

# Aplikovaná matematika

# 1 Lyx

## Matematický editor Lyx

Lyx je matematický editor nad Latexem. Psaný text je programován a přeložen do výsledného formátu.

Výhody

- jednoduše píše hezkou matematiku
- výstup jak je, je perfektní
- naprosto stabilní - co teď napíšu, budu mít za 10 let

Nevýhody

- těžko se realizují vlastní formáty
- co píšu je sice dobře čitelné, ale jinak než bude
- musím si pamatovat klávesové zkratky
- někdy potíže s instalací nové verze

## Jak na to?

- Nejprve se instaluje Miktex - <https://miktex.org/download>  
To je překladač pro napsaný text. Lyx se ho chytne a používá ho.
- Dále se instaluje lyx - <https://www.lyx.org/Download>

Pozor: Download packages : on the fly - aby si sám stahoval package (je někde)

Pro windows (jiné neumím)

Lyx se instaluje v adresáři `c:\Program Files (x86)\`

a dále v adresáři `\AppData\Roaming\`, kde si uloží soubory, které je možno měnit uživatelsky.

# Menu

- `bind` → `user.bind` (možno zjistit, měnit nebo zadávat vlastní klávesové zkratky) !!! Pozor: **M = Alt**
- `ui` → `stdcontext.inc` (kontextové menu), `stdmenus.inc` (hlavní menu), `stdtoolbars.inc` (ikony) - tady se lze učit, jak napsat příkazy `lyx`.

!!! **PŮVODNÍ KLÁVESOVÉ ZKRATKY JSOU V**

`c:\Program Files (x86)\LyX 2.3\Resources\bind\`

**ZDE JE TAKÉ PŮVODNÍ OBSAH UI.**

Co chci změnit, nakopíruju do `user.bind` a změním (tady nic neměnit !!)

Hlavní soubor je `cua.bind` (myslím), pak `math.bind`

- zbytek už si snadno samo zjistíte :-)

Máme nainstalováno a co teď s tím?

Můžeme psát s použitím uvedených zkratek. Ale je ještě pár věcí okolo.

Kouknem krátce na menu:

Document (Change Tracking - opravy)

- Settings

- Document Class (volba formátu: paper, book atd.)

- Text Layout (odstavce, sloupce atd.)

- Page Layout (Portrait/Landscape, číslování stran)

- Page Margins (vlastní okraje)

- Language (jazyk pro korekce)

- PDF Properties (nastavení pdf výstupu)

- Float Placement (umístění float objektů)

Tools (zajímavé možnosti)

- Preferences
  - Editing → Shortcuts
  - Paths (možno nastavit pracovní adresář atd.)
  - File Handling (pro pokročilé)

## Základy pro vlastní psaní

Lze používat **klávesové zkratky** nebo **menu**:

Např. Alt+v+v - přeloží a ukáže psaný text (písmenko, které se má použít je podtrženo) ... nemusí se tolik pamatovat, je pomalejší.

Ctrl+M - matematika v řádku

Ctrl+Shift+M - matematika jako odstavec

Nadpisy: lze zadávat z otevíracího okénka těsně pod File - obsah záleží na formátu dokumentu v Document/Settings/Document Class

Vytvoření dokumentu (přelož a ukaž) - ikona s očima nebo Alt+v+v (tj. View/View [PDF (pdfLatex)])

Uložení pdf na disk - File/Export/PDF (pdfLatex) - uloží se do pracovního adresáře.

# Jak psát

- **Forma**

**název** – jednoznačný a přesně říkající o čem článek je

**jméno, afliace, kontakty** – mail (raději školní nebo pracovní), ORCID (často je zapotřebí)

**abstrakt** – má nalákat čtenáře (obvykle cca 200 slov – o čem článek je, jaké teoretické metody používáte, hlavní přínos článku, jaká data používáte)

**klíčová slova** - kvůli zařazení

**Úvod** – motivace – proč je tato úloha důležitá, proč to chceme řešit, jak to řeší ostatní (přehled literatury), jak my na to půjdeme a čím se liší náš přístup, struktura článku

**Preliminaries** - co je potřeba znát předem, označení

**Teoretické řešení** - jak se to dělá

**Experimenty** - že to funguje, porovnání s existujícími metodami, popis dat a experimentů, grafy s velkými písmeny, popis obrázků a tabulek

**Diskuze** – komentář k tomu, jak to dopadlo (co bylo cílem práce, co se povedlo, zlepšení oproti existujícím metodám, co se nepovedlo, potenciální využití, omezení řešení)

**Závěr** - o čem článek byl (3 klíčové body), hlavní přínosy řešení, plány do budoucna

**Literatura** - pozor na požadovaný formát



## • Obsah

Především je dobré pro své téma vybrat vhodný časopis (jestli se hodí, jaký má impakt atd.) a podívat se, jaká má pravidla, prohlédnout pár jejich článků a podle toho začít psát.

**ZÁKLADNÍ PRAVIDLO:** když chci psát, musím mít co napsat!

Tedy u každé věty, odstavce, kapitoly musím dobře rozmyslet,

- co chci napsat

- a pak jestli jsem skutečně napsal to, co jsem chtěl

- a jestli to také poznají čtenáři.

Neměly by se psát příliš komplikované věty (je to i důkaz toho, že nemám co psát a jen tak plkám).

Myšlenky by měly spojitě navazovat (ve větách i odstavcích) - zase je to důkaz toho, že mám co psát.

