

JAKAUMIA : DISKR	PTNF $f_X(x)$	EX	$var X$	$M(t)$
$X \sim \text{Bin}(n, p)$	$\binom{n}{x} p^x (1-p)^{n-x}$	np	$np(1-p)$	$(pe^t + 1 - p)^n$
$X \sim \text{Bernoulli}(p)$	$\Leftrightarrow X \sim \text{Bin}(1, p)$			
$X \sim \text{Geom}(p)$	$p(1-p)^x, x=0,1,2,\dots$	$\frac{1-p}{p}$	$\frac{1-p}{p^2}$	$\frac{p}{1-(1-p)e^t}, t < \ln(\frac{1}{1-p})$
$X \sim \text{Poi}(\theta), \theta > 0$	$e^{-\theta} \cdot \frac{\theta^x}{x!}, x=0,1,2,\dots$	θ	θ	$\exp(\theta(e^t - 1))$

JAKAUMIA : JATKUMA	TF $f_X(x)$	EX	$var X$	
$X \sim U(a, b)$	$\frac{1}{b-a} \mathbb{1}\{a < x < b\}$	$\frac{a+b}{2}$	$\frac{(b-a)^2}{12}$	
$X \sim \text{Exp}(\lambda), \lambda > 0$	$\lambda e^{-\lambda x} \mathbb{1}\{x > 0\}$	$\frac{1}{\lambda}$	$\frac{1}{\lambda^2}$	$\frac{\lambda}{\lambda - t}, t < \lambda$
$X \sim N(\mu, \sigma^2)$	$\frac{1}{\sigma\sqrt{2\pi}} \exp(-\frac{1}{2}(\frac{x-\mu}{\sigma})^2)$	μ	σ^2	$\exp(\mu t + \frac{1}{2}\sigma^2 t^2)$

JAKAUMIA = DISTRIBUTIONS = FÖRDELNINGAR
 DISKR = DISCRETE
 JATKUMA = CONTINUOUS = KONTINUERLIG

ODOTUSARVO = EXPECTATION = VÄNTEVÄRDE
 VARIANSI = VARIANCE = VARIANS

- ODOTUSARVON OMINAISUUKSIJA : $EX \geq EY \Leftrightarrow X \geq Y$
 1-ulott. (1-dim)
 • $EX = 0, X \geq 0 \Rightarrow X = 0$ (kun: läht. f. with pr. 1)
 • $E(aX + bY) = aEX + bEY$
 • $E(XY) = EXEY \Leftrightarrow X \perp Y$
 • $X \stackrel{d}{=} Y \Rightarrow EX = EY$

• $Eg(X) = \begin{cases} \sum_n g(x_i) f_X(x_i), & X \text{ DISKR.} \\ \int g(x) f_X(x) dx, & X \text{ illä jatkuva jakauma} \end{cases}$
 (TTL)

- (ko) varianssi (1-ulott.)
- $var X \geq 0$
 - $var X = E(X - EX)^2 = EX^2 - (EX)^2$
 - $var(aX + b) = a^2 var X$
 - $var(X + Y) = var X + var Y \Leftrightarrow X \perp Y$
 - $cov(X, Y) = E(X - EX)(Y - EY)$
 - $cov(X, X) = var X$

EHDOLLINEN ODOTUSARVO = CONDITIONAL EXPECTATION = BETINGAT VÄNTEVÄRDE
MONIULOTTINEN = MULTI DIMENSIONAL = FLEBOIMENSIONELL
YHTEISJAKAUMA = JOINT (PROB.) DISTRIBUTION = SIMULTANA FÖRDELNINGEN
VEKTORI = VECTOR = VEKTOR, MATEIISI = MATRIX = MÄTRIS
STANDARDINORMAALIJAKAUMA = STANDARD ^(MULTI) NORMAL DISTRIBUTION
 = STANDARDISERAU NORMAL FÖRDELNING
MULTINORMAALIJAKAUMA = MULTINORMAL ^(MULTIVARIAT) DISTRIBUTION
 = MULTIVARIAT NORMAL FÖRDELNING

