

Oulun yliopiston matemaattisten tieteiden laitos/tilastotiede
JOHDATUS BAYESILÄISEEN TILASTOTIETEESEEN, kl 2011 (Esa Läärä)
Loppukuulustelu, ma 17.10. klo 14-18 L1

Merkitse vastauspaperiin selvästi, suoritaiko kurssin aineopintoihin vai syventäviin opintoihin. VASTAA VIITEEN (5) KYSYMYKSEEN. Tehtävä 1 sisältyy vain aineopintotason tenttiin, kun taas tehtävä 6 vaaditaan vain syventävien opintojen kuulusteluun. Osa muiden tehtävien alakohdista sisältyy vain syventävänä suoritettavaan tenttiin.

Mukana saa olla laskin mutta ei omia muistiinpanoja eikä muutakaan kirjallista materiaalia. Tarvittavat taulukot jaetaan tehtäväpaperin mukana.

1. *Vain aineopintoihin.* Huonoennusteiseen leukemiaan sairastuneiden potilaiden ryhmän ($n = 16$) elinajat (viikkoina) diagnoosin jälkeen olivat

2 3 3 3 4 4 4 7 8 16 17 22 30 43 56 65

Elinaikojen keskiarvo oli $\bar{y} = 17.94$ viikkoa = 0.35 vuotta.

Oletetaan elinaikojen y_1, \dots, y_n olevan toisistaan ehdollisesti riippumattomia ehdolla λ , jossa $y_i | \lambda \sim \text{Exp}(\lambda)$, jok. $i = 1, \dots, n$, ja $\lambda > 0$. Priorijakaumaksi λ :lle oletetaan $\text{Gamma}(\alpha, \beta)$, jonka molemmat parametrit ovat positiivisia.

- Osoita, että gammajakauma on eksponenttijakauman konjugaattijakauma.
- Osoita, että parametrin λ posteriorijakaumalle pätee: $\lambda | y \sim \text{Gamma}(\alpha + n, \beta + t)$, jossa $y = (y_1, \dots, y_n)$ ja $t = \sum_{i=1}^n y_i$.
- Jos leukemiapotilaiden elinaikojen analyysissä prioriparametrien arvoiksi oletetaan $\alpha = 0.1$ (paljas luku) ja $\beta = 0.1$ vuotta, niin kuinka suuria ovat em. havaintojen pohjalta λ :n posteriorijakauman odotusarvo $\mathbb{E}(\lambda | y)$ ja varianssi $\text{var}(\lambda | y)$?

2. Narkolepsiaan sairastuneiden 5–19-vuotiaiden lasten ja nuorten lukumääät Suomessa vuosjakson 2006–2010 aikana olivat vuosittain seuraavat:

vuosi	2006	2007	2008	2009	2010
lukumääärä	5	6	14	9	62

Lähde: Kansallisen narkolepsiatyöryhmän raportti, 2011 (http://www.thl.fi/fi_FI/web/fi-rokotteet/narkolepsia_ja_sikainfluenssarokote).

Narkolepsiatapausten lukumääristä Suomessa ei ole luotettavia tilastoja ennen vuotta 2006. Ruotsissa diagnostoitiin 2000-luvun puolivälistä alkaen vuosittain 7–16 uutta narkolepsiatapausta tässä ikäluokassa.

Merkitään $y_i =$ ikäluokassa 15–19 vuotta ilmaantuneiden uusien narkolepsiatapausten lukumäärä Suomessa vuonna $i + 2005$; $i = 1, \dots, 5$. Oletetaan, että havainnot y_1, \dots, y_5 ovat toisistaan ehdollisesti riippumattomat siten, että $y_i | \theta_i \sim \text{Poisson}(\theta_i)$, jossa $\theta_i > 0$ jok. $i = 1, \dots, 5$.

