



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

# Odhad stavu stochastických systémů

Miroslav Šimandl (FAV, ZČU v Plzni)

8. prosince 2010



# Problém odhadu

## Základní pojmy

**Odhadování:** proces hledání hodnoty veličiny z nepřímých, nepřesných a nejistých pozorování.

**Odhad:** nalezená hodnota veličiny  
V případě, že hledaná veličina je náhodná proměnná, je za odhad často považováno nalezení hustoty pravděpodobnosti této veličiny nebo bodový odhad.

**Estimátor:** systém generující odhad.


**Rozhodování:** výběr jedné možnosti z množiny alternativ.




# Problém odhadu

## Základní pojmy

odhadování neměřitelného stavu reálného objektu



blokové schéma popisující úlohu odhadu





# Problém odhadu

## Základní pojmy

**Filtrace:** odhad veličin nebo stochastických procesů ze zašuměných dat

**Sledování:** cílem je sledovat atributy objektu a měřicí zařízení je mimo objekt

**Navigace:** cílem je sledovat atributy objektu a měřicí zařízení je součástí objektu



# Problém odhadu

## Aplikace odhadování

### Aplikace odhadování

- ▶ sledování
- ▶ navigace
- ▶ řídicí systémy
- ▶ řízení strojů a technologických procesů
- ▶ zpracování signálu
- ▶ zpracování obrazu
- ▶ komunikace (zpracování řeči, komunikace člověk-stroj)



# Problém odhadu

## Aplikace odhadování

- ▶ biomedicínské inženýrství
- ▶ operační výzkum
- ▶ geofyzikální problémy
- ▶ ekonometrické systémy
- ▶ demografické systémy
- ▶ dopravní systémy
- ▶ předpověď počasí



# Problém odhadu

## Obecné aspekty rozhodování

**Estimace prováděná Gaussem** (1777-1855) - proces vyvozování informace o parametrech, např. pohyb nebeských těles, přesně predikovatelný pohyb

**Estimace ve smyslu Kalmana** (1960 - Kalmanův filtr) - vyvozování informace o stavu objektu, který se pohybuje ne zcela přesně predikovatelným způsobem.



# Problém odhadu

## Obecné aspekty rozhodování

### Gaussovy postřehy

- Jestliže je pozorování absolutně přesné, stačí  $n$  pozorování pro  $n$  parametrů. Následující pozorování by mělo potvrdit, ale ne korigovat odhad.
- Pozorování je pouze aproximací skutečnosti, mělo by se využít více pozorování než je minimální počet s ohledem na počet neznámých parametrů. Odhady by se měly korigovat následnými pozorováními a je vhodné použít všechny pozorování k získání odhadu.



# Problém odhadu

## Obecné aspekty rozhodování

### Základní principy odhadu parametrů

- ▶ Existuje základní popis modelu systému s neznámými parametry, které mají být odhadnuty.
- ▶ Redundantní data jsou požadována pro redukci efektu chyb měření.
- ▶ Je nutné zajistit, aby rozdíl mezi pozorovanými hodnotami a predikovanými z odhadů byl co nejmenší.
- ▶ Kombinace počáteční znalosti a následného pozorování vede ke koncepci rekurzivního výpočtu.
- ▶ Nepřesnost pozorování vyžaduje statistické přístupy.



# Problém odhadu

## Základní estimační problémy

### Nejmenší čtverce (Gauss-Legendre)

- ▶ Odhad **konstantních parametrů** modelu minimalizací kvadrátu rozdílu výstupu modelu a měřeného výstupu systému.
- ▶ Pro gaussovské šумы je minimalizace součtu kvadrátu reziduí ekvivalentní maximalizaci věrohodnostní funkce parametrů.
- ▶ Později použito pro odhad náhodné veličiny.



# Problém odhadu

## Základní estimační problémy

Wiener-Hopfův problém, Kolmogorovův problém (30. až 40. léta 20. století)

- ▶ **Odhadované veličiny nejsou konstantní**, ale časově proměnné.
- ▶ Cíl je odhadnout náhodný stacionární proces.
- ▶ Odhad procesu je obdržen ve frekvenční oblasti.



