välille  $(-\infty, \ln 5)$ , sillä sinne väli  $(0, 5)$  kuvautuu logaritmuunnoksessa!

Tulos tuntuu vastaavan otoshistogrammin muotoa.



# MULTINOMIKERROIN JA MULTINOMIKOE

# Multinomikerroin

Tuominen 34-36

10 ihmisellä on eriväriset hatut: 3 punaista, 2 sinistä ja 5 vihreää.

Ihmiset asettuvat jonoon.

Monessako eri järjestyksessä värit voivat olla? Emme välitä ihmisistä.

**G B E H A J D F I C**

Ihmisten jonoja on  $10!$  erilaista. Mutta monessa eri jonossa on sama värijärjestys!

- Jos punaisten (B, E, C) järjestys vaihdetaan keskenään, saadaan sama värijono
- Jos sinisten (J, I) järjestys vaihdetaan keskenään, saadaan sama värijono
- Jos vihreiden (G, H, A, D, F) järjestys vaihdetaan keskenään, saadaan sama värijono

Tuloperiaate: sama värijono saadaan  $(3!) \cdot (2!) \cdot (5!)$  eri tavalla

Eri värijonoja on siis

$$\frac{10!}{(3!) \cdot (2!) \cdot (5!)} = \frac{3628800}{6 \cdot 2 \cdot 120} = 2520 = \binom{10}{3, 2, 5}$$

Uusi merkintä: **multinomikerroin**

”Monellako tavalla 10:stä alkioista voi valita 3 kpl ensimmäiseen osajoukkoon, 2 kpl toiseen ja 5 kpl kolmanteen?” Vrt. binomikerroin.

# Menikö oikein?

```
>> P = perms(' PPPSSVVVV' );  
>> size(P)  
ans =  
      3628800      10
```

```
>> U = unique(P, ' rows' );  
>> size(U)  
ans =  
      2520      10
```

Värit eri ihmisjonoissa  
(monessa jonossa sama värijärjestys)

```
WWWVSSPPP  
WWWVSSPPP  
WWWVSSPPP  
WWWVSSPPP  
WWWVSSPPP  
...  
PVVVVSPSP  
PVVVVSSPP  
PVVVVSSPP
```

} 3 628 800 kpl

Erilaiset värijonot

```
WWWVPPSS  
WWWVPPSPS  
WWWVPPSSP  
WWWVSPSPS  
WWWVSPSPS  
...  
SSPPVPVWV  
SSPPVPVWV  
SSPPVWVWV
```

} 2 520 kpl **OK**

# Multinomikoe

Toistokokeen yleistys: Joka kerralla on **monta** poissulkevaa vaihtoehtoa, joiden tn:t tunnetaan. Kysytään montako kertaa toteutuu mikäkin vaihtoehto, kun kokeita on  $n$  kpl.

Suuressa populaatiossa on kolmen puolueen **A**, **B** ja **C** kannattajia osuuksin  $p = 0.5$ ,  $q = 0.3$  ja  $r = 0.2$ .

Poimitaan populaatiosta umpimähkään  $n = 10$  henkilön otos.

Millä todennäköisyydellä saadaan otos, jossa puolueiden kannattajien **lukumäärät** ovat  $a$ ,  $b$  ja  $c$  (missä  $a + b + c = 10$ )?

- Suuri populaatio: approksimoimme otoksen ”takaisinpanolla”, kukin otoksen henkilö on toisista **riippumatta** A:n kannattaja tn:llä  $p$  jne.
- Alkeistapauksina mahdolliset 10-jonot puoluekantoja otoksessa – ei symmetriset! Esim. eräiden jonojen todennäköisyyksiä:

$$P(\text{AAAAAAAAAA}) = p^{10} \approx 0.000\ 977$$

$$P(\text{AAABBBCC}) = p^4 \cdot q^4 \cdot r^2 \approx 0.000\ 020 \quad \text{Miksi pienempi?!}$$

# Multinomikoe

Meitä ei kiinnosta, missä järjestyksessä puoluekantoja ilmaantuu otokseen, vain lukumäärät. **Lasketaan yhteen** alkeistapaukset, joissa lukumäärät ovat samat. Tapausten määrä = multinomikerroin!

