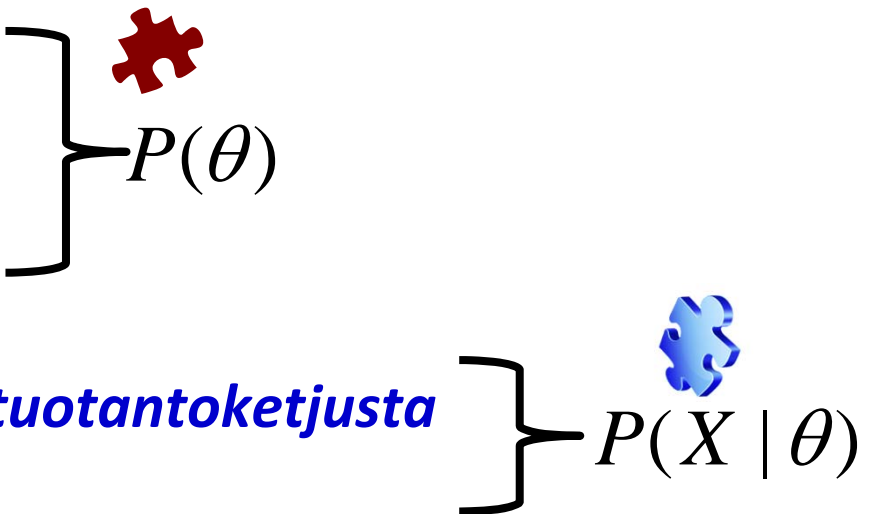



Muuttuvan kokonaissensitiivisyyden mallinnus valvontaohjelman riskinarvioinnissa - esimerkkinä munintaparvet

Tausta:

- Aiemmat salmonellaprojektit, FoodBUG-projekti, ja uusi malli munintaparville (2008).
- EFSA WG: salmonella munintaparvissa. Samaa mallia sovellettiin tässä (2010).
- Ratkaisematta tuolloin jäi muuttuvan sensitiivisyyden ongelma. → vielä yksi lisärakenne aiempaan malliin.

Mallin ideana evidenssin synteesi:

- **Kokeellinen data**
 - **Oletukset ja asiantuntija-arviot**
 - ***Havaintoaineisto tutkittavasta tuotantoketjusta***
- 

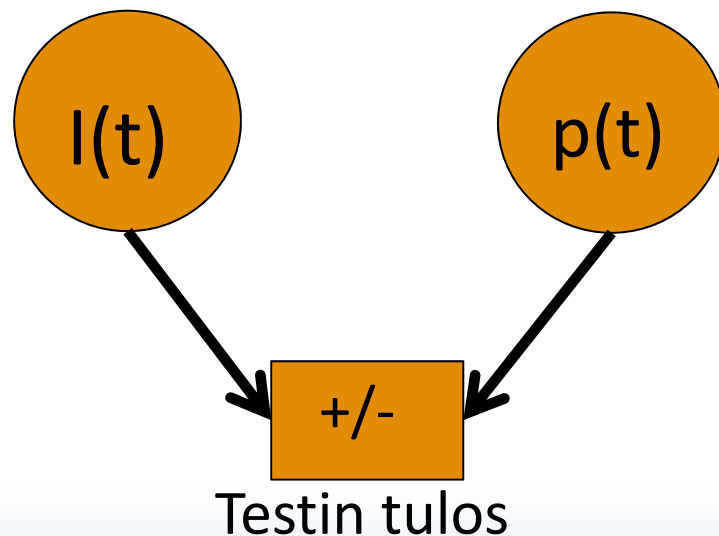


$$P(\theta | X) = \frac{P(X | \theta)P(\theta)}{\int_{\Theta} P(X | \theta)P(\theta)d\theta}$$



Positiivisten munintaparvien löytyminen

- $I(t)$ = parven inf. status hetkellä t : $I(t) = 1$ tai 0 .
- t = aika munintajakson alusta laskien.
- $p(t)$ = kokonaissensitiivisyys hetkellä t .
- Testitulokset D_1, D_2, D_3, \dots testaushetkinä t_1, t_2, t_3, \dots



$I(t)$ = Markov-prosessi,
Intensiteetein λ ja μ .

$p(t)$ muuttuu parven sisäisen
epidemian mukana.