# Problém odhadu

## Základní estimační problémy

### Kalman-Bucy problém (od roku 1960)

- ▶ Odhaduje se **náhodný proces**, ne nutně stacionární.
- ▶ **Popis** - lineární diferenciální nebo diferenční rovnice se známými parametry.
- ▶ **Řešení** v časové oblasti odpovídá minimalizaci ve střední kvadratické chybě.
- ▶ **Estimátor** je nazýván Kalman-Bucy filtr nebo Kalmanův filtr.



# Problém odhadu

## Základní estimační problémy

### Problém nelineárního odhadu (od roku 1970)


- ▶ Odhaduje se náhodný proces generovaný
  - ▶ nelineárním systémem
  - ▶ lineárním systémem s negaussovskými poruchami
- ▶ Výsledkem je nalezení
  - ▶ podmíněné hustoty pravděpodobnosti stavu
  - ▶ podmíněný bodový odhad stavu




# Problém odhadu

## Základní estimační problémy


Odhad stacionárního náh. procesu  $x(t)$  pomocí Wienerova filtru



Odhad náhodného procesu  $x(t)$  pomocí Kalmanova filtru



Odhad náhodného procesu  $x(t)$  pomocí nelineárního filtru





# Modelování a odhad

## Motivační případ

Uvažujme jako přirozený základ pro diskusi o odhadu parametrů a odhadu stavu následující rovnici

$$z_k = y_k + v_k \quad k = 0, 1, \dots$$

kde  $z_k$  je měření na systému dostupné v čase  $t_k$

$y_k$  je výstup systému v čase  $t_k$

$v_k$  reprezentuje šum měření neboli poruchu v čase  $t_k$ .

Problém je najít odhad  $y_k$  z měření  $z_k$  pro všechna  $k$ .



# Modelování a odhad

## Motivační případ

Primitivní odhad by mohl být

$$\hat{y}_k \triangleq z_k.$$

Chyba odhadu by v tomto případě byla

$$\tilde{y}_k \triangleq y_k - \hat{y}_k = z_k - v_k - z_k = -v_k.$$

Cíl estimační teorie je navrhnout takový postup při stanovení odhadu, který bude redukovat chybu odhadu na menší, než kterou dává primitivní estimátor



# Modelování a odhad

## Motivační případ

Problém: chyba  $\tilde{y}_k$  nemůže být určena explicitně.

Proto je třeba znát více o signálu  $y_k$  - předpokládejme nejdříve, že

$$y_k = \theta$$

$$z_k = \theta + v_k \quad k = 0, 1, 2, \dots, N.$$

Odhad  $\theta$  můžeme provést

$$\left(\sum_{k=0}^N z_k\right)/(N+1) = \theta + \left(\sum_{k=0}^N v_k\right)/(N+1).$$



# Modelování a odhad

## Motivační případ

Rozumný odhad  $\theta$

$$\hat{\theta} \triangleq (\sum_{k=0}^N z_k) / (N + 1)$$

a chyba odhadu

$$\tilde{\theta} = \theta - \hat{\theta} = -(\sum_{k=0}^N v_k) / (N + 1).$$

Jestliže je však  $v_k$  konstanta, pak k žádnému zlepšení odhadu nedojde, přestože jsme věděli více o výstupu  $y_k$  a použili statistický přístup.



# Modelování a odhad

## Strukturální modelování

Rozšířme úvahy na situaci popsanou rovnicí  
nelineární problém estimace parametrů  $\Theta$

$$y_k = h_k(\Theta) \quad k = 0, 1, 2, \dots$$

kde  $h_k(\cdot)$  je známá vektorová funkce  
nebo

lineární problém estimace parametrů  $\Theta$

$$y_k = H_k \cdot \Theta \quad k = 0, 1, 2, \dots$$

kde  $H_k$  je známá matice příslušných dimenzí.



# Modelování a odhad

## Strukturální modelování

### Nelineární estimace stavu

Mnohdy však není možné uvažovat neznámé jako konstantní veličiny a pak

$$y_k = h_k(x_k).$$

Vývoj vektorové proměnné  $x_k$  je popsán diferenční rovnicí

$$x_{k+1} = f_k(x_k) + w_k$$

kde  $f_k(\cdot)$  je známá vektorová funkce.

$w_k$  je neznámý vektor reprezentující šum v čase  $t_k$ .