Seuraavalla sivulla on aineiston analyysiä varten laadittu Jags-skripti sekä sen pohjalta tehdyt simulaatioajot ja niiden tuloksia. Kerro tiiviisti mutta riittävän yksityiskohtaisesti, mikä on ollut analyysin kohde, millaisia malli-, priori- ym. oletuksia on tehty, ja mitkä ovat analyysin keskeiset tulokset.

```

write("
  model{
    for( i in 1:length(y) )
    {   y[i] ~ dpois(theta[i])
        theta[i] <- beta0 + beta1*(x[i]-mean(x)) }
    beta0 ~ dgamma(6, 1)
    beta1 ~ dnorm(0, 0.05)
    pb1 <- step(beta1)
    tt <- beta0 + beta1*2.5
    yt ~ dpois(tt)
  }
", "gampoislin.txt")

> library(rjags)
> y <- c(5, 6, 14, 9)
> x <- 2005 + 1:4
> gpl <- jags.model("gampoislin.txt", data = list(y = y, x = x))
> gpls <- coda.samples(gpl, c("beta0", "beta1", "pb1", "yt"), n.iter = 5000)

> summary(gpls)

```

Iterations = 1001:6000

Thinning interval = 1

Number of chains = 1

Sample size per chain = 5000

1. Empirical mean and standard deviation for each variable,
plus standard error of the mean:

	Mean	SD	Naive SE	Time-series SE
beta0	8.1409	1.2526	0.017714	0.024495
beta1	1.8284	1.1748	0.016614	0.020255
pb1	0.9438	0.2303	0.003257	0.003687
yt	12.7160	4.9972	0.070672	0.075380

2. Quantiles for each variable:

	2.5%	25%	50%	75%	97.5%
beta0	5.8696	7.297	8.097	8.922	10.842
beta1	-0.4881	1.044	1.838	2.621	4.109
pb1	0.0000	1.000	1.000	1.000	1.000
yt	4.0000	9.000	12.000	16.000	23.000

3. Oletetaan nyt että neljänä ensimmäisenä vuonna 2006–2009 vuotuisten tapausmäärien odotusarvo oli samansuuruisen $\mu_0 = \theta_i$, $i = 1, \dots, 4$ mutta vuoden 2010 odotusarvo $\mu_1 = \theta_5$ oli mahdollisesti erilainen. Analysoidaan odotusarvojen μ_1 ja μ_0 suhdetta $\rho = \mu_1/\mu_0$ normaalijakaumaan perustuvalla likimääräisellä menetelmällä. Tässä nojaudutaan siihen, että parametrin $\alpha = \log(\rho)$ suurimman uskottavuuden estimaattorin $\hat{\alpha} = \log(\hat{\rho})$ otantajakauma on likimain

normaalijakauma odotusarvolla α ja varianssilla σ^2 , jossa su-estimaattorien ja σ^2 :n lausekkeet ovat

$$\hat{\mu}_0 = \frac{1}{4} \sum_{i=1}^4 y_i, \quad \hat{\mu}_1 = y_5, \quad \hat{\alpha} = \log(\hat{\rho}) = \log(\hat{\mu}_1) - \log(\hat{\mu}_0), \quad \sigma^2 = \frac{1}{4\hat{\mu}_0} + \frac{1}{\hat{\mu}_1},$$

Parametrin α priorijakaumaksi omaksutaan normaalijakauma prioriodotusarvolla α_0 ja priorivarianssilla ν_0 .

Näillä oletuksilla parametrin α posteriorijakauma on likimain normaalijakauma odotusarvolla α_1 ja varianssilla ν_1 , jossa

$$\nu_1 = \left(\frac{1}{\nu_0} + \frac{1}{\sigma^2} \right)^{-1}, \quad \alpha_1 = \frac{\nu_0^{-1}\alpha_0 + \sigma^{-2}\hat{\alpha}}{\nu_0^{-1} + \sigma^{-2}}.$$