MONIUCOTTEI

X, Y SATUNNAISVEKTOREITA.
 $Z = (X, Y) = \begin{pmatrix} X \\ Y \end{pmatrix}$
 $= (X_1, \dots, X_n, Y_1, \dots, Y_m)$

MERK.
 $X = \begin{pmatrix} X_1 \\ \vdots \\ X_n \end{pmatrix} = (X_1, \dots, X_n)$
 $Y = (Y_1, \dots, Y_m)$

YHTEISJAKAUMA, KERTOLASKUSÄÄNTÖ (VOIMASSA KUN

X, Y JATEUV. JAK.
 X, Y DISKR. JAK.
 X DISKR.
 Y JUASTI JAK.)

$f_{X,Y}(x,y) = f_X(x) f_{Y|X}(y|x)$

MARGINALISOINTI: $f_X(x) = \int f_{X,Y}(x,y) dy$
 $\int \sum f_{X,Y}(x,y)$

(TTL) $Eg(X,Y) = \begin{cases} \sum_x \int g(x,y) f_{X,Y}(x,y) dy & X \text{ DISKR.}, Y \text{ JUVA JAK} \\ \int \int g(x,y) f_{X,Y}(x,y) dx dy & X, Y \text{ JUVA JAK} \\ \sum_x \sum_y g(x,y) f_{X,Y}(x,y) & X, Y \text{ DISKR.} \end{cases}$

EHDOULLINEN

ODOTUSARVO
 VARIANSSI $\rightarrow E(g(X,Y) | X=x) = m(x)$
 $Var(g(X,Y) | X=x) = v(x)$

MÄÄR. (TTL):n AVULLA KUN $f_{X,Y}(x,y)$ KÄYTTÄÄN

EHDOULLINEN

ODOTUSARVO
 VARIANSSI $E(g(X,Y) | X) = m(X)$
 $Var(g(X,Y) | X) = v(X)$

KAUVANA $f_{Y|X}(y|x)$ LJA $E!$
 "integroida" x :n suhteen
 (COND. EXP. IS DEFINED WITH (TTL) BY REPLACING $f_{X,Y}$ WITH $f_{Y|X}$)
 MODIFIED

OHJAINSUUKSIA:

- $Eg(X,Y) = E E(g(X,Y) | X)$
- $Var g(X,Y) = E Var(g(X,Y) | X) + Var E(g(X,Y) | X)$

KOVARIANSSI JA KOVARIANSSIMATRIISI:

- $Cov(X) = Cov(X,X)$
- $Cov(X,Y) = E(X-EX)(Y-EY)^T = E(XY^T) - (EX)(EY)^T$
- $Cov(AX, BY) = A Cov(X,Y) B^T$
 (A, B VAKIOMATRIISIT JA CONSTANT MATRICES)

STANDARDINORMAALIJAKAUMA $N_n(0, I_n)$.

$U \sim N_n(0, I_n)$ on TF $f_U(u) = (2\pi)^{-n/2} \exp(-\frac{1}{2} u^T u)$
 $E U = 0_n, Cov U = I_n$

YLEINEN MULTINORMAALIJAKAUMA: $X = A U + \mu, EX = \mu, Cov X = A A^T = \Sigma$
 JOS Σ SÄÄNNÖLLINEN, TF OLEMATTA JA

$f_X(x) = (2\pi)^{-n/2} (\det \Sigma)^{-1/2} \exp(-\frac{1}{2} (x-\mu)^T \Sigma^{-1} (x-\mu))$

TIHEYSPUNKTION MUUNTOKAAVAN MUISTISÄÄNTÖ (MONIUCOTT.)

$f_X(x) | dx| = f_Y(y) | dy|$ kun $y = g(x)$ tai $x = h(y)$
 $\frac{\partial x}{\partial y} = \frac{\partial(x_1, \dots, x_n)}{\partial(y_1, \dots, y_m)}$ on jacobiaani (kuvausten h)