# Modelování a odhad

## Strukturální modelování

### Lineární estimace stavu nebo parametrů

speciální případ

$$x_{k+1} = F_k x_k + w_k$$

$$y_k = H_k x_k$$

kde  $F_k$  a  $H_k$  jsou známé matice příslušných dimenzí.

Pro

$$x_{k+1} = x_k = \Theta$$

nebo

$$x_{k+1} = f_k(x_k)$$

tedy stavový šum je nulový pro všechna  $k$  dostáváme problém estimace parametrů,  $x_0 = \Theta$ .



# Modelování a odhad

## Strukturální modelování

### závěr

- ▶ strukturální vlastnosti
- ▶ jednoduchost při aplikaci
- ▶ problémy s kvalitativním ohodnocením přesnosti odhadu



# Modelování a odhad

## Pravděpodobnostní modelování

K popisu neurčitosti se tradičně používá počtu pravděpodobnosti.

Aby měření poskytovalo nejvíce informací, měl by šum

$v^N = (v_0, v_1, \dots, v_N)$  splňovat

$$p(v^N) = p(v_0, v_1, \dots, v_N) = p(v_0) \cdot p(v_1) \dots p(v_N)$$

Tedy, aby stochastický proces  $\{v_k\}$  byl bílý šum.



### Stavový šum

- ▶ Stavový šum  $w_k$  nesmí vykazovat žádnou závislost do minulosti.

$$p(w^k) = p(w_0, w_1, \dots, w_k) = p(w_0) \cdot p(w_1) \dots p(w_k)$$

- ▶ Nezávislost stavového šumu, šumu měření a počátečního stavu  $x_0$ ,
- ▶ Poznamenejme, že v tomto případě  $x_k$  pro  $k = 0, 1, 2, \dots$  reprezentuje markovský proces.



# Modelování a odhad

## Pravděpodobnostní modelování

### Problém estimace parametrů

Mějme vektor měření  $z_k$  popsany rovnicí

$$z_k = h_k(\Theta) + v_k \quad k = 0, 1, 2, \dots, N,$$

kde  $E[v_k] = 0$ ,  $E[v_k v_l^T] = R_k \delta_{kj}$ ,  $\delta_{kj} = 1, k = j$ ;  $\delta_{kj} = 0, k \neq j$   
 $h_k(\cdot)$  je známá vektorová funkce.

Cílem je určit odhad neznámých konstantních parametrů  $\Theta$ .



# Modelování a odhad

## Pravděpodobnostní modelování

### Problém estimace stavu

Mějme vektor měření  $z_k$  popsany

$$z_k = h_k(x_k) + v_k \quad k = 0, 1, 2, \dots, N$$

kde  $E[v_k] = 0$ ,  $E[v_k v_j^T] = R_k \delta_{kj}$ ,  $h_k(\cdot)$  je známá nelineární funkce  
a vektor stavu se vyvíjí podle rovnice

$$x_{k+1} = f_k(x_k) + w_k \quad k = 0, 1, 2, \dots, N$$

kde  $E[w_k] = 0$ ,  $E[w_k w_j^T] = Q_k \delta_{kj}$ ,  $f_k(\cdot)$  je známá nelineární funkce.

Cílem je odhadnout stav  $x_k$ .



# Klasická teorie odhadu

## Optimální odhad podle střední kvadratické chyby - MS

- ▶ Uvažujme náhodné vektory  $\mathbf{x}$  a  $\mathbf{z}$ ,
  - ▶ vektor  $\mathbf{x}$  je neznámý,
  - ▶ vektor  $\mathbf{z}$  reprezentuje data, vztažená k  $\mathbf{x}$ ,
  - ▶ předpokládejme apriorní informaci o neznámé  $\mathbf{x}$ .
- 
- ▶ Cílem je najít pro dané  $\mathbf{z}$  odhad  $\hat{\mathbf{x}}(\mathbf{z})$  náhodné veličiny  $\mathbf{x}$  tak, aby chyba odhadu  $\tilde{\mathbf{x}} = \mathbf{x} - \hat{\mathbf{x}}(\mathbf{z})$  byla malá.