- (a) *Syventäviin opintoihin:* Perustele edellä kerrottu tulos koskien α :n likimääräistä posteriorijakaumaa.
- (b) Kirjoita Jags-malliskripti, jolla simuloidaan odotusarvojen suhteen $\rho = \mu_1/\mu_0$ posteriorijakaumaa edellä määriteltyyn normaaliamproksimaatioon sekä latteaan priorijakaumaan $\alpha \sim N(0, 10^{-6})$ perustuen ja jolla saadaan allaolevat tulokset, joista mainittakoon, että `prhogt1` tarkoittaa todennäköisyyttä $\mathbb{P}(\rho > 1 | y)$. Tarvittavat havaintovektorin $y = (y_1, \dots, y_5)$ muunnokset kannattaa tehdä tämän skriptin ulkopuolella tavaramaisista R-komentojen avulla.

```
> rhomalli <- jags.model("poisrho.txt", data = list(alphahat = alphahat,
+      SE = SE))
> rhosimu <- coda.samples(rhomalli, c("alpha", "rho", "prhogt1"),
+      n.iter = 10000)

> summary(rhosimu)

Iterations = 1:10000
Thinning interval = 1
Number of chains = 1
Sample size per chain = 10000
```

1. Empirical mean and standard deviation for each variable,
plus standard error of the mean:

	Mean	SD	Naive	SE	Time-series	SE
alpha	1.985	0.1708	0.001708		0.001576	
prhogt1	1.000	0.0000	0.000000		0.000000	
rho	7.388	1.2736	0.012736		0.011928	

2. Quantiles for each variable:

	2.5%	25%	50%	75%	97.5%
alpha	1.647	1.870	1.986	2.101	2.321
prhogt1	1.000	1.000	1.000	1.000	1.000
rho	5.190	6.487	7.287	8.175	10.181

- (c) Esitä tiivis sanallinen selostus saaduista tuloksista ja niiden pohjalta tekemistästä päätelmistä.

4. Tee selkoa priorijakaumien merkityksestä ja roolista sekä niistä periaatteista joiden nojalla priorijakauma valitaan ja määritellään bayesiläisessä analyysissä ja päätelyssä.
5. Tee selkoa posteriorijakauman MCMC-simuloinnissa tuotettavien ketjujen suppenemisdiagnostiikan periaatteista ja perusmenetelmistä.
6. *Vain syventäviin opintoihin:* Hepatiitti B-virusta (HBV) vastaan kehitetyn rokotteen tehoa tutkittiin Gambiassa. Mitattavana vasteena on vasta-ainemäärä A_{ij} henkilöllä i mittauskertana $j = 1, 2, 3$, jolloin oli kulunut t_{ij} vuorokautta rokottamisesta. Mittauskertoja oli korkeintaan 3 per henkilö. Seuraavassa kuvassa on esitetty kaikkien tutkittujen henkilöiden ($n = 106$) mittaussarjat rokottamisesta kuluneen ajan funktiona.

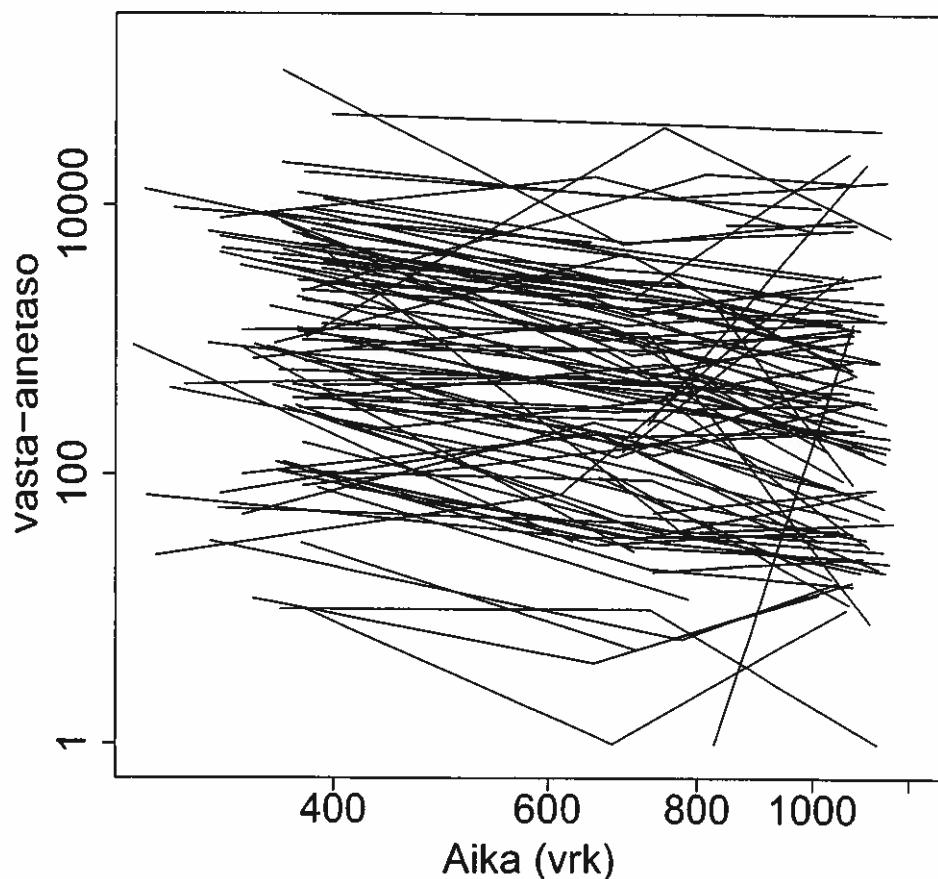
Vasta-ainetasojen logaritmien $y_{ij} = \log(A_{ij})$ malliksi omaksutaan $y_{ij} | \mu_{ij}, \sigma^2 \sim N(\mu_{ij}, \sigma^2)$ ($i = 1, \dots, n; j = 1, 2, 3$) muista havainnoista ehdollisesti riippumatta siten, että odotusarvot riippuvat lineaarisesti ajan logaritmista:

$$\mu_{ij} = \alpha_i + \beta_i[\log(t_{ij}/730)], \quad i = 1, \dots, n; j = 1, 2, 3.$$

Regressiokertoimien oletetaan noudattavan seuraavia malleja

$$\alpha_i | \mu_\alpha, \sigma_\alpha^2 \sim N(\mu_\alpha, \sigma_\alpha^2), \quad \beta_i | \mu_\beta, \sigma_\beta^2 \sim N(\mu_\beta, \sigma_\beta^2), \quad i = 1, \dots, n,$$

toisistaan ehdollisesti riippumatta. Kaikki tarvittavat hyperpriorijakaumat määritetään latteiksi: odotusarvoille $N(0, 10^{-6})$ ja tarkkuuksille Gamma($10^{-3}, 10^{-3}$) toisistaan riippumatta.



Simuloinnin jälkeen saatiaan seuraavat tulokset, jossa `sigma`, `sigma.alpha`, `sigma.beta` viittaa vastaavien varianssien σ^2 , σ_α^2 , σ_β^2 neliöjuuriin.

```
Iterations = 1:10000
Thinning interval = 1
Number of chains = 1
Sample size per chain = 10000
```

1. Empirical mean and standard deviation for each variable,
plus standard error of the mean:

	Mean	SD	Naive SE	Time-series SE
<code>mu.alpha</code>	6.0358	0.19216	0.0019216	0.002328
<code>mu.beta</code>	-1.0528	0.12890	0.0012890	0.013653
<code>sigma</code>	1.0035	0.05659	0.0005659	0.001480
<code>sigma.alpha</code>	1.8617	0.14850	0.0014850	0.001884
<code>sigma.beta</code>	0.2071	0.16612	0.0016612	0.020800

2. Quantiles for each variable:

	2.5%	25%	50%	75%	97.5%
<code>mu.alpha</code>	5.65730	5.90952	6.0377	6.1647	6.4087
<code>mu.beta</code>	-1.29419	-1.13819	-1.0617	-0.9663	-0.8017
<code>sigma</code>	0.90172	0.96479	1.0008	1.0386	1.1175
<code>sigma.alpha</code>	1.60107	1.75944	1.8558	1.9525	2.1707
<code>sigma.beta</code>	0.02917	0.07757	0.1565	0.2944	0.6091

- (a) Piirrä suunnattu, syklitön vuokaavio eli DAG, joka havainnollistaa graafisesti näiden oletusten määrittelemän mallikokonaisuuden elementit ja niiden keskinäiset suhteet.
- (b) Kirjoita Jags-skripti, jolla tämän mallin parametrien posteriorijakaumaa voidaan simuloida.
- (c) Tulkitse sanallisesti mallin sisältö sekä saadut tulokset. Kommentoi erityisesti regressiokertoimille α_i ja β_i tehtyjä oletuksia ja miten niitä voi tässä tilanteessa perustella verrattuna ajateltavissa oleviin vaihtoehtoihin, kuten siihen että $\alpha_i = \alpha$ ja $\beta_i = \beta$, $i = 1, \dots, n$, tai että kaikki α_i :t ja β_i :t olisivat toisistaan täysin erillisiä parametreja.

