

Odhad parametrů v hybridních systémech

Martin Dungl

27.06.2011

Prezentace bude složena ze dvou částí

- Online filtering for hybrid systems - Presentation in Rome
- Aplikace teorie systémů hromadné obsluhy

Online Filtering For Hybrid Systems

Evgenia Suzdaleva¹, Ivan Nagy² and Martin Dungl¹

¹Department of Adaptive Systems
Institute of Information Theory and Automation
of the Academy of Sciences of the Czech Republic

²Faculty of Transportation Sciences, Czech Technical University, Prague



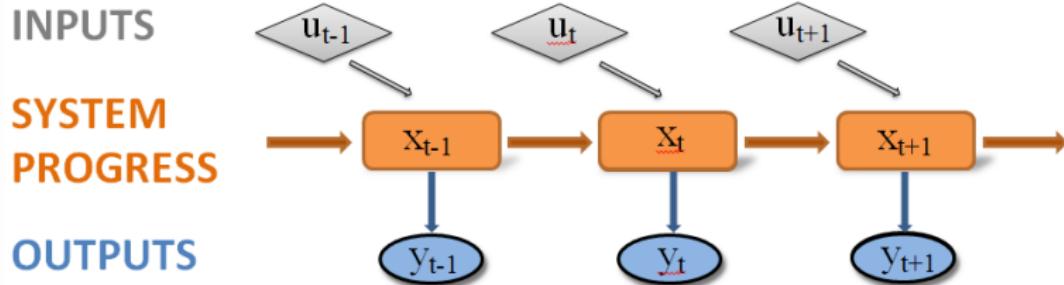
Outline of the presentation

- Motivation and problem formulation
- General probabilistic solution
- Recursive filter for normal and multinomial models
- Experiment
- Conclusion

System example



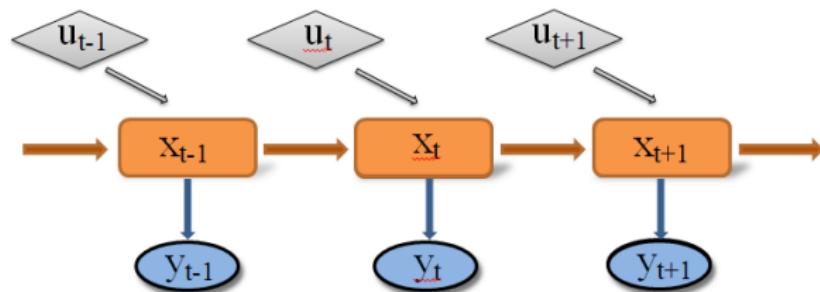
System illustration



Question: What is going on in the system?

System illustration

INPUTS
SYSTEM
PROGRESS
OUTPUTS



Question: What is going on in the system?

Problem formulation

Hybrid system

- State of the hybrid system in time $t \in \{1, \dots, T\}$:

$$x_t = [x_t^c, x_t^d]' = [x_{1,t}^c, \dots, x_{C,t}^c, x_t^d]'$$

- Superscript c – continuous variables, d – discrete variables

Available data

$u_t = [u_t^c, u_t^d]'$... system inputs in time t ,

$y_t = [y_t^c, y_t^d]'$... system outputs in time t ,

The Goal

Estimate of x_t based on $(y_1, \dots, y_t, u_1, \dots, u_t) = d^t$

- *online filtering*.



Problem formulation

Hybrid system

- State of the hybrid system in time $t \in \{1, \dots, T\}$:

$$x_t = [x_t^c, x_t^d]' = [x_{1,t}^c, \dots, x_{C,t}^c, x_t^d]'$$

- Superscript c – continuous variables, d – discrete variables

Available data

$u_t = [u_t^c, u_t^d]'$... system inputs in time t ,

$y_t = [y_t^c, y_t^d]'$... system outputs in time t ,

The Goal

Estimate of x_t based on $(y_1, \dots, y_t, u_1, \dots, u_t) = d^t$
- *online filtering*.

Problem formulation

Hybrid system

- State of the hybrid system in time $t \in \{1, \dots, T\}$:

$$x_t = [x_t^c, x_t^d]' = [x_{1,t}^c, \dots, x_{C,t}^c, x_t^d]'$$

- Superscript c – continuous variables, d – discrete variables

Available data

$u_t = [u_t^c, u_t^d]'$... system inputs in time t ,

$y_t = [y_t^c, y_t^d]'$... system outputs in time t ,

The Goal

Estimate of x_t based on $(y_1, \dots, y_t, u_1, \dots, u_t) = d^t$
- online filtering.

State-space model and Bayesian filtering

- Generally, a state-space model consists of two models:

observation model $f(y_t | x_t, u_t),$

state evolution model $f(x_{t+1} | x_t, u_t).$

- Basic facts:

- Data updating (derived using Bayes' theorem):

$$\begin{aligned} f(x_t | d^t) &= \frac{f(y_t | x_t, u_t) f(x_t | d^{t-1})}{\int_{x^*} f(y_t | x_t, u_t) f(x_t | d^{t-1}) dx_t} \\ &\propto f(y_t | x_t, u_t) f(x_t | d^{t-1}), \end{aligned}$$

- Time updating (from the Law of total probability):

$$f(x_{t+1} | d^t) = \int_{x^*} f(x_{t+1} | x_t, u_t) f(x_t | d^t) dx_t$$

State-space model and Bayesian filtering

- Generally, a state-space model consists of two models:

observation model $f(y_t | x_t, u_t),$

state evolution model $f(x_{t+1} | x_t, u_t).$

- Basic facts:

- Data updating (derived using Bayes' theorem):

$$\begin{aligned} f(x_t | d^t) &= \frac{f(y_t | x_t, u_t) f(x_t | d^{t-1})}{\int_{x^*} f(y_t | x_t, u_t) f(x_t | d^{t-1}) dx_t} \\ &\propto f(y_t | x_t, u_t) f(x_t | d^{t-1}), \end{aligned}$$

- Time updating (from the Law of total probability):

$$f(x_{t+1} | d^t) = \int_{x^*} f(x_{t+1} | x_t, u_t) f(x_t | d^t) dx_t$$

State-space model and Bayesian filtering

- Generally, a state-space model consists of two models:

$$\begin{array}{ll} \textit{observation model} & f(y_t | x_t, u_t), \\ \textit{state evolution model} & f(x_{t+1} | x_t, u_t). \end{array}$$