# Klasická teorie odhadu

## Optimální odhad podle střední kvadratické chyby - MS

Definujme střední kvadratickou chybu jako střední hodnotu kvadrátu eukleidovské normy chyby odhadu  $\tilde{\mathbf{x}}$

$$J = E [\tilde{\mathbf{x}}^T \tilde{\mathbf{x}}] = E [(\mathbf{x} - \hat{\mathbf{x}}(\mathbf{z}))^T (\mathbf{x} - \hat{\mathbf{x}}(\mathbf{z}))] .$$

Odhad podle střední kvadratické chyby je speciální případ tzv. Bayesova odhadu, kde se hledá odhad minimalizující Bayesovo riziko

$$J = E [C(\tilde{\mathbf{x}})] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} C(\mathbf{x} - \hat{\mathbf{x}}(\mathbf{z})) p_{\mathbf{xz}}(\mathbf{x}, \mathbf{z}) d\mathbf{x} d\mathbf{z}$$

kde  $C()$  je penalizační, kritériální funkce.



# Klasická teorie odhadu

## Optimální odhad podle střední kvadratické chyby - MS

Interpretace: použití veškeré dostupné informace k nalezení optimálního odhadu  $\hat{x}$  minimalizující kritérium střední kvadratické chyby.

dostupná informace:

1. Existuje pouze informace o statistice  $x$ , o pravděpodobnostním rozložení.
2. Existuje apriorní informace o statistikách  $x$  a  $z$ , a navíc je k dispozici hodnota měření  $z$ .



# Klasická teorie odhadu

## MS odhad při znalosti pouze apriorní informace

Předpokládejme, že nemáme žádné měření  $\mathbf{z}$ , ale známe apriorní statistiky neznámé  $\mathbf{x}$ , tedy že známe  $p_{\mathbf{x}}(\mathbf{x})$ .

$$J(\hat{\mathbf{x}}) = E [(\mathbf{x} - \hat{\mathbf{x}})^T (\mathbf{x} - \hat{\mathbf{x}})] = E [\mathbf{x}^T \mathbf{x}] - 2\hat{\mathbf{x}}^T E [\mathbf{x}] + \hat{\mathbf{x}}^T \hat{\mathbf{x}}.$$

Derivací předchozího výrazu je zřejmé

$$\frac{\partial J}{\partial \hat{\mathbf{x}}} = -2E [\mathbf{x}] + 2\hat{\mathbf{x}},$$

a tedy

$$\hat{\mathbf{x}}_{MS} = E [\mathbf{x}].$$

Nejlepší konstanta jako odhad  $\hat{\mathbf{x}}_{MS}$  je  $E [\mathbf{x}]$ .



# Klasická teorie odhadu

## MS odhad při znalosti pouze apriorní informace

Odhad je nestranný

$$E[\tilde{x}] = E[x - \hat{x}] = E[x] - \hat{x} = E[x] - E[x] = 0.$$

$$E[\tilde{x}] = 0$$

nebo ekvivalentně

$$E[\hat{x}] = E[x].$$



Míru důvěry v odhad vyjadřuje kovariance chyby

$$\begin{aligned}\mathbf{P}_{\tilde{\mathbf{x}}} &= E[(\tilde{\mathbf{x}} - E[\tilde{\mathbf{x}}])(\tilde{\mathbf{x}} - E[\tilde{\mathbf{x}}])^T] = E[\tilde{\mathbf{x}}\tilde{\mathbf{x}}^T] = E[(\mathbf{x} - \hat{\mathbf{x}})(\mathbf{x} - \hat{\mathbf{x}})^T] \\ &= E[(\mathbf{x} - E[\mathbf{x}])(\mathbf{x} - E[\mathbf{x}])^T]\end{aligned}$$

což je apriorní kovarianční matice veličiny  $\mathbf{x}$ .

Apriorní kovarianční matice  $\mathbf{P}_{\mathbf{x}}$  je tedy rovna kovarianci chyby

$$\mathbf{P}_{\tilde{\mathbf{x}}} = \mathbf{P}_{\mathbf{x}}.$$



# Klasická teorie odhadu

## MS odhad využitím apriorní informace i měření

Předpokládejme, že navíc ke statistice  $\mathbf{x}$  známe i statistiku  $\mathbf{z}$ , která je v nějakém vztahu k  $\mathbf{x}$ . Tento vztah obecně vyjádříme pomocí sdružené hustoty pravděpodobnosti.

$$p_{\mathbf{xz}}(\mathbf{x}, \mathbf{z}).$$

Optimální odhad podle střední kvadratické chyby závisí na (známých) měřeních, tedy  $\hat{\mathbf{x}}(\mathbf{z})$ . Tento odhad můžeme nazývat aposteriorním odhadem  $\mathbf{x}$ .