U delších textů je dobře si napsat osnovu a tu pak vyplňovat.

Když jsou s nějakou větou potíže, tak ji vynechat.

Když píšu dál, je potřeba kontrolovat je-li to v souladu s předešlým a případně předešlé přepisovat - stejné značení, názvy atd.

Vyhnout se hovorovým výrazům. U každé věty zkontrolovat, jestli má smysl - obsahem i formou.

Dát pozor na citace – pokud používám cizí metody, musím na ně vždy v textu odkázat.

Nakonec to celé pečlivě přečíst, jestli tam nejsou chyby.

## 2 Data

### Náhodná veličina

Veličina  $x$ , jejíž hodnoty se při měření i za stejných podmínek mění.

Má konstantní charakteristiky (střední hodnota, rozptyl)

### Náhodný proces

Náhodná veličina indexovaná časem  $x_t$

### Typy náhodných procesů

hodnoty: diskrétní  $\times$  spojité

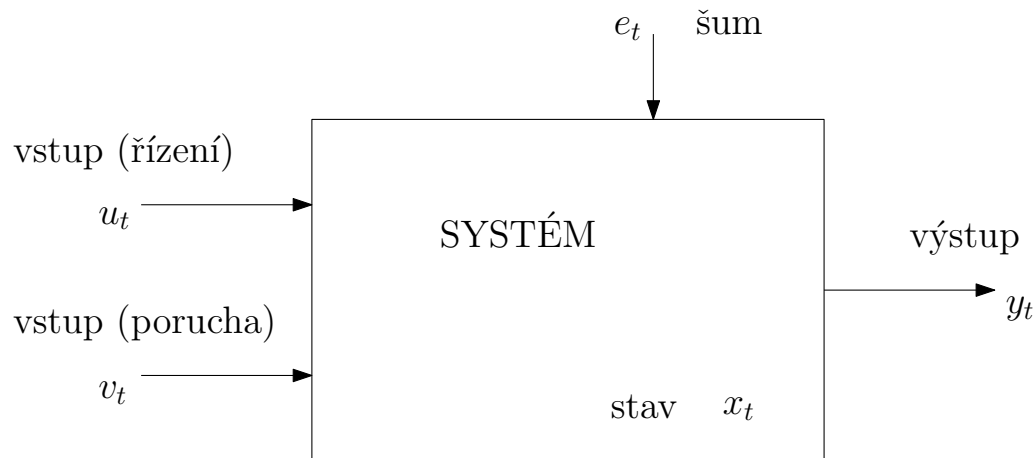
čas: diskrétní  $\times$  spojitý

### Pro nás

**DISKRÉTNÍ SYSTÉM:** diskrétní čas i hodnoty

**SPOJITÝ SYSTÉM:** diskrétní čas, spojité hodnoty

# System



## Jak na analýzu dat (s modelem)

Data jsou **naměřené hodnoty** zvolených veličin.

Jedno měření dá datový záznam (většinou)  $v_t$  a  $y_t$  -  $t$  je pořadí měření (diskrétní čas),

kde  $v = [v_1, v_e, \dots, v_n]$  (vysvětlující veličina) a  $y$  (výstup) je většinou skalár.

Data (dataset) je matice datových záznamů  $\{v_t, y_t\}_{t=1}^N$  -  $N$  je počet dat.

Data se nejlépe uloží v Excelu ve formě \*.csv

Dvojice  $v_t$  a  $y_t$  jsou měřeny současně. Pokud v záznamu nějaká hodnota chybí, je nejlépe celý záznam smazat.

### Pro dotazníky

Veličina je otázka.

Hodnoty jsou odpovědi.

Datový záznam je jeden dotazník.

Dataset je množina všech vyplněných dotazníků.

Data musí být informativní: nést informaci o vlastnostech, o které se zajímáme.

např. je-li nějaká veličina konstantní, nenese informaci.

# Typy dat vzhledem k úlohám

Existují zhruba 3 typy dat pro 3 typy úloh

## 1. Descriptive:

$$f(v_t)$$

kde  $v_t = [v_1, v_2, \dots, v_n]_t$ ,  $t = 1, 2, \dots, N$

## 2. Explanatory:

$$f(y_t|v_t)$$

kde  $y_t$  je většinou skalár a  $v_t = [v_1, v_2, \dots, v_n]_t$

## 3. Predictive:

$$f(y_t|y(t-1), u_t)$$

kde  $y_t$  je skalár,  $y(t-1) = [y_{t-1} \dots y_{t-k}]$ ,  $k$  pevné a  $u_t$  je řízení nebo měřená vysvětlující veličina.

## 1. Descriptive

Matice dat - hodnoty  $n$  veličin (ve sloupcích nebo v řádcích).

Z Excelu se dostanou buď Ctrl C, Ctrl V nebo uložit jako \*.csv soubor.

Do Scilabu se natáhnou pomocí příkazu `csvRead`.

Analýzu provedeme buď přímo v Excelu nebo Scilabu (Matlabu).

*Např. jaké zpomalovací prahy existují a které jsou si podobné?*

Většinou jde o statistické charakteristiky a testy nebo klastrování.

## 3. Predictive

Jedná se o časový vývoj modelované veličiny v závislosti na jejích předchozích hodnotách a případně dalších vysvětlujících nebo řídicích veličinách.

*Např. předpověď intenzity dopravního proudu.*

Lokální modelování: konstrukce predikce na klastrech.