Ntzoufras, I. (2009) Bayesian Modeling Using WinBUGS. Wiley, Hoboken NJ.

Table 3.3 Functions available in WinBUGS

WinBUGS Syntax	Function	Description
1. abs(x)	$ x $	Absolute value
2. cloglog(x)	$\log(-\log(1-x))$	Complementary log-log function
3. cos(x)	$\cos(x)$	Cosine function
4. cut(x)		Posterior of x is not updated by the likelihood
5. equals(x1, x2)	$f(x_1, x_2) = 1 \text{ when } x_1 = x_2$ $= 0 \text{ otherwise}$	Binary indicator function for equal nodes
6. exp(x)	e^x	Exponent value
7. inprod(v1[], v2[])	$\sum_i v_{1i}v_{2i}$	Inner product of two vectors
8. interp.lin(x, v1[], v2[])	$v_{2i} + (v_{2,i+1} - v_{2i})$ $\times (x - v_{1i}) / (v_{1,i+1} - v_{1i})$	Interpolation line
8. inverse(M[,])	A^{-1}	Inverse of a symmetric positive-definite matrix
9. log(x)	$\log(x)$	Logarithm (ln)
10. logdet(M[,])	$\log A $	Logarithm of the determinant of a symmetric positive-definite matrix
11. logfact(k)	$\log(k!)$	Log factorial function of an integer
12. loggam(x)	$\log(\Gamma(x))$	Log gamma function
13. logit(x)	$\log \frac{x}{1-x}$	Logit function
14. max(x1, x2)	$\max(x_1, x_2)$	Maximum of two values
15. mean(v[])	$\bar{v} = \sum_{i=1}^n v_i/n$, where n is the length of vector v	Sample mean
16. min(x1, x2)	$\min(x_1, x_2)$	Minimum of two values
17. phi(x)	$P(X \leq x)$, $X \sim N(0, 1)$	CDF of standardized normal
18. pow(x, z)	x^z	Power function
19. sin(x)	$\sin(x)$	Sine function
20. sqrt(x)	\sqrt{x}	Square root
21. rank(v[], k)	$\sum_i I(v_i \leq v_k)$, where $I(z) = 1$ if z true and 0 otherwise	Rank of s component of a vector
22. ranked(v[], k)	$v_i : \sum_s I(v_s \leq v_i) = k$	Element of a vector with rank s
23. round(x)		Round to the closest integer
24. sd(v[])	$\sqrt{\sum_{i=1}^n (v_i - \bar{v})^2 / (n-1)}$	Sample standard deviation
25. step(x)	$f(x) = 1 \text{ when } x \geq 0; 0 \text{ otherwise}$	Binary indicator function of positive nodes
26. sum(v[])	$\sum_i v_i$	Sum of a vector's components
27. trunc(x)		Truncation to the closest smaller than x integer

Key: x , z = single real value or logical or mathematical expression; k = single integer value; v = vector; M = matrix.

Ntzoufras, I. (2009). Bayesian Modeling Using WinBUGS. Wiley, Hoboken, NJ.