Aiempi oletus:
 $p(t) = p$, vakio.

Markov-prosessi parven todelliselle infektiostatukselle $I(t)$:

Siirtymätodennäköisyydet parvelle: $0 \rightarrow 1$, ja $1 \rightarrow 0$

$$p_{01} = P(I_t = 1 | I_0 = 0, \lambda, \mu) = \frac{\lambda}{\lambda + \mu} - \frac{\lambda}{\lambda + \mu} \exp(-(\lambda + \mu)t)$$

$$p_{10} = P(I_t = 1 | I_0 = 1, \lambda, \mu) = \frac{\lambda}{\lambda + \mu} + \frac{\mu}{\lambda + \mu} \exp(-(\lambda + \mu)t)$$

Ratkaistaan todennäköisyys todelliselle infektiolle, testihetkellä t .
Ratkaisu on rekursiivinen (Nagelkerke *et al.*, 1990):

$$\rho_t = \begin{cases} \frac{(1-p)[(1-p_{01}-p_{10})\rho_{t-1} + p_{01}]}{1-p[(1-p_{01}-p_{10})\rho_{t-1} + p_{01}]}, & t > 1 \\ \frac{(1-p)P(I_1 = 1)}{(1-p)P(I_1 = 1) + P(I_1 = 0)}, & t = 1 \end{cases}$$

Edellä: $\rho_t = P(I_t = 1 | D_1, \dots, D_t)$, riippuu havaintohistoriasta.

Jos $D_t = 1$, niin $I_t = 1$, mutta tavallisesti $D_1 = 0, \dots, D_t = 0$

Mitä tiedetään sensitiivisyydestä $p(t)$?

- EFSA report: *"the rate of transmission of Salmonella within a flock determines the change in within-flock prevalence, which, in turn determines when a colonised flock can be detected"*.
- Jos parvi on vasta juuri infektoitunut, toteaminen ei todennäköistä.
- 2-4 viikkoa infektiosta, toteaminen varmempaa. (parven sisäinen prevalenssi > 5%).
- Myöhemmin, toteaminen riippuu tilanteesta, (salmonellan erittäminen vähenee tai vaihtelee, sopeutuminen, muita vaikuttavia tekijöitä?)

Mitä tiedetään sensitiivisyydestä $p(t)$?


- EFSA report: *"most hens stop shedding the bacteria after approximately three weeks"*.
 - AND: *"over time the number of organisms excreted by infected birds, and as a consequence, the within-flock prevalence, may decrease"*.
- Yksinkertaistaen, tätä voisi kuvata funktiolla joka riippuu **infektion kestosta** parvessa.
 - Kestoaika riippuu infektion alkuhetkestä. Tämä on tuntematon parametri τ_0 .

- Sensitiivisyys kestoajan funktiona, $d = t - \tau_0$?

- Yksinkertainen funktio:

$$P(\oplus_t | \tau_0, I_t = 1) = p(d) = \begin{cases} 0 & , \text{if } d < d_1 \\ p^* & , \text{if } d_1 < d < d_2 \\ 0 & , \text{if } d > d_2 \end{cases}$$

- Sensitiivisyys hetkellä t (=parven ikä), saadaan integroimalla yli tuntemattoman alkuhetken τ_0 .



$$P(\oplus_t | I_t = 1) = \int_0^t P(\oplus_t | \tau_0, I_t = 1) \pi(\tau_0 | I_t = 1) d\tau_0$$

$$\Rightarrow \frac{p^* e^{-\mu t}}{1 - e^{-\mu t}} (e^{\mu \max\{t-d_1, 0\}} - e^{\mu \max\{t-d_2, 0\}})$$

$p^* = 1, \mu = 0.1, 1, 10,$
 $d_1 = 2/52, d_2 = 8/52, d_2 = \infty$

- Sensitiivisyys kestoajan funktiona, $d = t - \tau_0$?