- Basic facts:

- Data updating (derived using Bayes' theorem):

$$\begin{aligned} f(x_t | d^t) &= \frac{f(y_t | x_t, u_t) f(x_t | d^{t-1})}{\int_{x^*} f(y_t | x_t, u_t) f(x_t | d^{t-1}) dx_t} \\ &\propto f(y_t | x_t, u_t) f(x_t | d^{t-1}), \end{aligned}$$

- Time updating (from the Law of total probability):

$$f(x_{t+1} | d^t) = \int_{x^*} f(x_{t+1} | x_t, u_t) f(x_t | d^t) dx_t$$

State-space model and Bayesian filtering

- Generally, a state-space model consists of two models:

$$\begin{array}{ll} \textit{observation model} & f(y_t | x_t, u_t), \\ \textit{state evolution model} & f(x_{t+1} | x_t, u_t). \end{array}$$

- Basic facts:

- Data updating (derived using Bayes' theorem):

$$\begin{aligned} f(x_t | d^t) &= \frac{f(y_t | x_t, u_t) f(x_t | d^{t-1})}{\int_{x^*} f(y_t | x_t, u_t) f(x_t | d^{t-1}) dx_t} \\ &\propto f(y_t | x_t, u_t) f(x_t | d^{t-1}), \end{aligned}$$

- Time updating (from the Law of total probability):

$$f(x_{t+1} | d^t) = \int_{x^*} f(x_{t+1} | x_t, u_t) f(x_t | d^t) dx_t$$

State-space model and Bayesian filtering

- Generally, a state-space model consists of two models:

$$\begin{array}{ll} \textit{observation model} & f(y_t | x_t, u_t), \\ \textit{state evolution model} & f(x_{t+1} | x_t, u_t). \end{array}$$

- Basic facts:

- Data updating (derived using Bayes' theorem):

$$\begin{aligned} f(x_t | d^t) &= \frac{f(y_t | x_t, u_t) f(x_t | d^{t-1})}{\int_{x^*} f(y_t | x_t, u_t) f(x_t | d^{t-1}) dx_t} \\ &\propto f(y_t | x_t, u_t) f(x_t | d^{t-1}), \end{aligned}$$

- Time updating (from the Law of total probability):

$$f(x_{t+1} | d^t) = \int_{x^*} f(x_{t+1} | x_t, u_t) f(x_t | d^t) dx_t$$

Online filtering - general case

- Together:

$$f(x_{t+1} | d^t) \propto \int f(x_{t+1} | x_t, u_t) \left\{ \underbrace{f(y_t | x_t, u_t) f(x_t | d^{t-1})}_{\propto f(x_t | d^t)} \right\} dx_t. \quad (1)$$

- $f(x_t | d^{t-1})$ stands for the *prior distribution*.

Hybrid system decomposition

- Decomposition of *observation* and *state evolution models*

$$\begin{aligned} f(y_t|x_t, u_t) &= f(y_t^c, y_t^d|x_t^c, x_t^d, u_t^c, u_t^d) \\ f(x_{t+1}|x_t, u_t) &= f(x_{t+1}^c, x_{t+1}^d|x_t^c, x_t^d, u_t^c, u_t^d) \end{aligned}$$

- Chain rule: $f(a, b|c) = f(a|b, c)f(b|c)$
- Models after using chain rule and reasonable omissions:

$$f(y_t|x_t, u_t) = f(y_t^c|y_t^d, x_t^c, u_t^c)f(y_t^d|x_t^d, u_t^d) \quad (2)$$

$$f(x_{t+1}|x_t, u_t) = f(x_{t+1}^c|x_{t+1}^d, x_t^c, u_t^c)f(x_{t+1}^d|x_t^d, u_t^d). \quad (3)$$

- Prior distribution:

$$f(x_t^c, x_t^d|d^{t-1}) = f(x_t^c|x_t^d, d^{t-1})f(x_t^d|d^{t-1}) \quad (4)$$

Hybrid system decomposition

- Decomposition of *observation* and *state evolution models*

$$\begin{aligned} f(y_t|x_t, u_t) &= f(y_t^c, y_t^d|x_t^c, x_t^d, u_t^c, u_t^d) \\ f(x_{t+1}|x_t, u_t) &= f(x_{t+1}^c, x_{t+1}^d|x_t^c, x_t^d, u_t^c, u_t^d) \end{aligned}$$

- Chain rule: $f(a, b|c) = f(a|b, c)f(b|c)$
- Models after using chain rule and reasonable omissions:

$$f(y_t|x_t, u_t) = f(y_t^c|y_t^d, x_t^c, u_t^c)f(y_t^d|x_t^d, u_t^d) \quad (2)$$

$$f(x_{t+1}|x_t, u_t) = f(x_{t+1}^c|x_{t+1}^d, x_t^c, u_t^c)f(x_{t+1}^d|x_t^d, u_t^d). \quad (3)$$

- Prior distribution:

$$f(x_t^c, x_t^d|d^{t-1}) = f(x_t^c|x_t^d, d^{t-1})f(x_t^d|d^{t-1}) \quad (4)$$

Hybrid system decomposition

- Decomposition of *observation* and *state evolution models*

$$\begin{aligned} f(y_t|x_t, u_t) &= f(y_t^c, y_t^d|x_t^c, x_t^d, u_t^c, u_t^d) \\ f(x_{t+1}|x_t, u_t) &= f(x_{t+1}^c, x_{t+1}^d|x_t^c, x_t^d, u_t^c, u_t^d) \end{aligned}$$

- Chain rule: $f(a, b|c) = f(a|b, c)f(b|c)$
- Models after using chain rule and reasonable omissions:

$$f(y_t|x_t, u_t) = f(y_t^c|y_t^d, x_t^c, u_t^c)f(y_t^d|x_t^d, u_t^d) \quad (2)$$

$$f(x_{t+1}|x_t, u_t) = f(x_{t+1}^c|x_{t+1}^d, x_t^c, u_t^c)f(x_{t+1}^d|x_t^d, u_t^d). \quad (3)$$