Úloha je predikce založená na regresi (multiregresi) nebo diskretním modelu. Sem patří taky směsi a všechny úlohy klasifikace z oblasti data-mining.

## 2. Explanatory

Nejčastěji se vyskytující úloha.

Zjišťuje, jestli a jak vysvětlující veličiny  $v = [v_1, v_2, \dots, v_n]$  ovlivňují modelovanou veličinu  $y$ .

*Např. které okolnosti mají největší vliv na těžké dopravní nehody?*

Zásady:

- veličiny  $v_i$  musí s  $y$  skutečně souviset - testovat jednu po druhé (třeba regresí)
- nesmí existovat jiná veličina, která významně ovlivňuje  $y$  a není ve  $v$
- ve  $v$  nesmí být lineárně závislé veličiny (ideálně stochasticky nezávislé)
- záznamy s chybějícími údaji vynechat; konstantní veličiny jsou k ničemu
- data musí být informativní - počet, obsah
- pro učení (odhad) musí být k dispozici obojí  $v$  i  $y$ , pro aplikaci už jen  $v$ .

## Typy dat svou povahou

Data jsou dvojího druhu: **spojitá** nebo **diskrétní** (mohou být i smíšená).

- $v$  i  $y$  diskrétní - diskrétní model (průřvih s dimenzí), klasifikace
- $v$  spojité,  $y$  diskrétní - logistická regrese, naivní Bayes, klasifikace
- $v$  i  $y$  spojité - regrese, multiregrese, diskretizace



# Odhad

**Diskrétní model** - tabulka.

**Spojité model** - nejmenší čtverce, Bayes (expertní znalost)

**Směsi** - několik modelů pro jednotlivé módy systému. Změřím data, provedu klasifikaci vzhledem ke komponentám → váhy, statistiky komponent přepočtu s vahami.

Analýza dat, predikce, klasifikace.

# 3 Modely

## Model

Model je popisem náhodné veličiny, případně v závislosti na jiných veličinách. Tímto popisem je (podmí-  
něná) distribuce (pf nebo hp)

$$f(y_t | \psi_t, \Theta)$$

- $y_t$  - výstup (modelovaná veličina, target variable ...),
- $\psi_t$  - regresní vektor (veličiny ovlivňující  $y_t$ , případně zpožděné veličiny)
- $\Theta$  - parametry (vyjadřují jak veličiny ovlivňují  $y_t$ ).

Tato distribuce bývá generována různě.

# Regresní model

Spojité  $y_t$  a většinou i  $\psi_t$

$$\begin{bmatrix} y_1 \\ y_2 \end{bmatrix}_t = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \end{bmatrix}_{t-1} + \begin{bmatrix} b_1 \\ b_2 \end{bmatrix} u_t + \begin{bmatrix} c_{11} & c_{12} & c_{13} \\ c_{21} & c_{22} & c_{23} \end{bmatrix} \begin{bmatrix} v_1 \\ v_2 \\ v_3 \end{bmatrix}_t + \begin{bmatrix} k_1 \\ k_2 \end{bmatrix} + \begin{bmatrix} e_1 \\ e_2 \end{bmatrix}_t$$

kde regresní vektor je  $\psi_t = [y_{t-1}, u_t, v_t, 1]$  a parametry  $\theta = \{a, b, c, k\}$ ,  $+ r$  je kovarianční matice  $e_t$ .

Krátce

$$y_t = ay_{t-1} + bu_t + cv_t + k + e_t$$

a ještě stručněji

$$y_t = \theta\psi_t + e_t$$

$$\psi = [y_{1;t-1}, y_{2;t-1}, u_t, v_{1;t}, v_{2;t}, v_{3;t}, 1]'$$

$$\theta = \begin{bmatrix} a_{11} & a_{12} & b_1 & c_{11} & c_{12} & c_{13} & k_1 \\ a_{21} & a_{22} & b_2 & c_{21} & c_{22} & c_{23} & k_2 \end{bmatrix}$$

## Nejčastější speciální případy

Descriptive

$$y_t = k + e_t$$

Explanatory

$$y_t = cx_t + e_t$$

Predictive

$$y_t = ay_{t-1} + bu_t + e_t$$

# Diskrétní model

Obecně - pf je tabulka hodnot a pravděpodobností

$y_t$	$f(y_t)$
1	$p_1$
2	$p_2$
...	...
$m$	$p_m$

Koruna

$$\begin{array}{l} y_t \quad f(y_t) \\ 1 \quad p_1 \quad , \quad p_1 + p_2 = 1 \\ 2 \quad p_2 \end{array}$$

4 koruny 1,2,3,4

koruna	1	2	3	4
padlo 1	$p_{11}$	$p_{12}$	$p_{13}$	$p_{14}$
padlo 2	$p_{21}$	$p_{22}$	$p_{23}$	$p_{24}$

→ generuje  $f(y|\text{koruna} = i)$ ,  $i = 1, 2, 3, 4$

# Obecný diskrétní model

Ve tvaru  $f(y_t|u_t, y_{t-1})$  s daty 1, 2

$u_t$	1	1	2	2
$y_{t-1}$	1	2	1	2
$y_t = 1$	$\Theta_{1 11}$	$\Theta_{1 12}$	$\Theta_{1 21}$	$\Theta_{1 22}$
$y_t = 2$	$\Theta_{2 11}$	$\Theta_{2 12}$	$\Theta_{2 21}$	$\Theta_{2 22}$

kde  $\theta_{i|jk} \geq 0$  a  $\sum_i \theta_{i|jk} \forall j, k$  - nezáporné, součty v řádcích jsou jedna.