- Mikä funktio?

$$P(\oplus_t | \tau_0, I_t = 1) = p(d) = \begin{cases} 0 & , \text{if } d < d_1 \\ p^* & , \text{if } d_1 < d < d_2 \\ 0 & , \text{if } d > d_2 \end{cases} \quad \text{porrasfunktio}$$

$$P(\oplus_t | \tau_0, I_t = 1) = p(d) = p^* e^{-0.5(d-a)^2 / \sigma^2} \quad \text{Gaussinen funktio}$$

$$P(\oplus_t | \tau_0, I_t = 1) = p(d) = p^* (1 - e^{-ad}) \quad \text{Eksponentiaalinen nousu}$$

$$P(\oplus_t | \tau_0, I_t = 1) = p(d) = p^* (1 - e^{-ad}) e^{-a \max\{d-d^*, 0\}} \quad \text{Eksponentiaalinen nousu \& lasku}$$

Kriteereitä:


- Tulisi heijastaa oletuksia.
- Tulisi olla yksinkertainen (helppo integroida).
- Mahdollisimman vähän parametreja.
- Parametreilla tulkinta (asiantuntija-arviot).
- Voisi estimoida kokeellisesta datasta, jos joskus saatavilla.

- Sensitiivisyys kestoajan funktiona, $d = t - \tau_0$?

– Esim. Gaussinen funktio:

$$P(\oplus_t | I_t = 1) =$$

$$\frac{p^* \mu}{1 - e^{-\mu t}} e^{-0.5(a^2 - (a - \mu\sigma^2)^2) / \sigma^2} \sqrt{2\pi\sigma} [\Phi((t - a + \mu\sigma^2) / \sigma) - \Phi((-a + \mu\sigma^2) / \sigma)]$$