- Prior distribution:

$$f(x_t^c, x_t^d|d^{t-1}) = f(x_t^c|x_t^d, d^{t-1})f(x_t^d|d^{t-1}) \quad (4)$$

Hybrid system decomposition

- Decomposition of *observation* and *state evolution models*

$$f(y_t|x_t, u_t) = f(y_t^c, y_t^d|x_t^c, x_t^d, u_t^c, u_t^d)$$

$$f(x_{t+1}|x_t, u_t) = f(x_{t+1}^c, x_{t+1}^d|x_t^c, x_t^d, u_t^c, u_t^d)$$

- Chain rule: $f(a, b|c) = f(a|b, c)f(b|c)$
- Models after using chain rule and reasonable omissions:

$$f(y_t|x_t, u_t) = f(y_t^c|y_t^d, x_t^c, u_t^c)f(y_t^d|x_t^d, u_t^d) \quad (2)$$

$$f(x_{t+1}|x_t, u_t) = f(x_{t+1}^c|x_{t+1}^d, x_t^c, u_t^c)f(x_{t+1}^d|x_t^d, u_t^d). \quad (3)$$

- Prior distribution:

$$f(x_t^c, x_t^d|d^{t-1}) = f(x_t^c|x_t^d, d^{t-1})f(x_t^d|d^{t-1}) \quad (4)$$

Hybrid system decomposition

- Decomposition of *observation* and *state evolution models*

$$f(y_t|x_t, u_t) = f(y_t^c, y_t^d|x_t^c, x_t^d, u_t^c, u_t^d)$$

$$f(x_{t+1}|x_t, u_t) = f(x_{t+1}^c, x_{t+1}^d|x_t^c, x_t^d, u_t^c, u_t^d)$$

- Chain rule: $f(a, b|c) = f(a|b, c)f(b|c)$
- Models after using chain rule and reasonable omissions:

$$f(y_t|x_t, u_t) = f(y_t^c|y_t^d, x_t^c, u_t^c)f(y_t^d|x_t^d, u_t^d) \quad (2)$$

$$f(x_{t+1}|x_t, u_t) = f(x_{t+1}^c|x_{t+1}^d, x_t^c, u_t^c)f(x_{t+1}^d|x_t^d, u_t^d). \quad (3)$$

- Prior distribution:

$$f(x_t^c, x_t^d|d^{t-1}) = f(x_t^c|x_t^d, d^{t-1})f(x_t^d|d^{t-1}) \quad (4)$$

Online filtering - hybrid systems:

- Substituting models for hybrid systems ((3), (2) and (4)) into the general result (1), one obtains

$$\begin{aligned}
 f(x_{t+1}|d^t) &\propto \int_{x^{c*}} \sum_{x^{d*}} \underbrace{f(x_{t+1}^c|x_{t+1}^d, x_t^c, u_t^c)}_{f(x_{t+1}|x_t, u_t)} \underbrace{f(x_{t+1}^d|x_t^d, u_t^d)}_{f(x_{t+1}|x_t, d^{t-1})} \\
 &\times \underbrace{f(y_t^c|y_t^d, x_t^c, u_t^c)}_{f(y_t|x_t, u_t)} \underbrace{f(y_t^d|x_t^d, u_t^d)}_{f(x_t^d|d^{t-1})} \underbrace{f(x_t^c|x_t^d, d^{t-1})}_{prior\ pdf} dx_t^c \\
 &= \underbrace{\sum_{x^{d*}} f(x_{t+1}^d|d^t) f(x_{t+1}^c|x_{t+1}^d, d^t)}_{sum\ of\ distributions} \tag{5}
 \end{aligned}$$

- Sum of distributions is difficult to work with (for the use in recursion) - approximation by Kerridge inaccuracy (later)

Online filtering - hybrid systems:

- Substituting models for hybrid systems ((3), (2) and (4)) into the general result (1), one obtains

$$\begin{aligned}
 f(x_{t+1}|d^t) &\propto \int_{x^{c*}} \sum_{x^{d*}} \underbrace{f(x_{t+1}^c|x_{t+1}^d, x_t^c, u_t^c)}_{f(x_{t+1}|x_t, u_t)} \underbrace{f(x_{t+1}^d|x_t^d, u_t^d)}_{f(x_{t+1}|x_t, d^{t-1})} \\
 &\times \underbrace{f(y_t^c|y_t^d, x_t^c, u_t^c)}_{f(y_t|x_t, u_t)} \underbrace{f(y_t^d|x_t^d, u_t^d)}_{f(x_t^d|d^{t-1})} \underbrace{f(x_t^c|x_t^d, d^{t-1})}_{prior\ pdf} dx_t^c \\
 &= \underbrace{\sum_{x^{d*}} f(x_{t+1}^d|d^t) f(x_{t+1}^c|x_{t+1}^d, d^t)}_{sum\ of\ distributions} \quad (5)
 \end{aligned}$$

- Sum of distributions is difficult to work with (for the use in recursion) - approximation by Kerridge inaccuracy (later)

Normal and multinomial models

Suppose the following distributions of variables:

y_t^c K-dimensional normal distribution

y_t^d one-dimensional multinomial distribution

x_t^c C-dimensional normal distribution

x_t^d one-dimensional multinomial distribution

- This choice is very universal

Normal and multinomial models

Suppose the following distributions of variables:

y_t^c K-dimensional normal distribution

y_t^d one-dimensional multinomial distribution

x_t^c C-dimensional normal distribution

x_t^d one-dimensional multinomial distribution

- This choice is very universal

Normal and multinomial models

- Substituting into (2) we get the observation model as the product of distributions:

$$f(y_t^c | y_t^d, x_t^c, u_t^c) f(y_t^d | x_t^d, u_t^d) = \mathcal{N}(Hx_t^c + Du_t^c, R_v) \alpha_{y_t^d | x_t^d u_t^d}$$

where $\alpha_{y_t^d=q|x_t^d=l, u_t^d=n}$ are known probabilities of output

$y_t^d = q$ under conditions of $x_t^d = l$ and $u_t^d = n$, and it holds

$$\sum_q^Q \alpha_{q|ln} = 1, \quad \alpha_{q|ln} \geq 0 \quad \forall q, l, n \text{ and } Q.$$

- The state evolution model (3) is in form

$$f(y_t^c | y_t^d, x_t^c, u_t^c) f(y_t^d | x_t^d, u_t^d) = \mathcal{N}(Hx_t^c + Du_t^c, R_v) \alpha_{y_t^d | x_t^d u_t^d}$$

where $\alpha_{y_t^d=q|x_t^d=l, u_t^d=n}$ are known probabilities of output

$y_t^d = q$ under conditions of $x_t^d = l$ and $u_t^d = n$, and it holds

$$\sum_q^Q \alpha_{q|ln} = 1, \quad \alpha_{q|ln} \geq 0 \quad \forall q, l, n \text{ and } Q.$$