Abychom našli odhad  $\hat{\mathbf{x}}(\mathbf{z})$ , uvažujme kritérium

$$J = \tilde{\mathbf{x}}^T \tilde{\mathbf{x}} = \iint_{-\infty}^{\infty} (\mathbf{x} - \hat{\mathbf{x}}(\mathbf{z}))^T (\mathbf{x} - \hat{\mathbf{x}}(\mathbf{z})) p_{\mathbf{xz}}(\mathbf{x}, \mathbf{z}) d\mathbf{x} d\mathbf{z}.$$



# Klasická teorie odhadu

## MS odhad využitím apriorní informace i měření

Použitím Bayesova pravidla

$$p_{\mathbf{x},\mathbf{z}}(\mathbf{x}, \mathbf{z}) = p_{\mathbf{x}|\mathbf{z}}(\mathbf{x}|\mathbf{z})p_{\mathbf{z}}(\mathbf{z})$$

můžeme předchozí vztah přepsat následujícím způsobem

$$J = \int_{-\infty}^{\infty} p_{\mathbf{z}}(\mathbf{z}) \int_{-\infty}^{\infty} (\mathbf{x} - \hat{\mathbf{x}}(\mathbf{z}))^T (\mathbf{x} - \hat{\mathbf{x}}(\mathbf{z})) p_{\mathbf{x}|\mathbf{z}}(\mathbf{x}|\mathbf{z}) d\mathbf{x} d\mathbf{z}.$$

V tomto případě lze minimalizovat pouze vnitřní integrál

$$J_V = \int_{-\infty}^{\infty} (\mathbf{x} - \hat{\mathbf{x}}(\mathbf{z}))^T (\mathbf{x} - \hat{\mathbf{x}}(\mathbf{z})) p_{\mathbf{x}|\mathbf{z}}(\mathbf{x}|\mathbf{z}) d\mathbf{x}.$$



# Klasická teorie odhadu

## MS odhad využitím apriorní informace i měření

Optimální odhad lze najít takto

$$\begin{aligned} J_V &= E \left[ (\mathbf{x} - \hat{\mathbf{x}}(\mathbf{z}))^T (\mathbf{x} - \hat{\mathbf{x}}(\mathbf{z})) \mid \mathbf{z} \right] \\ &= E [\mathbf{x}^T, \mathbf{x} \mid \mathbf{z}] - 2\hat{\mathbf{x}}^T(\mathbf{z}) E [\mathbf{x} \mid \mathbf{z}] + \hat{\mathbf{x}}^T(\mathbf{z}) \hat{\mathbf{x}}(\mathbf{z}). \end{aligned}$$

Derivací kritéria podle  $\hat{\mathbf{x}}(\mathbf{z})$  dostaneme

$$\frac{\partial J_V}{\partial \hat{\mathbf{x}}(\mathbf{z})} = -2E [\mathbf{x} \mid \mathbf{z}] + 2\hat{\mathbf{x}}(\mathbf{z}) = 0,$$

tedy

$$\hat{\mathbf{x}}_{MS}(\mathbf{z}) = E [\mathbf{x} \mid \mathbf{z}].$$



# Klasická teorie odhadu

## MS odhad využitím apriorní informace i měření

Pokud měření  $z$  neobsahuje informaci o  $\mathbf{x}$ , tedy

$p_{\mathbf{x}z}(\mathbf{x}, \mathbf{z}) = p_{\mathbf{x}}(\mathbf{x})p_{\mathbf{z}}(\mathbf{z})$  pak

$$E[\mathbf{x}|\mathbf{z}] = \int \mathbf{x} p_{\mathbf{x}|\mathbf{z}}(\mathbf{x}|\mathbf{z}) d\mathbf{x} = \int \mathbf{x} \frac{p_{\mathbf{x},\mathbf{z}}(\mathbf{x}, \mathbf{z})}{p_{\mathbf{z}}(\mathbf{z})} d\mathbf{x} = \int \mathbf{x} \frac{p_{\mathbf{x}}(\mathbf{x}) p_{\mathbf{z}}(\mathbf{z})}{p_{\mathbf{z}}(\mathbf{z})} = E[\mathbf{x}].$$