$P(\text{AAAAAAAAAA})$	$= p^{10}$	$\approx 0.000\ 977$	} Näitä (10×A) on vain yksi
$P(\text{AAABABBBCC})$	$= p^4 \cdot q^4 \cdot r^2$	$\approx 0.000\ 020$	
$P(\text{BBCAABBAAC})$	$= p^4 \cdot q^4 \cdot r^2$	$\approx 0.000\ 020$	} Näitä alkeistapauksia (4×A, 4×B, 2×C) on
$P(\text{AABCCAABBB})$	$= p^4 \cdot q^4 \cdot r^2$	$\approx 0.000\ 020$	
...			
$P(\text{CCBBBBAAAA})$	$= p^4 \cdot q^4 \cdot r^2$	$\approx 0.000\ 020$	} $\binom{10}{4,4,2} = 3150$ kpl, tn yht. $\approx$ <b>0.064</b>
...			

# Multinomikoe

Tässä eri lukumäärien todennäköisyyksiä suuruusjärjestyksessä.

<b>(a,b,c)</b>	<b>tn</b>
(5,3,2)	0.085
(6,2,2)	0.071
(6,3,1)	0.071
(4,4,2)	0.064
(5,4,1)	0.064
...	...
(10,0,0)	0.000 977
...	...
(0,0,10)	0.000 000 102
<b>yhteensä</b>	<b>1</b>

Tn, että otososuudet ovat **täsmälleen** samat (50%, 30%, 20%) kuin populaatiossa, on vain 0.085

Mutta muutkaan todennäköiset osuudet eivät **paljon** poikkea

Tn saada "pahasti pielessä" oleva otos on hyvin pieni



# Multinomikoe ja multinomijakauma

- $n$  riippumatonta koetta, jokaisessa 3 poissulkevaa vaihtoehtoa.
- Joka kerta vaihtoehtojen todennäköisyydet  $p, q, r$ .
- Tn, että toteutuneet lukumäärät ovat  $(a, b, c)$  on

$$\binom{n}{a, b, c} \cdot p^a \cdot q^b \cdot r^c$$

- Voimme sanoa, että lukumäärät  $(a, b, c)$  ovat yhdessä **multinomijakautuneet** parametrein  $n$  ja  $(p, q, r)$ .
- Lukumäärät ovat satunnaismuuttujia, ja keskenään **riippuvia!**  
Jos esim. sattuu  $a=n$ , niin on pakko olla  $b=c=0$ . (miksi?)
- Jos vaihtoehtoja on  $> 3$ , kaava yleistyy ilmeisellä tavalla.
- Jos vaihtoehtoja on vain 2, kaava palautuu tuttuun binomijakaumaan.

# Pylväiden korkeuksien jakauma

Merk.

$Y_i = i$ :nnen pylvään korkeus  
=  $i$ :nnelle jakovälille osuvien  
pisteiden lukumäärä


Yksittäisen pylvään korkeus on  
**binomijakautunut. (miksi?)**

Tn, että histogrammi on täysin  
tasainen? Huomaa, että pylväiden  
korkeudet eivät ole riippumattomia.


Jos esim. ensimmäiseen väliin on  
osunut peräti 80 pistettä, niin ei  
muille väleille enää riitä kuin 20  
pistettä: vahva riippuvuus.

Kyseessä on **multinomijakauma**.

100 pistettä



Otoksen histogrammi



# Esim. 100 pistettä, 10 jakoväliä

- Jotta histogrammi olisi täysin tasainen, eri jakoväleille osuneiden pisteiden määrien (vrt. puolueiden kannattajat) täytyy olla täsmälleen  $(10, 10, 10, \dots, 10)$ .
- Tämän  $t_n =$

$$\binom{100}{10, 10, \dots, 10} \cdot 0.1^{10} \cdot 0.1^{10} \cdot \dots \cdot 0.1^{10} \approx 2.4 \cdot 10^{-8}$$

eli aika vähän.

- Toisaalta voitaisiin laskea  $t_n$  saada melko tasainen histogrammi, esim.  $t_n$  että jokaisen pylvään korkeus on välillä  $[7, 13]$ . Miten?
- Vaikka täysin tasainen histogrammi toteutuu harvoin (pienellä  $t_n$ ), melko tasainen toteutuu suurella  $t_n$ .