Normal and multinomial models

- Substituting into (2) we get the observation model as the product of distributions:

$$f(y_t^c | y_t^d, x_t^c, u_t^c) f(y_t^d | x_t^d, u_t^d) = \mathcal{N}(Hx_t^c + Du_t^c, R_v) \alpha_{y_t^d | x_t^d u_t^d}$$

where $\alpha_{y_t^d=q|x_t^d=l, u_t^d=n}$ are known probabilities of output

$y_t^d = q$ under conditions of $x_t^d = l$ and $u_t^d = n$, and it holds

$$\sum_q^Q \alpha_{q|ln} = 1, \quad \alpha_{q|ln} \geq 0 \quad \forall q, l, n \text{ and } Q.$$

- The state evolution model (3) is in form

$$f(y_t^c | y_t^d, x_t^c, u_t^c) f(y_t^d | x_t^d, u_t^d) = \mathcal{N}(Hx_t^c + Du_t^c, R_v) \alpha_{y_t^d | x_t^d u_t^d}$$

where $\alpha_{y_t^d=q|x_t^d=l, u_t^d=n}$ are known probabilities of output

$y_t^d = q$ under conditions of $x_t^d = l$ and $u_t^d = n$, and it holds

$$\sum_q^Q \alpha_{q|ln} = 1, \quad \alpha_{q|ln} \geq 0 \quad \forall q, l, n \text{ and } Q.$$

Choice of prior distributions

- The prior distributions (4) $f(x_t^c | x_t^d, d^{t-1})f(x_t^d | d^{t-1})$ are specialized as

$$\mathcal{N}(\mu_{t|t-1}, P_{t|t-1})p_{x_t^d(t)}$$

- This is a product of
 - C -dimensional prior normal distribution with initial mean value $\mu_{t|t-1}$ and covariance $P_{t|t-1}$
 - Multinomial distribution in the form of the prior probability $p_{x_t^d = l(t)}$ of $x_t^d = l$, where $\sum_l^L p_{l(t)} = 1$, $p_{l(t)} \geq 0 \forall l$.

Choice of prior distributions

- The prior distributions (4) $f(x_t^c | x_t^d, d^{t-1})f(x_t^d | d^{t-1})$ are specialized as

$$\mathcal{N}(\mu_{t|t-1}, P_{t|t-1})p_{x_t^d(t)}$$

- This is a product of
 - C -dimensional prior normal distribution with initial mean value $\mu_{t|t-1}$ and covariance $P_{t|t-1}$
 - Multinomial distribution in the form of the prior probability $p_{x_t^d = l(t)}$ of $x_t^d = l$, where $\sum_l^L p_{l(t)} = 1$, $p_{l(t)} \geq 0 \forall l$.

Choice of prior distributions

- The prior distributions (4) $f(x_t^c|x_t^d, d^{t-1})f(x_t^d|d^{t-1})$ are specialized as

$$\mathcal{N}(\mu_{t|t-1}, P_{t|t-1})p_{x_t^d(t)}$$

- This is a product of
 - C -dimensional prior normal distribution with initial mean value $\mu_{t|t-1}$ and covariance $P_{t|t-1}$
 - Multinomial distribution in the form of the prior probability $p_{x_t^d=I(t)}$ of $x_t^d = I$, where $\sum_I^L p_{I(t)} = 1$, $p_{I(t)} \geq 0 \forall I$.

Filter for normal and multinomial models

- The solution for normal models computationally coincides with the Kalman filter
 - We get the Kalman filter run for each value of x_t^d .
- The solution for multinomial models takes the form

$$p_{x_{t+1}^d}(t) = \beta_{l|1n} \alpha_{q|1n} p_1(t) + \beta_{l|2n} \alpha_{q|2n} p_2(t) + \dots + \beta_{l|Ln} \alpha_{q|Ln} p_L(t)$$

- The mixture distribution (5) has the form

$$\sum_{l=1}^L p_{l(t+1)} \mathcal{N}_l(\mu_{t+1|t}, P_{t+1|t}).$$

Filter for normal and multinomial models

- The solution for normal models computationally coincides with the Kalman filter
 - We get the Kalman filter run for each value of x_t^d .
- The solution for multinomial models takes the form

$$p_{x_{t+1}^d(t)} = \beta_{I|1n} \alpha_{q|1n} p_1(t) + \beta_{I|2n} \alpha_{q|2n} p_2(t) + \dots + \beta_{I|Ln} \alpha_{q|Ln} p_L(t)$$

- The mixture distribution (5) has the form

$$\sum_{l=1}^L p_{I(t+1)} \mathcal{N}_I(\mu_{t+1|t}, P_{t+1|t}).$$

Filter for normal and multinomial models

- The solution for normal models computationally coincides with the Kalman filter
 - We get the Kalman filter run for each value of x_t^d .
- The solution for multinomial models takes the form

$$p_{x_{t+1}^d(t)} = \beta_{I|1n} \alpha_{q|1n} p_1(t) + \beta_{I|2n} \alpha_{q|2n} p_2(t) + \dots + \beta_{I|Ln} \alpha_{q|Ln} p_L(t)$$

- The mixture distribution (5) has the form

$$\sum_{l=1}^L p_{I(t+1)} \mathcal{N}_I(\mu_{t+1|t}, P_{t+1|t}).$$

Filter for normal and multinomial models

- The solution for normal models computationally coincides with the Kalman filter
 - We get the Kalman filter run for each value of x_t^d .
- The solution for multinomial models takes the form

$$p_{x_{t+1}^d(t)} = \beta_{I|1n} \alpha_{q|1n} p_1(t) + \beta_{I|2n} \alpha_{q|2n} p_2(t) + \dots + \beta_{I|Ln} \alpha_{q|Ln} p_L(t)$$

- The mixture distribution (5) has the form

$$\sum_{l=1}^L p_{I(t+1)} \mathcal{N}_I(\mu_{t+1|t}, P_{t+1|t}).$$

Kerridge inaccuracy approximation

- This mixture distribution is replaced by the approximated normal distribution based on Kerridge inaccuracy with

$$\hat{\mu}_{t+1|t} = \sum_{l=1}^L p_{l(t+1)} \mu_{l,t+1|t}, \quad (6)$$

$$\hat{P}_{t+1|t} = \sum_{l=1}^L p_{l(t+1)} P_{l,t+1|t} + \sum_{l=1}^L p_{l(t+1)} (\hat{\mu}_{t+1|t} - \mu_{l,t+1|t})^2 \quad (7)$$

where $\mu_{l,t+1}$ and $P_{l,t+1}$ denote results of the Kalman filter obtained for each value l . The approximation (6)-(7) is then used as the prior normal distribution for the next step of the recursion.