Odhad ve smyslu podmíněné střední hodnoty je nestranný

$$\begin{aligned} 0 &= E[\tilde{\mathbf{x}}] = E[E[\tilde{\mathbf{x}}|\mathbf{z}]] = E[E[\mathbf{x} - \hat{\mathbf{x}}|\mathbf{z}]] = E[E[\mathbf{x} - E[\mathbf{x}|\mathbf{z}]|\mathbf{z}]] \\ &= E[E[\mathbf{x}|\mathbf{z}] - E[E[\mathbf{x}|\mathbf{z}]\mathbf{z}]] = E[E[\mathbf{x}|\mathbf{z}] - E[\mathbf{x}|\mathbf{z}]] = 0. \end{aligned}$$



# Klasická teorie odhadu

## MS odhad využitím apriorní informace i měření

Míra důvěry v odhad je opět dána kovariancí chyby, tedy

$$\begin{aligned}\mathbf{P}_{\tilde{\mathbf{x}}} &= E \left[ (\tilde{\mathbf{x}} - E[\tilde{\mathbf{x}}]) (\tilde{\mathbf{x}} - E[\tilde{\mathbf{x}}])^T \right] = E [\tilde{\mathbf{x}} \tilde{\mathbf{x}}^T] \\ &= E \left[ (\mathbf{x} - \hat{\mathbf{x}}) (\mathbf{x} - \hat{\mathbf{x}})^T \right] = E \left[ E \left[ (\mathbf{x} - E[\mathbf{x}|\mathbf{z}]) (\mathbf{x} - E[\mathbf{x}|\mathbf{z}])^T | \mathbf{z} \right] \right] \\ &= E [\mathbf{P}_{\mathbf{x}|\mathbf{z}}]\end{aligned}$$

A tedy

$$\mathbf{P}_{\tilde{\mathbf{x}}} = E [\mathbf{P}_{\mathbf{x}|\mathbf{z}}] .$$



# Klasická teorie odhadu

## MS odhad při omezení na strukturu estimátoru

Omezíme se nyní na speciální případ, kdy odhady  $\hat{\mathbf{x}}(\mathbf{z})$ , které vykazují lineární závislost na měření  $\mathbf{z}$

$$\hat{\mathbf{x}}(\mathbf{z}) = \mathbf{A}\mathbf{z} + \mathbf{b},$$

kde  $\mathbf{A}$  je konstantní matice,  $\mathbf{A} \in \mathbb{R}^{n \times p}$  a  $\mathbf{b} \in \mathbb{R}^n$ .

Cílem je najít matici  $\mathbf{A}$  a vektor  $\mathbf{b}$  pro kritérium ve smyslu střední kvadratické chyby

$$J = E \left[ (\mathbf{x} - \hat{\mathbf{x}}(\mathbf{z}))^T (\mathbf{x} - \hat{\mathbf{x}}(\mathbf{z})) \right].$$



# Klasická teorie odhadu

## MS odhad při omezení na strukturu estimátoru

Dosazením struktury estimátoru do kritéria dostaneme

$$\begin{aligned} J &= E \left[ (\mathbf{x} - \hat{\mathbf{x}})^T (\mathbf{x} - \hat{\mathbf{x}}) \right] = \text{tr} E \left[ (\mathbf{x} - \hat{\mathbf{x}}) (\mathbf{x} - \hat{\mathbf{x}})^T \right] \\ &= \text{tr} E \left[ [(\mathbf{x} - E[\mathbf{x}]) - (\mathbf{A}\mathbf{z} + \mathbf{b} - E[\mathbf{x}])] [(\mathbf{x} - E[\mathbf{x}]) - (\mathbf{A}\mathbf{z} + \mathbf{b} - E[\mathbf{x}])]^T \right] \\ &= \text{tr} \left[ \mathbf{P}_x + \mathbf{A} \left( \mathbf{P}_z + E[\mathbf{z}] E[\mathbf{z}]^T \right) \mathbf{A}^T + (\mathbf{b} - E[\mathbf{x}]) (\mathbf{b} - E[\mathbf{x}])^T \right. \\ &\quad \left. + 2\mathbf{A}\mathbf{z}((\mathbf{b} - E[\mathbf{x}])^T - 2\mathbf{A}\mathbf{P}_{zx}) \right]. \end{aligned}$$