Dimenze modelu: součin počtu hodnot jednotlivých veličin. 10 veličin po 10 hodnotách =  $10^{10}$

# Model směsi


Několik modelů - komponent + klasifikace, kam změřená data patří (ukazovátka).

Komponenty (descriptive)

$$f_j(y_t | \Theta_j), j = 1, 2, \dots, n_c$$

Ukazovátka

$c_t$	$f(c_t   \alpha)$
1	$\alpha_1$
2	$\alpha_2$
...	...
$n_c$	$\alpha_{n_c}$





# Model logistické regrese


$$p = f(y_t = 1 | x_t, \theta)$$

$$\text{logit}(p) = \underbrace{x_t \theta}_{z_t}$$

→

$$z_t = x_t \theta$$

$$\ln \frac{p}{1-p} = z_t$$



# Stavový model

Stav je veličina prvního řádu (závisí pouze na své minulé hodnotě, ne na historii)

model predikce  $x_t = Mx_{t-1} + Nu_{t-1} + w_t$

model filtrace  $y_t = Ax_t + Bu_t + v_t$

Úloha:

- odhad hodnot neměřené veličiny z  $u_t$  a  $y_t$
- filtrace šumu

Pro lineární model se známými parametry a normální rozdělení stavu a šumů funguje **Kalmanův filtr** - vývoj středních hodnot a kovariancí stavu.

$$f(x_{t-1}|d(t-1)) \underbrace{\rightarrow}_{\text{predikce}} f(x_t|d(t-1)) \underbrace{\rightarrow}_{\text{filtrace}} f(x_t|d(t))$$

## Programy

- T11simCont.sce simulation with a regression model
- T13simDisc.sce simulation with a discrete model
- T15simState.sce simulation with state model (from reg. model)

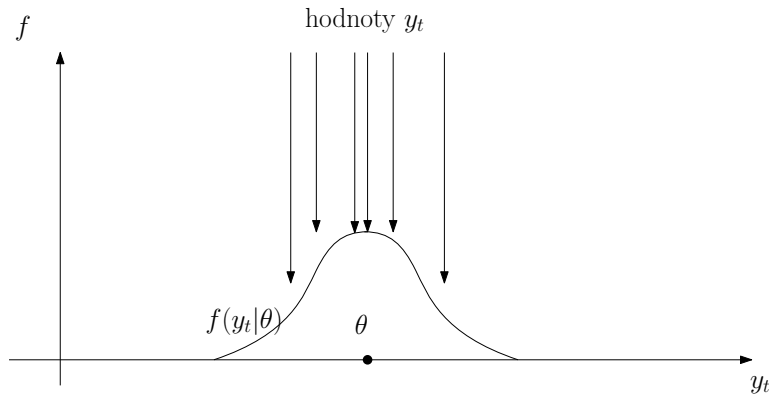
# 4 Odhad

## Bayesův vzorec

$d(t) = \{y_\tau, u_\tau, v_\tau\}_{\tau=1}^t$  data, změřená do  $t$  včetně.

$$f(\Theta|d(t)) \propto f(y_t|\psi_t, \Theta) f(\Theta|d(t-1))$$

**Parametry v modelu mají za následek hodnoty  $y_t$ . Stejně tak měřené hodnoty  $y_t$  ukazují na parametr modelu, který je generoval.**



$\theta$  specifikuje systém (jaderný reaktor  $\times$  atomová bomba)

## Likelihood

$$f(\Theta|d(t)) \propto f(\Theta|d(0)) \underbrace{\prod_{\tau=1}^t f(y_\tau|\psi_\tau, \Theta)}_{L_t(\Theta)\text{-likelihood}}$$

... pro  $f(\Theta|d(0))$  rovnoměrné (žádná apriorní znalost) je

$$f(\Theta|d(t)) \propto L_t(\Theta)$$

**Parametrizace** → statistiky.

**Rekurzivita** - konjugované rozdělení.

# Jednotlivé modely

## Regresní model

Přepočítání statistiky

$\Psi_t = [y_t, \psi_t]'$  - rozšířený regresní vektor

$$V_t = V_{t-1} + \Psi_t \Psi_t' \quad \text{informační matice}$$

$$\kappa_t = \kappa_{t-1} + 1 \quad \text{počítadlo}$$

Bodové odhady

$$V_t = \begin{bmatrix} V_y & V_{y\psi}' \\ V_{y\psi} & V_\psi \end{bmatrix}$$

$$\hat{\theta} = V_\psi^{-1} V_{y\psi}$$

$$\hat{r} = \frac{V_y - V_y' \hat{\theta}}{\kappa_t}$$

nebo podle nejmenších čtverců

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_N \end{bmatrix}, \quad X = \begin{bmatrix} y_0 & u_1 & v_1 & 1 \\ y_1 & u_2 & v_2 & 1 \\ \dots & \dots & \dots & \dots \\ y_{N-1} & u_N & v_N & 1 \end{bmatrix}$$

$$\hat{\theta} = (X'X)^{-1} X'Y, \quad y_p = X\hat{\theta}, \quad \hat{e} = y - y_p, \quad \hat{r} = D[\hat{e}]$$

**Jednotlivé typy**

Je v: Laboratory.