Experiment

- Testing of the algorithm for real traffic-control data from one of the controlled microregions in Prague
- Comparison of results with those of the Hidden Markov Models (HMM) algorithms available in standard package of MATLAB.

Experiment

- Testing of the algorithm for real traffic-control data from one of the controlled microregions in Prague
- Comparison of results with those of the Hidden Markov Models (HMM) algorithms available in standard package of MATLAB.

Used data

- x_t^c - four-dimensional queue length of cars
- x_t^d - level of service (LoS) with 4 possible values: from 1 (the best) to 4 (the worst)
- y_t^c - four-dimensional intensity of outgoing cars measured by a detector
- u_t^c - relative time of green light
- $t = 1, \dots, 288$ - one day, 5 minutes long intervals

Used data

- x_t^c - four-dimensional queue length of cars
- x_t^d - level of service (LoS) with 4 possible values: from 1 (the best) to 4 (the worst)
- y_t^c - four-dimensional intensity of outgoing cars measured by a detector
- u_t^c - relative time of green light
- $t = 1, \dots, 288$ - one day, 5 minutes long intervals

Used data

- x_t^c - four-dimensional queue length of cars
- x_t^d - level of service (LoS) with 4 possible values: from 1 (the best) to 4 (the worst)
- y_t^c - four-dimensional intensity of outgoing cars measured by a detector
- u_t^c - relative time of green light
- $t = 1, \dots, 288$ - one day, 5 minutes long intervals

Results and comparison with HMM

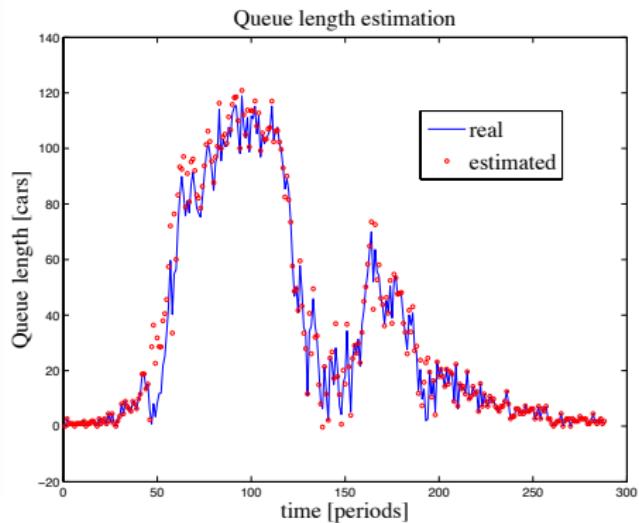


Figure: Online filtering of car queue length

Results and comparison with HMM

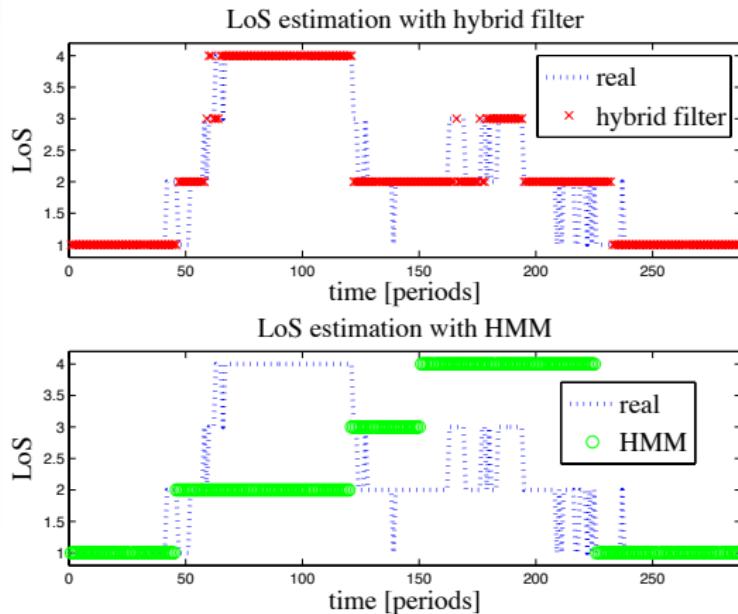


Figure: LoS estimation with the hybrid filter (top) and the HMM (bottom)

Conclusion

To summarize, important features of the proposed theory are that

- the algorithms used run in online mode,
- numerical procedures are applied only in that parts, which can not be computed analytically. In this way the amount of computations as well as the risk of collapsing is minimized,
- general probabilistic approach is universal for the distributions used,
- it opens a way to recursive estimation of discrete system modes dependent on evolution of continuous states. This is planned for future research.

Questions

**Thank you for your attention.
Time for your questions.**

Modely hromadné obsluhy

Martin Dungl

27.06.2011

Obsah

1 Úvod

2 Trocha teorie

- Procesy se spojitým časem
- Poissonův proces
- Systémy hromadné obsluhy a fronty typu $M/M/\infty$
- Fronty typu $M/M/s$

3 Závěr

Obsah

1 Úvod

2 Trocha teorie

- Procesy se spojitým časem
- Poissonův proces
- Systémy hromadné obsluhy a fronty typu $M/M/\infty$
- Fronty typu $M/M/s$

3 Závěr

Obsah

1 Úvod

2 Trocha teorie

- Procesy se spojitým časem
- Poissonův proces
- Systémy hromadné obsluhy a fronty typu $M/M/\infty$
- Fronty typu $M/M/s$

3 Závěr

Fenomén call center

Čerpám z článku pojednávajícího o call centrech, lze nalézt mnoho podobností s některými systémy. Něco o call centrech:

- Pro mnoho společností se jedná o preferovanou cestu komunikace se zákazníky
- V USA a Velké Británii příbuzná odvětví zaměstnávají asi 3% pracovní síly
- Zajímavá jsou pro nás call centra zaměřená na příchozí hovory
- V případě, že jsou všichni agenti zaneprázdněni, čekají další zákazníci, kteří se dovolali, ve frontě.