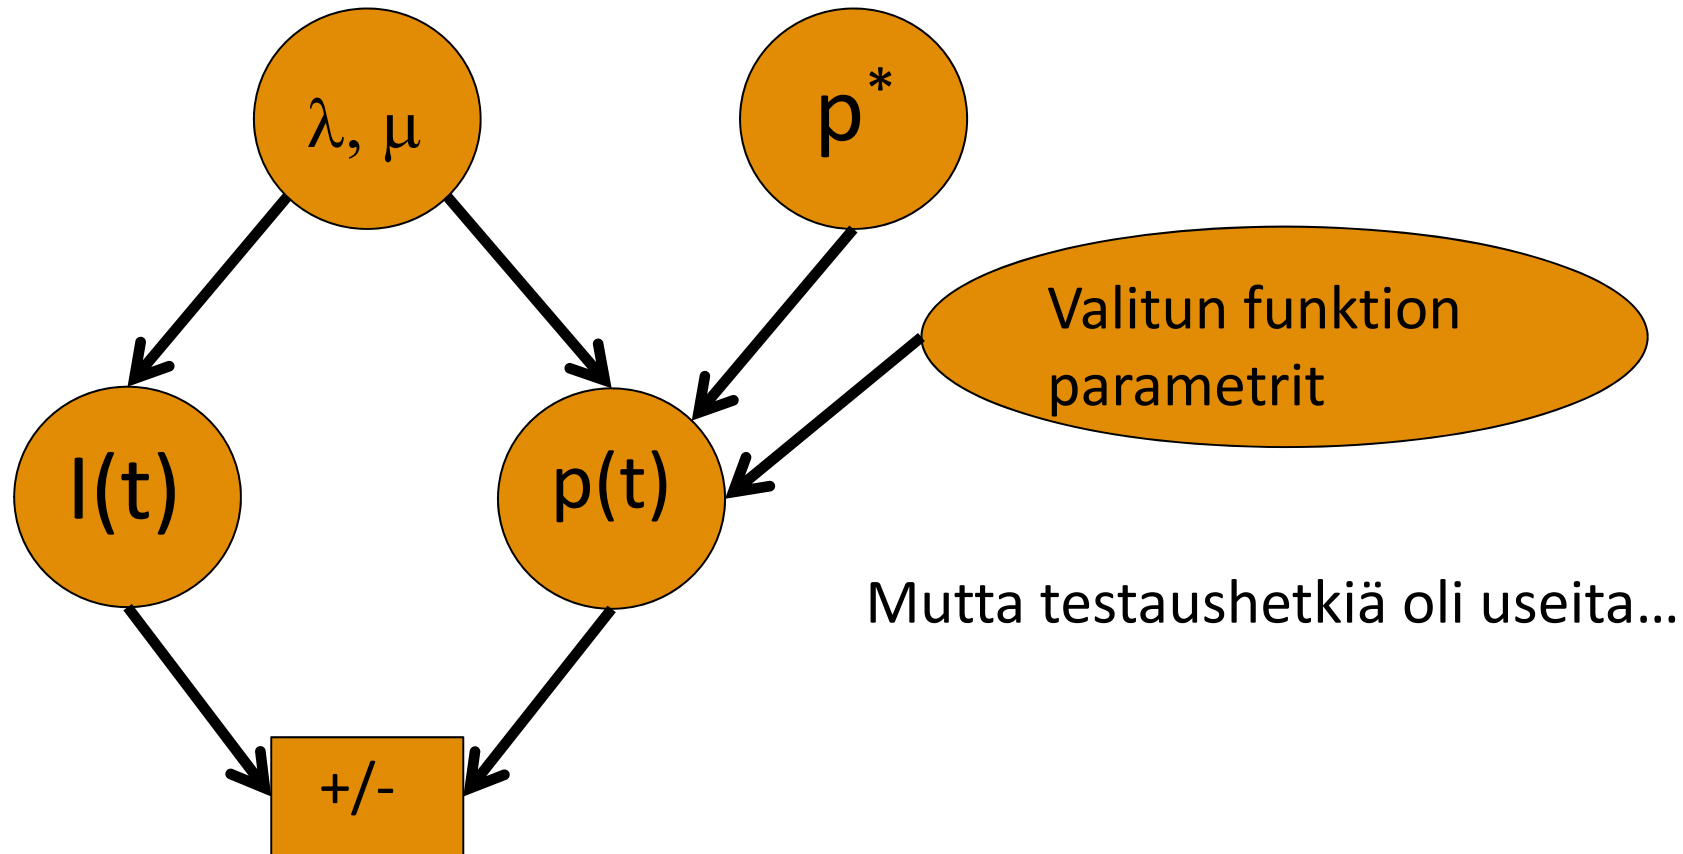


19.3.2012, RA-seminaari

weeks

$p^* = 1$, $a = 4/52$, $a = 10/52$
 $\sigma = 10/52$,
 $\mu = 0.1, 1, 10$

- DAG-kaavio, datana yhden testin tulos:



- Aiemmat testitulokset sisältävät **evidenssiä** siitä mikä τ_0 todennäköisesti oli, ehdolla että $I(t)=1$.
- Tuloshistoria on sarja negatiivisia tuloksia (*positiiviset parvet hävitetään*).
- Lasketaan $p(t)$ aikahetkellä t joka on 1. ja 2. testaushetkien t_1 ja t_2 välissä, esim. Gaussisella funktiolla:



$$P(\tau_0 | I_t = 1) \propto \begin{cases} e^{-(t-\tau_0)\mu} (1 - p^* e^{-0.5(t_1-\tau_0-a)^2/\sigma^2}) & , \text{if } \tau_0 \in [0, t_1] \\ e^{-(t-\tau_0)\mu} & , \text{if } \tau_0 \in [t_1, t], t < t_2 \end{cases}$$
- Enemmän testejä → enemmän paloja!
- Tarvitaan numeerista integrointia.

- Edellisen ratkaisu tarvitaan tämän laskemiseen:

$$P(\oplus_t | I_t = 1) = \int_0^t P(\oplus_t | \tau_0, I_t = 1) \pi(\tau_0 | I_t = 1) d\tau_0$$

- Tämäkin vaatii numeerista integrointia.
- OpenBUGS tarjoaa välineen:
`result <- integral(F(),start,end,accuracy)`

- **Koetuloksia:** 4 testiä munintakaudella, $p^* = 0.95$, $d^* \sim U(1\text{vk},5\text{vk})$, oletus: kaikki testit negatiivisia



	mean	val2.5pc	val97.5pc
$P(I(t_1)=1)$	0.1438 %	0.01179 %	0.4832 %
$P(I(t_2)=1)$	0.1261 %	0.01433 %	0.3727 %
$P(I(t_3)=1)$	0.1679 %	0.01367 %	0.57 %
$P(I(t_4)=1)$	0.2206 %	0.01395 %	0.7905 %

	mean	val2.5pc	val97.5pc
$P(I(t_1)=1)$	0.1184 %	0.007416 %	0.4092 %
$P(I(t_2)=1)$	0.07394 %	0.009393 %	0.2122 %
$P(I(t_3)=1)$	0.04733 %	0.003843 %	0.1608 %
$P(I(t_4)=1)$	0.04281 %	0.001838 %	0.155 %