# Diskrétní model

Jako u koruny: Statistika

$u_t$	1	1	2	2
$y_{t-1}$	1	2	1	2
$y_t = 1$	$\nu_{1 11}$	$\nu_{1 12}$	$\nu_{1 21}$	$\nu_{1 22}$
$y_t = 2$	$\nu_{2 11}$	$\nu_{2 12}$	$\nu_{2 21}$	$\nu_{2 22}$

$$\nu_{y_t|u_t, y_{t-1}; t} = \nu_{y_t|u_t, y_{t-1}; t-1} + 1$$

ostatní nic.

*Koruna: Máme dvě misky - pro rub a pro líc. Hodíme a na tu misku, jejíž strana padla, přidáme další úspěch.*

Bodové odhady: normalizace řádků na součet jedna.



## Model směsi

Odhad podle toho, jaké jsou komponenty.

Rozdíl:

- výpočet vah
- vážený update statistik

Tedy např.

$$V_{j;t} = V_{j;t-1} + w_j \Psi_t \Psi_t', \quad \forall j$$

nebo

$$\nu_{j,y_t|u_t,y_{t-1};t} = \nu_{j,y_t|u_t,y_{t-1};t-1} + w_j, \quad \forall j$$

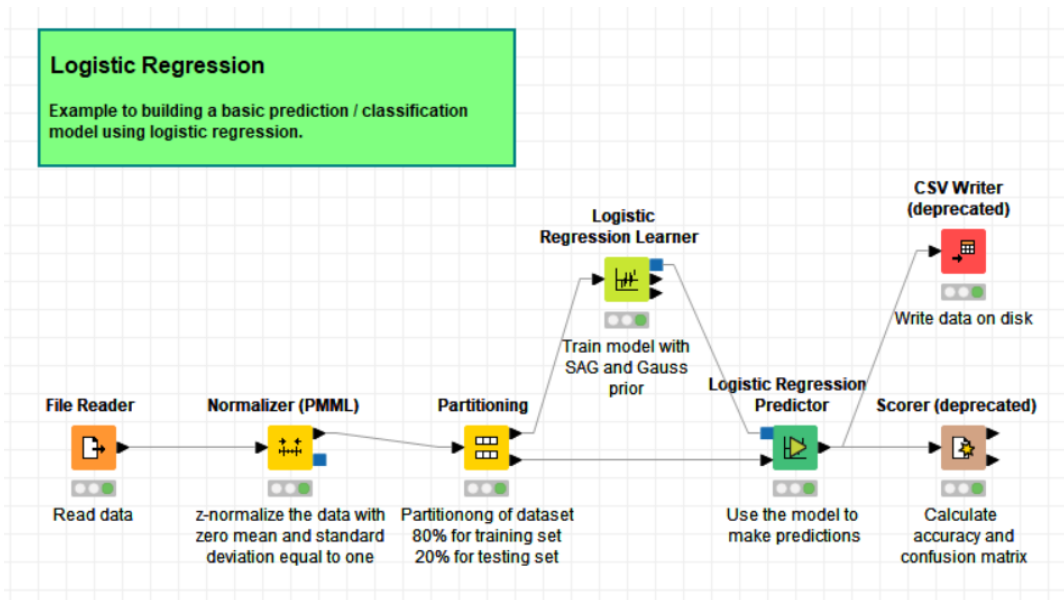
kde  $j$  je číslo komponenty.

# Model logistické regrese

Nemá reprodukovatelnou statistiku.

Sestaví se likelihood a ten se maximalizuje numericky.

Nejlépe použít hotový program - např. KNIME



# Stavový model

$$x_t = Mx_{t-1} + Nu_t + F + w_t$$

$$y_t = Ax_t + Bu_t + G + v_t$$

Kalmanův filtr

$$[x, Rx, yp] = \text{Kalman}(x, y, u, M, N, F, A, B, G, R_w, R_v, Rx);$$

Filtrace šumu

$$x_t = x_{t-1} + w_t$$

$$y_t = x_t + v_t$$

$y$  je zašuměný průběh

$x$  je filtrovaný (hladký) průběh

$r_w$  a  $r_v$  určují, o kolik se může měnit  $x$  a jak se mění  $y$  ( $x$  se šumem)

## Programy

- T21estCont\_LS.sce - odhad regresního modelu (nejmenší čtverce)
- T22estCont\_B.sce - odhad regresního modelu (Bayes)
- T22estCont\_B2.sce - neshoda struktury
- T22estCont\_B3.sce - neshoda struktury
- T22estCont\_B4.sce - odhad s reálnými daty
- T23estDisc.sce - odhad diskrétního modelu

## Inicializace

Přednastavení parametrů modelu z apriorních dat nebo expertní znalosti.

Zvláště nutné je u směsí - jinak se odhad nerozběhne.

Expertní znalost je nejlépe vyjádřit v tzv fiktivních datech, která se na začátku zpracují běžným způsobem.

Fiktivní data jsou např.: *když bude dopoledne nebo nehoda, tak bude hustota provozu velká*. Tedy podmínka - důsledek.

**Odhad koruny** - pro férovou korunu

	rub	líc	vliv
1.	1	1	slabý
2.	10	10	střední
3.	100	100	velký

Poměr udává parametr, velikost sílu informace.