Fenomén call center

Čerpám z článku pojednávajícího o call centrech, lze nalézt mnoho podobností s některými systémy. Něco o call centrech:

- Pro mnoho společností se jedná o preferovanou cestu komunikace se zákazníky
- V USA a Velké Británii příbuzná odvětví zaměstnávají asi 3% pracovní síly
- Zajímavá jsou pro nás call centra zaměřená na příchozí hovory
- V případě, že jsou všichni agenti zaneprázdněni, čekají další zákazníci, kteří se dovolali, ve frontě.

Úspěchy

Křížovatka může být *skoro plná*, a stále funguje bez velkých front. Alespoň, lze-li nalézt analogie:

- Ve velkých call centrech telefonují agenti asi 90-95% svého pracovního času
- Asi 50% zákazníků je spojeno přímo s agentem. Ostatní se zařadí do fronty, s agentem jsou však spojeni během několika vteřin.
- Jen 1% zákazníků, kteří se dovolají, ukončí hovor před spojením s agentem.

Úspěchy

Křížovatka může být *skoro plná*, a stále funguje bez velkých front. Alespoň, lze-li nalézt analogie:

- Ve velkých call centrech telefonují agenti asi 90-95% svého pracovního času
- Asi 50% zákazníků je spojeno přímo s agentem. Ostatní se zařadí do fronty, s agentem jsou však spojeni během několika vteřin.
- Jen 1% zákazníků, kteří se dovolají, ukončí hovor před spojením s agentem.

Modelování systému

- Obecně hovoříme o systémech hromadné obsluhy nebo o teorii front.
- Má-li čas mezi dvěma vstupy do systému exponenciální rozdělení, lze použít aparát markovských řetězců se spojitým časem
- Toto zjednodušení může být problematické

Outline

1 Úvod

2 Trocha teorie

- Procesy se spojitým časem
- Poissonův proces
- Systémy hromadné obsluhy a fronty typu $M/M/\infty$
- Fronty typu $M/M/s$

3 Závěr

Procesy se spojitym časem

Základní definice

Definice:

Markovovým řetězcem se spojitym časem a spočetnou množinou stavů S rozumíme systém celočíselných náhodných veličin $\{X_t, t \geq 0\}$, které jsou definovány na stejném pravděpodobnostním prostoru a pro které platí

$$P(X_{s+t} = j | X_s = i) = P(X_{s+t} = j | X_s = i, (X_{t_1}, \dots, X_{t_n}) = (i_1, \dots, i_n))$$

pro všechna $n \in \mathbb{N}$, $i, j, i_1, \dots, i_n \in S$, $s, t > 0$, $0 \leq t_k < s$, pro která má pravá strana rovnice smysl. Zavádíme značení

$$P(X_{s+t} = j | X_s = i) = p_{ij}(s, s + t)$$

Procesy se spojitým časem

Předpoklady

- Předpokládáme homogenitu, tj. $p_{ij}(s, s + t)$ nezávisí na s . Značíme $p_{ij}(t)$. Odtud definujeme pro každé $t > 0$ matici pravděpodobností přechodu $\mathbf{P}(t)$ s prvky $p_{ij}(t)$.
- Lze dokázat, že $q_{ij} = \lim_{t \rightarrow 0_+} \frac{p_{ij}(t)}{t}$ a $q_i = \lim_{t \rightarrow 0_+} \frac{1 - p_{ij}(t)}{t}$ existují pro každé $i, j \in S$. Dále předpokládáme, že platí $\sum_{j \neq i} q_{ij} = q_i$ pro každé $i \in S$.
- Číslo q_{ij} nazýváme *Intenzita přechodu ze stavu i do stavu j* . Položíme $q_{ii} = -q_i$ pro $i \in S$. Matici $\mathbf{Q} = \{q_{ij}, i, j \in S\}$ nazýváme *Matice intenzit přechodu*.

Procesy se spojitym časem

Význam matice intenzit přechodu

- Označme T_i dobu, po kterou zůstává řetězec ve stavu i poté, co do něj v nějakém (libovolném) čase vstoupil. Lze dokázat, že T_i je náhodná veličina, která má exponenciální rozdělení o parametru q_i . Platí tedy $P(T_i < t) = 1 - e^{-q_i t}$ a $\mathbf{E}[T_i] = \frac{1}{q_i}$.

Procesy se spojitým časem

Limitní rozdělení

- Existuje-li pro všechna $i, j \in S$ $\lim_{t \rightarrow \infty} p_{ij}(t) = a_j$, nazýváme $\boldsymbol{a} = \{a_j, j \in S\}$ *limitní rozdělení řetězce*.
- Mějme nerozložitelný Markovův řetězec $\{X_t, t \geq 0\}$ s trvalými stavy, který má matici intenzit \boldsymbol{Q} . Jestliže existuje

$$\boldsymbol{\pi} = \{\pi_j, \sum_{j \in S} \pi_j = 1\} \quad : \quad \boldsymbol{\pi}^T \boldsymbol{Q} = 0,$$

jedná se o limitní rozdělení tohoto řetězce. Jestliže takové $\boldsymbol{\pi}$ neexistuje, nemá řetězec limitní rozdělení.

Procesy se spojitým časem

Limitní rozdělení

- Existuje-li pro všechna $i, j \in S$ $\lim_{t \rightarrow \infty} p_{ij}(t) = a_j$, nazýváme $\boldsymbol{a} = \{a_j, j \in S\}$ limitní rozdělení řetězce.
- Mějme nerozložitelný Markovův řetězec $\{X_t, t \geq 0\}$ s trvalými stavy, který má matici intenzit \mathbf{Q} . Jestliže existuje

$$\boldsymbol{\pi} = \{\pi_j, \sum_{j \in S} \pi_j = 1\} \quad : \quad \boldsymbol{\pi}^T \mathbf{Q} = 0,$$

jedná se o limitní rozdělení tohoto řetězce. Jestliže takové $\boldsymbol{\pi}$ neexistuje, nemá řetězec limitní rozdělení.