Table 3.1 Univariate distributions available in WinBUGS

Distribution name	WinBUGS syntax	Probability or density function $f(x)$	Mean	Variance
Discrete distributions				
Continuous distributions				
(1) Bernoulli	$x \sim \text{dbern}(p)$	$p^x(1-p)^{1-x}$	p	$p(1-p)$
(2) Binomial	$x \sim \text{dbin}(p, n)$	$n!p^x(1-p)^{n-x}/[x!(n-x)!]$	np	$np(1-p)$
(3) Categorical	$x \sim \text{dcat}(p[])$	p_x	$\sum_{x=1}^K xp_x$	$\sum_{x=1}^K [x - E(x)]^2 p_x$
(4) Negative binomial	$x \sim \text{dnegbin}(p, r)$	$(x+r-1)!p^r(1-p)^x/[x!(r-1)!]$	$r(1-p)/p$	$r(1-p)/p^2$
(5) Poisson	$x \sim \text{dpois}(lambda)$	$\exp(-\lambda)\lambda^x/x!$	λ	λ
Continuous distributions				
(6) Beta	$x \sim \text{dbeta}(a, b)$	$\Gamma(a+b)x^{a-1}(1-x)^{b-1}/[\Gamma(a)\Gamma(b)]$	$a/(a+b)$	$a/[a+b]^2(a+b+1)$
(7) Chi-squared	$x \sim \text{dchisqr}(k)$	See Gamma($k/2, \frac{1}{2}$)	k	$2k$
(8) Double exponential	$x \sim \text{ddexp}(mu, tau)$	$\frac{1}{2}\tau \exp(-\tau x-\mu)$	μ	$\sqrt{2}/\tau$
(9) Exponential	$x \sim \text{dexp}(lambda)$	$\lambda e^{-\lambda x}$	$1/\lambda$	$1/\lambda^2$
(10) Gamma	$x \sim \text{dgamma}(a, b)$	$b^a x^{a-1} e^{-bx}/\Gamma(a)$	a/b	a/b^2
(11) Generalized gamma	$x \sim \text{gen.gamma}(a, b, r)$	$r b(bx)^{ra-1} \exp[-(bx)^r]/\Gamma(a)$	$\Gamma(a+1/r)/[b\Gamma(a)]$	$[\Gamma(a+2/r^2)\Gamma(a) - \Gamma(a+1/r)^2]/[\lambda\Gamma(a)]^2$
(12) Log-normal	$x \sim \text{dlnorm}(mu, tau)$	$\sqrt{\tau}/(2\pi)x^{-1} \exp\left[-\tau/2(\log x - \mu)^2\right]$	$e^{\mu+1/(2\tau)}$	$(e^{1/\tau}-1)e^{2\mu+1/\tau}$
(13) Logistic	$x \sim \text{dlogis}(mu, tau)$	$\tau e^{\tau(x-\mu)} [1 + e^{\tau(x-\mu)}]^{-2}$	μ	$\pi^2/[3\tau^2]$
(14) Normal	$x \sim \text{dnorm}(mu, tau)$	$\sqrt{\tau}/(2\pi) \exp[-\tau(x-\mu)^2/2]$	μ	$1/\tau$
(15) Pareto	$x \sim \text{dpar}(a, c)$	$a c^a x^{-a-1} \sqrt{\tau}/[(2\pi)[\Gamma(v/2)]^{-1}]$	$ab/(a-1)$	$ab^2/[(a-1)^2(a-2)]$
(16) Student's t	$x \sim \text{dt}(mu, tau, v)$	$\Gamma[(v+1)/2] \sqrt{\tau}/[(2\pi)[\Gamma(v/2)]^{-1}] \times [1 + \tau v^{-1}(x-\mu)^2]^{-(v+1)/2}$	μ	$v\tau^{-1}/(v-2)$
(17) Uniform	$x \sim \text{unif}(a, b)$	$1/(b-a)$	$\frac{1}{2}(a+b)$	$\frac{1}{12}(b-a)^2$
(18) Weibull	$x \sim \text{dweib}(v, lambda)$	$v \lambda x^{v-1} \exp(-\lambda x^v)$	$\lambda^{-1/v} \Gamma(1+v^{-1})$	$[\Gamma(1+2v^{-1}) - \Gamma(1+v^{-1})]^2 \lambda^{-2/v}$

Key: $p \in (0, 1)$; (1) $x = 0, 1, \dots, n$, $p \in (0, 1)$; (2) x is a vector of dimension K , $x = 1, 2, \dots, K$ and elements $p[x] = p_x \in (0, 1)$, $\sum_{x=1}^K p_x = 1$; (4) $x = 0, 1, 2, \dots; r = 1, 2, \dots$; (5) $x = 0, 1, 2, \dots; \lambda > 0$; (6) $x \in (0, 1), a, b > 0$; (8) $x \in \mathbb{R}, \tau > 0$; (9) $x > 0, \lambda > 0$; (10, 11) $x > 0, a, b, r > 0$; (12) $x > 0, \mu \in \mathbb{R}, \tau > 0$; (13, 14, 16) $x \in \mathbb{R}, \mu \in \mathbb{R}, \tau > 0$; (15) $x > c, a, b > 0$; (17) $x \in (a, b), a, b \in \mathbb{R}, a < b$; (18) $x > 0, v, \lambda > 0$.