Regresní model (statický) : statistiky  $S$  -součet,  $\kappa$  počet

## Odhad střední hodnoty

$$\theta = \frac{S}{\kappa}$$

Volím

$\kappa$  - počet dat

$\hat{\theta}_0$  - hodnota parametru

$$S = \hat{\theta}_0 \kappa$$

Jako odhad dostanu právě  $\hat{\theta}_0$

## Obecný regresní model

$$y_t = b_0 u_t + a_1 y_{t-1} + b_1 u_{t-1} + k + e_t$$

$$V_0 = \begin{bmatrix} 1 & b_0 & a_1 & b_1 & k \\ b_0 & 1 & & & \\ a_1 & & 1 & & \\ b_1 & & & 1 & \\ k & & & & 1 \end{bmatrix}$$

Odhad dá právě tyto parametry.

Síla

$$\kappa = n_0$$

$$V = V_0 \kappa$$

Dk.

$$V_\psi = E$$

$$V_{y\psi} = \theta = [b_0, a_1, b_1, k]'$$

$$\hat{\theta} = \theta$$

## Programy

- T24iniCoin.sce - estimation of a coin model with initialization
- T24iniReg.sce - estimation of regression model with initialization



# 5 Predikce a odhad stavu

## Predikce

Je to odhad budoucího výstupu.

Máme model  $f(y_t|\psi_t, \theta)$ ,  $\psi = [y_{t-1}, \dots, y_{t-n}]'$ .

Jsme v čase  $t$ ,  $y_t$  jsme ještě nezměřili a známe  $y(t-1)$ .

- $f(y_t|y(t-1))$  je nula-kroková predikce (odhad aktuálního výstupu). Ta se hodí pro kontrolu odhadu - chyba predikce.
- $f(y_{t+k}|y(t-1))$  je  $k$ -kroková predikce (odhad do budoucna).

## Příklad

$$\begin{aligned} f(y_{t+1}|y(t-1)) &= \int_{\theta^*} \int_{y^*} f(y_{t+1}, y_t, \theta | y(t-1)) dy_t d\theta = \\ &= \int_{\theta^*} \int_{y^*} f(y_{t+1} | \psi_{t+1}, \theta) \underbrace{f(y_t | \psi_t, \theta)}_{\rightarrow \hat{y}_t} \underbrace{f(\theta | d(t-1))}_{\rightarrow \hat{\theta}} dy_t d\theta \end{aligned}$$

pro bodové odhady

$$\begin{aligned} f(y_{t+1}|y(t-1)) &= f(y_{t+1} | \hat{y}_t, \psi_t, \hat{\theta}) \\ \hat{y}_{t+1} &= E[y_{t+1} | \hat{y}_t, \psi_t, \hat{\theta}] = \int_{y_{t+1}^*} y_{t+1} f(y_{t+1} | \hat{y}_t, \psi_t, \hat{\theta}) dy_{t+1} \end{aligned}$$

# V praxi

## Regresní model

$$y_t = a_1 y_{t-1} + a_2 y_{t-2} + k + e_t$$

Bodová predikce + známé parametry

$$\hat{y}_t = a_1 y_{t-1} + a_2 y_{t-2} + k$$

$$\hat{y}_{t+1} = a_1 \hat{y}_t + a_2 y_{t-1} + k$$

$$\hat{y}_{t+2} = a_1 \hat{y}_{t+1} + a_2 \hat{y}_t + k$$

atd.

## Diskrétní model

$u_t$	1	1	2	2
$y_{t-1}$	1	2	1	2
$y_t = 1$	$\Theta_{1 11}$	$\Theta_{1 12}$	$\Theta_{1 21}$	$\Theta_{1 22}$
$y_t = 2$	$\Theta_{2 11}$	$\Theta_{2 12}$	$\Theta_{2 21}$	$\Theta_{2 22}$

Dáno  $u_t$  a  $y_{t-1} \rightarrow$  řádek,  $\hat{y}_t$  je hodnota s větší pravděpodobností.

Víceřádková bodová - viz program.

## Filtrace

Odhad hodnot neměřené veličiny ze vstupu a výstupu.

Kalmanův filtr - bylo.

## Nelineární model

$$x_t = f(x_{t-1}, u_{t-1}) + w_t$$

$$y_t = g(x_t, u_t) + v_t$$

Linearizace - Taylorův rozvoj v  $\hat{x}$  z minula

$$f(x) = f(\hat{x}) + f'(\hat{x})(x - \hat{x}) = \underbrace{f'(\hat{x})}_M x + \underbrace{f(\hat{x}) - f'(\hat{x})\hat{x}}_F$$

## Model s neznámými parametry

Příklad

$$x_t = ax_{t-1} + u_t + w_t$$

Nový stav

$$X_t = \begin{bmatrix} X_{1;t} \\ X_{2;t} \end{bmatrix} = \begin{bmatrix} x_t \\ a \end{bmatrix}$$

a dostaneme

$$X_{1;t} = X_{2;t-1}X_{1;t-1} + u_t + W_{1;t}$$

$$X_{2;t} = X_{2;t-1} + W_{2;t}$$

To se linearizuje - viz výše.

## Programy

- T31preCont.sce prediction with reg. model, known parameters
- T32preCont\_Adapt.sce prediction with reg. model, unknown parameters
- T32preCont\_Adapt2.sce prediction with estimation, model mismatch
- T32preCont\_Adapt3.sce prediction with estimation, real data
- T33preDisc\_Off.sce prediction with discrete model
- T34preDisc\_OffEst.sce pred. with disc. mod. - off-line estimation
- T35preDisc\_OnEst.sce pred. with disc. mod. - on-line estimation
- T46statEst\_KF.sce state estimation (KF)
- T47statEst\_Noise.sce KF as a noise filter

## 6 Řízení

### Řízení minimum variance

Velmi jednoduché ale někdy nestabilní.