Procesy se spojitým časem

Limitní rozdělení

- Existuje-li pro všechna $i, j \in S$ $\lim_{t \rightarrow \infty} p_{ij}(t) = a_j$, nazýváme $\boldsymbol{a} = \{a_j, j \in S\}$ limitní rozdělení řetězce.
- Mějme nerozložitelný Markovův řetězec $\{X_t, t \geq 0\}$ s trvalými stavy, který má matici intenzit \mathbf{Q} . Jestliže existuje

$$\boldsymbol{\pi} = \{\pi_j, \sum_{j \in S} \pi_j = 1\} \quad : \quad \boldsymbol{\pi}^T \mathbf{Q} = 0,$$

jedná se o limitní rozdělení tohoto řetězce. Jestliže takové $\boldsymbol{\pi}$ neexistuje, nemá řetězec limitní rozdělení.

Outline

1 Úvod

2 Trocha teorie

- Procesy se spojitým časem
- **Poissonův proces**
- Systémy hromadné obsluhy a fronty typu $M/M/\infty$
- Fronty typu $M/M/s$

3 Závěr

Poissonův proces

Definice a význam

- Modelový příklad náhodného procesu.
- Události se vyskytují náhodně v čase, na sobě nezávisle.
 X_t značí počet událostí, ke kterým došlo do času t .
- Lze jimi modelovat chování zákazníků, např. takto lze popsat množství hovorů přicházejících na ústřednu.
- Předpokládáme, že v intervalu $(t, t + h]$ dojde k právě jedné události s pravděpodobností $\lambda h + o(h)$, $\lambda > 0$, a k více než jedné události s pravděpodobností $o(h)$.

Poissonův proces

Vlastnosti

- Poissonův proces lze popsat maticí intenzit

$$\mathbf{Q} = \begin{pmatrix} -\lambda & \lambda & 0 & 0 & \dots \\ 0 & -\lambda & \lambda & 0 & \dots \\ 0 & \ddots & \ddots & \ddots & \ddots \end{pmatrix}.$$

- Lze dokázat, že pro absolutní pravděpodobnosti v čase t platí

$$p_j(t) = \frac{e^{-\lambda t} (\lambda t)^j}{j!}, \quad 0 \leq j < \infty, \quad t > 0.$$

Počet událostí v libovolné množině délky t má tedy Poissonovo rozdělení s parametrem λt .

Outline

1 Úvod

2 Trocha teorie

- Procesy se spojitým časem
- Poissonův proces
- Systémy hromadné obsluhy a fronty typu $M/M/\infty$
- Fronty typu $M/M/s$

3 Závěr

Systémy hromadné obsluhy

Předpoklady

- Do systému přicházejí zákazníci, po obslužení jej opouštějí.
- V systému existuje s tzv. stanic obsluhy, s je pevné, $s \in \mathbb{N} \cup \infty$. Každá stanice může obsluhovat nejvýše jednoho zákazníka.
- Pro popis některých systémů se hodí volit $s \in \mathbb{R}_+$ udávající kapacitu systému.
- Doby mezi příchody po sobě jdoucích zákazníků jsou nezávislé exponenciálně rozdělené náhodné veličiny, stejně jako doby obsluhy jednotlivých zákazníků.
- Je-li kapacita zaplněna, tvoří zákazníci frontu.

Matematický popis

- Systém popisuje trojice $A/B/s$, kde A udává rozdělení doby mezi příchody zákazníků, B udává rozdělení doby obsluhy jednotlivých zákazníků a s je počet stanic obsluhy
- Uvažujeme případ $A \in \text{Exp}(\lambda)$ a $B \in \text{Exp}(\mu)$.

Matematický popis

- Systém popisuje trojice $A/B/s$, kde A udává rozdělení doby mezi příchody zákazníků, B udává rozdělení doby obsluhy jednotlivých zákazníků a s je počet stanic obsluhy
- Uvažujeme případ $A \in \text{Exp}(\lambda)$ a $B \in \text{Exp}(\mu)$.

Matematický popis

- Systém popisuje trojice $A/B/s$, kde A udává rozdělení doby mezi příchody zákazníků, B udává rozdělení doby obsluhy jednotlivých zákazníků a s je počet stanic obsluhy
- Uvažujeme případ $A \in \text{Exp}(\lambda)$ a $B \in \text{Exp}(\mu)$.

Fronty typu $M/M/\infty$

Matice intenzit přechodu

- Nejprve nechť $s = \infty$.
- Pro matici intenzit přechodu \mathbf{Q} platí

$$\mathbf{Q} = \begin{pmatrix} -\lambda & \lambda & 0 & 0 & 0 & \dots \\ \mu & -\lambda - \mu & \lambda & 0 & 0 & \dots \\ 0 & 2\mu & -\lambda - 2\mu & \lambda & 0 & \dots \\ 0 & 0 & 3\mu & -\lambda - 3\mu & \lambda & \ddots \\ \vdots & \vdots & \ddots & \ddots & \ddots & \ddots \end{pmatrix}.$$

Fronty typu $M/M/\infty$

Limitní rozdělení - výsledek

- Lze dokázat, že limitní rozdělení počtu zákazníků v systému má Poissonovo rozdělení s parametrem $\frac{\lambda}{\mu}$.

Outline

1 Úvod

2 Trocha teorie

- Procesy se spojitým časem
- Poissonův proces
- Systémy hromadné obsluhy a fronty typu $M/M/\infty$
- Fronty typu $M/M/s$

3 Závěr

Fronty typu $M/M/s$

Matice intenzit přechodu

- Prvních s řádků a sloupců matice intenzit se neliší od předchozí matice:

$$\mathbf{Q} = \begin{pmatrix} -\lambda & \lambda & 0 & 0 & 0 & \dots \\ \mu & -\lambda - \mu & \lambda & 0 & 0 & \dots \\ 0 & 2\mu & -\lambda - 2\mu & \lambda & 0 & \dots \\ 0 & 0 & 3\mu & -\lambda - 3\mu & \lambda & \ddots \\ \vdots & \vdots & \ddots & \ddots & \ddots & \ddots \end{pmatrix}.$$

Následující řádky vypadají následovně:

$$(0 \ 0 \ \dots \ \dots \ 0 \ s\mu \ -\lambda - s\mu \ \lambda \ 0 \ \dots \ \dots).$$