Table 3.2 Multivariate distributions available in WinBUGS

Distribution name	WinBUGS syntax	Probability or density function $f(x)$	Mean	Variance/covariance
Discrete distributions				
(19) Multinomial	$x[1:K] \sim dmult(p[], N)$	$N! \left(\prod_{i=1}^K x_i! \right)^{-1} \prod_{i=1}^K p_i^{x_i}$	$E(X_i) = Np_i$	$V(X_i) = Np_i(1 - p_i)$
Continuous distributions				
(20) Dirichlet	$x[1:K] \sim ddirch(a[])$	$\Gamma(a) \left[\prod_{i=1}^K \Gamma(a_i) \right]^{-1} \prod_{i=1}^K x_i^{a_i - 1}$	$E(X_i) = a_i/a$	$V(X_i) = a_i(a - a_i)/[a^2(a + 1)]$
(21) Multivariate normal	$x[1:K] \sim dnorm(mu[], T[,])$	$(2\pi)^{-K/2} T ^{1/2} \exp \left[-\frac{1}{2} (x - \mu)^T T(x - \mu) \right]$	$\text{Cov}(X_i, X_j) = -a_i a_j / [a^2(a + 1)]$	$V(\mathbf{X}) = T^{-1}$
(22) Multivariate Student's t	$x[1:K] \sim dmt(mu[], T[,], v)$	$\left\{ (v\pi)^{-K/2} \Gamma[(v+K)/2] T ^{1/2} / \Gamma(v/2) \right\} \times \left[1 + v^{-1} (x - \mu)^T T(x - \mu) \right]^{-(v+K)/2}$	$E(\mathbf{X}) = \mu$	$V(\mathbf{X}) = v(v - 2)^{-1} T^{-1}$
(23) Wishart	$x[1:K, 1:K] \sim dwish(R[,], v)$	$ R ^{v/2} x ^{(v-K-1)/2} \exp \left[-\frac{1}{2} \text{Tr}(Rx) \right]$	$E(X_{ij}) = vA_{ij}$	$\text{Cov}(X_{ij}, X_{km}) = v(A_{ik}A_{jm} + A_{im}A_{jk})$
<p>Key: (19) $x[]$ and $p[]$ are vectors of dimension K with elements $x[i] = x_i = 0, 1, 2, \dots$ and $p[i] = p_i \in (0, 1)$ with $\sum_{i=1}^K x_i = N$ and $\sum_{i=1}^K p_i = 1$; (20) $x[]$ and $a[]$ are vectors of dimension K with elements $x[i] = x_i \in (0, 1)$ and $a[i] = a_i > 0$ with $\sum_{i=1}^K x_i = 1$ and $a = \sum_{i=1}^K a_i$; (21, 22) $x[]$ and $mu[]$ (x and μ) are vectors of dimension K with elements $x[i] = x_i \in (0, 1)$ and $\mu[i] = \mu_i \in \mathbb{R}$. $T[]$ (and R) is a $K \times K$ symmetric precision matrix with elements $T[i, j] = \tau_{ij} > 0$; $v > 0$; (23) $x[]$ and $R[]$ (x and R) are $K \times K$ positive-definite (symmetric) matrices with elements $x[i, j] = x_{ij}$ and $R[i, j] = R_{ij}$; A_{ij} are the element of the matrix $A = R^{-1}$; $v > 0$. Also μ_i: mean of X_i; $V(X_i)$, $\text{Cov}(X_i, X_i)$: variance of X_i; $\text{Cov}(X_i, X_j)$: covariance between X_i and X_j.</p>				