Příklad

$$y_t = b_0 u_t + a_1 y_{t-1} + b_1 u_{t-1} + k + e_t$$

$$E[y_t] = 0$$

$$u_t = -\frac{1}{b_0} (a_1 y_{t-1} + b_1 u_{t-1} + k)$$

Nepoužívá se.



## Řízení na konečném intervalu

Navrhuje se najednou na několik kroků dopředu (interval řízení). Na tomto intervalu se požaduje  $y_t$  co nejbližší nule nebo požadovanému průběhu.

Jedná se o optimální řízení vzhledem ke kritériu

$$\min_{u_1, u_2 \dots u_T} E \left[ \sum_{t=1}^T \underbrace{(y_t^2 + \omega u_t^2)}_{J_t} \mid d(0) \right]$$

nebo

$$\min_{u_1, u_2 \dots u_T} E \left[ \sum_{t=1}^T \underbrace{(y_t^2 + \omega [u_t - u_{t-1}]^2)}_{J_t} \mid d(0) \right]$$

Kritérium se minimalizuje metodou Dynamického programování, postupně od konce intervalu a dostaneme **Bellmanovy rovnice**

$$\varphi_t = E [\varphi_{t+1}^* + J_t \mid u_t, d(t-1)]$$

$$\varphi_t^* = \min_{u_t} \varphi_t$$

s počáteční podmínkou  $\varphi_{T+1}^* = 0$ .

Pro **regresní model** (ve stavovém tvaru)

$$y_t = b_0 u_t + a_1 y_{t-1} + b_1 u_{t-1} + a_2 y_{t-2} + b_2 u_{t-2} + k + e_t$$

$$\underbrace{\begin{bmatrix} y_t \\ u_t \\ y_{t-1} \\ u_{t-1} \\ 1 \end{bmatrix}}_{x_t} = \underbrace{\begin{bmatrix} a_1 & b_1 & a_2 & b_2 & k \\ 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix}}_M \underbrace{\begin{bmatrix} y_{t-1} \\ u_{t-1} \\ y_{t-2} \\ u_{t-2} \\ 1 \end{bmatrix}}_{x_{t-1}} + \underbrace{\begin{bmatrix} b_0 \\ 1 \\ 0 \\ 0 \\ 0 \end{bmatrix}}_N u_t + \underbrace{\begin{bmatrix} e_t \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}}_{w_t}$$

dosadíme do Bellmanových rovnic. Dostaneme algoritmus

## Optimalizace na intervalu $(1, N)$

$$R_{N+1} = 0$$

**for**  $t = N, N - 1, \dots, 1$

$$U = R_{t+1} + \Omega$$

$$A = N'UN$$

$$B = N'UM$$

$$C = M'UM$$

$$S_t = A^{-1}B$$

$$R_t = C - S_t'AS_t$$

**end**

## Realizace optimálního řízení na intervalu $(1, N)$

**for**  $t = 1, 2, \dots, N$

$$x_{t-1} = [y_{t-1}, u_{t-1}, y_{t-2}, u_{t-1}, 1]$$

$$u_t = -S_t x_{t-1}$$

**end**

## Programy

- T52ctrlDisc.sce optimální řízení s diskrétním modelem
- T53ctrlX.sce optimální řízení se spojitým modelem
- T54ctrlXEst.sce adaptivní řízení se spojitým modelem

# 7 Směsi

## Úvod do problematiky

**Směs** = **množina modelů** (komponent) + **ukazovátka**, označující aktivní komponentu (tu, která odpovídá aktuálním datům).

**Použití:** Modeluje multimodální data - systém pracuje v různých pracovních módech a mezi nimi se přepíná.


Například: Doprava (*i*) ráno, (*ii*) přes den, (*iii*) večer a v (*iv*) noci. Dále ve (1) všední dny nebo o (2) víkendu. A ještě dále (*a*) přes rok a (*b*) o prázdninách.

*Problém: Při odhadu všech komponent najednou se budou módy přetahovat a komponenty se slezou všechny na jedno místo !!!*

## Odhad

- změříme datový vzorek
- určíme, které komponentě patří - proximity (= klasifikace)
- statistiky komponent přepočteme úměrně proximity

## Proximity



Model

$$f(y_t|\psi_t, \Theta)$$

říká, jak dobře spolu data  $[y_t, \psi_t]$  a parametry  $\Theta$  souvisí. Čím lépe, tím je větší pravděpodobnost.

Proximity za parametry dosazuje jejich nejnovější bodové odhady.

## Algoritmus

Pro všechny komponenty určete počáteční bodové odhady a jim odpovídající statistiky.