Fronty typu $M/M/s$

Limitní rozdělení

- Pro výpočet limitního rozdělení dostáváme

$$\pi_i = \frac{\pi_0 (\frac{\lambda}{\mu})^i}{i!} \quad i = 0, 1, \dots, s$$

$$\pi_i = \frac{\pi_0 s^s}{s!} \left(\frac{\frac{\lambda}{\mu}}{s} \right)^i \quad i = s+1, s+2, \dots$$

- π_0 se pak vypočítá z následujícího vztahu:

$$\pi_0 \left(\sum_{i=0}^s \frac{\left(\frac{\lambda}{\mu}\right)^i}{i!} + \sum_{i=s+1}^{\infty} \frac{s^s}{s!} \left(\frac{\frac{\lambda}{\mu}}{s} \right)^i \right) = 1$$

Fronty typu $M/M/s$

Limitní rozdělení

- Pro výpočet limitního rozdělení dostáváme

$$\pi_i = \frac{\pi_0 \left(\frac{\lambda}{\mu}\right)^i}{i!} \quad i = 0, 1, \dots, s$$

$$\pi_i = \frac{\pi_0 s^s}{s!} \left(\frac{\lambda}{\mu}\right)^i \quad i = s+1, s+2, \dots$$

- π_0 se pak vypočítá z následujícího vztahu:

$$\pi_0 \left(\sum_{i=0}^s \frac{\left(\frac{\lambda}{\mu}\right)^i}{i!} + \sum_{i=s+1}^{\infty} \frac{s^s}{s!} \left(\frac{\lambda}{\mu}\right)^i \right) = 1$$

Fronty typu $M/M/s$

Kdy limitní rozdělení neexistuje

- Je vidno, že limitní rozdělení existuje, právě když $\frac{\lambda}{\mu} < s$.
- Existuje, právě když je v systému více stanic obsluhy, nežli střední hodnota počtu obsazených stanic v systému $M/M/\infty$ (při stejném λ a μ).

Fronty typu $M/M/s$

Chování systému - spočtěme:

- Střední počet zákazníků v systému:

$$M = \sum_{i=0}^{\infty} i\pi_i$$

- Střední délku fronty:

$$\mathbf{E}[F] = \sum_{i=s+1}^{\infty} (s-i)\pi_i$$

- Střední počet obsluhovaných zákazníků

$$\mathbf{E}[B] = \sum_{i=0}^s i\pi_i + \sum_{i=s+1}^{\infty} s\pi_i = \frac{\lambda}{\mu}$$

Fronty typu $M/M/s$

Chování systému - spočtěme:

- Střední počet zákazníků v systému:

$$M = \sum_{i=0}^{\infty} i \pi_i$$

- Střední délku fronty:

$$\mathbf{E}[F] = \sum_{i=s+1}^{\infty} (s-i) \pi_i$$

- Střední počet obsluhovaných zákazníků

$$\mathbf{E}[B] = \sum_{i=0}^s i \pi_i + \sum_{i=s+1}^{\infty} s \pi_i = \frac{\lambda}{\mu}$$

Fronty typu $M/M/s$

Chování systému - spočtěme:

- Střední počet zákazníků v systému:

$$M = \sum_{i=0}^{\infty} i\pi_i$$

- Střední délku fronty:

$$\mathbf{E}[F] = \sum_{i=s+1}^{\infty} (s-i)\pi_i$$

- Střední počet obsluhovaných zákazníků

$$\mathbf{E}[B] = \sum_{i=0}^s i\pi_i + \sum_{i=s+1}^{\infty} s\pi_i = \frac{\lambda}{\mu}$$

Fronty typu $M/M/s$

Chování systému

- Pravděpodobnost, že nově příchozí zákazník nemusí čekat na obsluhu

$$P_N = \sum_{i=0}^{s-1} \pi_i$$

- Dále je zajímavé zjistit, za jak dlouho se dostane v průměru nově příchozí zákazník na řadu. Označme tuto veličinu DC (jako "doba cekání"). Platí:

$$\mathbf{E}[DC] = \mathbf{E}[DC\mathbb{I}_{F=0} + DC\mathbb{I}_{F=1} + DC\mathbb{I}_{F=2} + \dots]$$

Fronty typu $M/M/s$

Chování systému

- Pravděpodobnost, že nově příchozí zákazník nemusí čekat na obsluhu

$$P_N = \sum_{i=0}^{s-1} \pi_i$$

- Dále je zajímavé zjistit, za jak dlouho se dostane v průměru nově příchozí zákazník na řadu. Označme tuto veličinu DC (jako "doba cekání"). Platí:

$$\mathbf{E}[DC] = \mathbf{E}[DC\mathbb{I}_{F=0} + DC\mathbb{I}_{F=1} + DC\mathbb{I}_{F=2} + \dots]$$

Fronty typu $M/M/s$

Chování systému

- Úpravami dostaneme následující (hrůzný) vzorec:

$$\mathbf{E}[DC] = \sum_{i=1}^{\infty} \left(\pi_{s+i-1} \int_{t=0}^{\infty} t \frac{d \left[1 - \sum_{j=0}^{i-1} \frac{(s\mu t)^j e^{-s\mu t}}{j!} \right]}{dt} dt \right)$$

Fronty typu $M/M/s$

Simulace, položil jsem $\mu = 1$

λ	0.9	2.7	9	90	900	47
s	1	3	10	100	1000	50
$(\frac{\lambda}{\mu})$	0.9	0.9	0.9	0.9	0.9	0.94
M	9.0	10.05	15.02	91.95	900.05	55.90
$E[F]$	8.1	7.35	6.02	1.95	0.05	8.90
$E[B]$	0.9	2.7	9	90	900	47
P_N	0.1	0.1829	0.3313	0.7831	0.9994	0.4320
$E[DC]$	9.0	2.7236	0.6687	0.0217	0.0000	0.1901

- Lze postupovat zpětne - při znalosti výsledků, jako $\mathbf{E}[F]$, $\mathbf{E}[B]$, P_N a $\mathbf{E}[DC]$, lze odhadnout parametry systému (prvky matice intenzit přechodu).
- Tento odhad může sloužit k odhadu matic H, D, P z Kalmanova filtru, které považujeme v předchozí části za známé.
- Proveditelné až ad hoc podle parametrů systému
- Diskrétní veličiny mohou odpovídat obecnějším stavům systému - každý z nich je popsáný jinou maticí přechodu

Závěr

Děkuji za pozornost, prostor na Vaše otázky.