Pro  $t = 1, 2, \dots, N$

1. Změřte nová data
2. Pro každou komponentu spočtěte proximity s aktuálními odhady parametrů a změřenými daty.
3. Normalizujte  $\rightarrow$  váhy
4. Udělejte vážený přepočet statistik komponent
5. Přepočtěte bodové odhady parametrů

$C_1$ $f_1(y \theta_1)$	$C_2$ $f_2(y \theta_2)$	$C_m$ $f_m(y \theta_m)$
$y_t$		
$f_1(y_t \hat{\theta}_1)$	$f_2(y_t \hat{\theta}_2)$	$f_m(y_t \hat{\theta}_m)$
$q_1$	$q_2$	$q_m$
$w = q / \sum q$		
$w_1$	$w_2$	$w_m$
$S_{1;t} = S_{1;t-1} + w_1 x_t$	$S_{2;t} = S_{2;t-1} + w_2 x_t$	$S_{m;t} = S_{m;t-1} + w_m x_t$
$\kappa_{1;t} = \kappa_{1;t-1} + w_1$	$\kappa_{2;t} = \kappa_{2;t-1} + w_2$	$\kappa_{m;t} = \kappa_{m;t-1} + w_m$
$\hat{\theta}_1 = \frac{S_{1;t}}{\kappa_{1;t}}$	$\hat{\theta}_2 = \frac{S_{2;t}}{\kappa_{2;t}}$	$\hat{\theta}_m = \frac{S_{m;t}}{\kappa_{m;t}}$



## Programy

mix0.sce - regresní komponenty (statistika  $S$ )

mix1.sce - regresní komponenty (statistika  $V$ )

mix3.sce - kategorické komponenty

mix4.sce - kategorické komponenty (opakovaný odhad)

mix5.sce - binomické komponenty

(... in PrgsScilab/Mixtures)

# Model směsi

Množina modelů a ukazovátko, které indikuje aktivní model (komponentu).

Komponenty (statické)

$$f_j(y_t|\Theta_j), j = 1, 2 \dots n_c$$

Ukazovátko  $c_t \in \{1, 2 \dots n_c\}$

$$f(c_t = j|\alpha) = \alpha_j$$

Model směsi

$$\begin{aligned} f(y_t|\Theta) &= \sum_j f(y_t, c_t = j|\Theta_j) = \sum_j f_j(y_t|\Theta_j) f(c_t = j|\alpha) = \\ &= \sum_j \alpha_j f_j(y_t|\Theta_j) - \text{směs} \end{aligned}$$

Odhad - průšvih (Bayes  $\rightarrow$  součin součtů, narůstá složitost)

## Odhad směsi

Neznámé veličiny jsou  $c_t$ ,  $\Theta$ ,  $\alpha$ . Jejich distribuce je

$$\begin{aligned} f(c_t, \Theta, \alpha | d(t)) &\stackrel{\text{Bayes}}{\propto} f(y_t, c_t, \Theta, \alpha | d(t-1)) = \\ &= f(y_t | c_t, \Theta) f(c_t | \alpha) f(\Theta | d(t-1)) f(\alpha | d(t-1)) = \\ &= f_{c_t}(y_t | \Theta_{c_t}) f(\Theta | d(t-1)) \times f(c_t | \alpha) f(\alpha | d(t-1)) \end{aligned}$$

kde

$$\begin{aligned} f_{c_t}(y_t | \Theta_{c_t}) f(\Theta | d(t-1)) &\propto f(\Theta_{c_t} | d(t)) \\ f(c_t | \alpha) f(\alpha | d(t-1)) &\propto f(\alpha | d(t)) \end{aligned}$$

jsou Bayesova pravidla pro  $\Theta_{c_t}$  a  $\alpha$ .

Kdybychom znali  $c_t$ , jsme hotovi. To neznáme, tak musíme odhadovat

$$c_t \rightarrow f(c_t | d(t))$$

## Odhad $c_t$

$$\begin{aligned} f(c_t|d(t)) &= \int_{\Theta^*} \int_{\alpha^*} f(c_t, \Theta, \alpha|d(t)) d\alpha d\Theta \propto \\ &\propto \int_{\Theta^*} f_{c_t}(y_t|\Theta_{c_t}) f(\Theta|d(t-1)) d\theta \times \int_{\alpha^*} f(c_t|\alpha) f(\alpha|d(t-1)) d\alpha \end{aligned}$$

kde

$$\begin{aligned} \int_{\Theta^*} f_{c_t}(y_t|\Theta_{c_t}) f(\Theta|d(t-1)) d\theta &\rightarrow f_{c_t}(y_t|\hat{\Theta}_{c_t;t-1}) = q_{c_t;t} \\ \int_{\alpha^*} f(c_t|\alpha) f(\alpha|d(t-1)) d\alpha &\rightarrow f(c_t|\hat{\alpha}_{t-1}) = \hat{\alpha}_{c_t;t-1} = s_{c_t;t} \end{aligned}$$

jsou tzv. proximities - „blízkosti“ dat modelům.

**Proximity** dostaneme tak, že do komponenty nebo modelu  $\alpha$  dosadíme aktuální odhad parametrů a změřená data. Výsledek je číslo, které říká, jak blízko jsou změřená data modelu.

Proximity pro  $\alpha$  je nevýznamná a lze ji vynechat.

**Váhy** dostaneme normalizací proximit

$$w_t = \mathfrak{N}(q)$$

## Přepočet statistik

$$V_{j;t} = \underbrace{V_{j;t-1}}_{\text{inf. matice}} + w_j \underbrace{\Psi_t \Psi_t'}_{\text{data}}$$
$$\kappa_{j;t} = \underbrace{\kappa_{j;t-1}}_{\text{počítadlo}} + w_j \underbrace{1}_{\text{data}}$$

pro všechny komponenty  $j = 1, 2 \dots n_c$ . Liší se jen použitím vah  $w$ .

A jsme hotovi :-)