# Klasická teorie odhadu

## MS odhad při omezení na strukturu estimátoru

Pro výpočet minima potřebujeme řešit

$$\frac{\partial J}{\partial \mathbf{b}} = 2(\mathbf{b} - \mathbf{E}[\mathbf{x}]) + 2\mathbf{A}\mathbf{E}[\mathbf{z}] = 0,$$

$$\frac{\partial J}{\partial \mathbf{A}} = 2\mathbf{A}(\mathbf{P}_z + \mathbf{E}[\mathbf{z}]\mathbf{E}[\mathbf{z}]^T) - 2\mathbf{P}_{xz} + 2(\mathbf{b} - \mathbf{E}[\mathbf{x}])\mathbf{E}[\mathbf{z}]^T = 0.$$

Z první rovnice dostaneme hodnotu vektoru  $\mathbf{b}$

$$\mathbf{b} = \mathbf{E}[\mathbf{x}] - \mathbf{A}\mathbf{E}[\mathbf{z}]$$

a po dosazení do druhé rovnice obdržíme

$$\mathbf{A}\mathbf{P}_z - \mathbf{P}_{xz} = 0$$

z čehož plyne

$$\mathbf{A} = \mathbf{P}_{xz}\mathbf{P}_z^{-1}.$$



# Klasická teorie odhadu

## MS odhad při omezení na strukturu estimátoru

Nejlepší lineární estimátor ve smyslu střední kvadratické chyby

$$\hat{\mathbf{x}}_{LMS} = E[\mathbf{x}] + \mathbf{P}_{xz} \mathbf{P}_z^{-1} (\mathbf{z} - E[\mathbf{z}])$$

► Pro

$$\hat{\mathbf{x}}_{MS}(\mathbf{z}) = E[\mathbf{x}|\mathbf{z}]$$

potřebujeme  $p_{x|z}(\mathbf{x}|\mathbf{z})$ .

► Pro

$$\hat{\mathbf{x}}_{LMS}(\mathbf{z}) = E[\mathbf{x}] + \mathbf{P}_{xz} \mathbf{P}_z^{-1} (\mathbf{z} - E[\mathbf{z}])$$

potřebujeme momenty 1. a 2. řádu  $E[\mathbf{x}]$ ,  $E[\mathbf{z}]$  a  $\mathbf{P}_{xz}$ ,  $\mathbf{P}_z$ .



# Klasická teorie odhadu

## MS odhad při omezení na strukturu estimátoru

Snadno lze dokázat, že  $\hat{\mathbf{x}}_{LMS}$  je nestranný

$$E[\tilde{\mathbf{x}}] = E[\mathbf{x} - \hat{\mathbf{x}}_{LMS}] = E[\mathbf{x}] - E[\mathbf{x}] = 0$$

a kovariance chyby je

$$\mathbf{P}_{\tilde{\mathbf{x}}} = E[(\tilde{\mathbf{x}} - E[\tilde{\mathbf{x}}])(\tilde{\mathbf{x}} - E[\tilde{\mathbf{x}}])^T] = E[\tilde{\mathbf{x}}\tilde{\mathbf{x}}^T] = \mathbf{P}_x - \mathbf{P}_{xz}\mathbf{P}_z^{-1}\mathbf{P}_{zx}.$$



# Klasická teorie odhadu

## Optimální odhad podle maximální věrohodnosti - ML

- ▶ Předpokládejme, že  $\mathbf{x}$  je deterministická neznámá veličina a  $\mathbf{z}$  je stochastická veličina. O veličině  $\mathbf{x}$  není nic dalšího známo. Apriorní informace existuje o veličině  $\mathbf{z}$  ve smyslu existence a znalosti parametrické hustoty  $p_z(\mathbf{z}; \mathbf{x})$ .
- ▶ Mějme měření  $\mathbf{z}$ , odhad ve smyslu maximální věrohodnosti(ML)  $\hat{\mathbf{x}}^{ML}$  je hodnota  $\mathbf{x}$ , která maximalizuje  $p_z(\mathbf{z}; \mathbf{x})$ , tedy věrohodnost, že  $\mathbf{x}$  je promítnuto v měření  $\mathbf{z}$ .
- ▶  $p_z(\mathbf{z}; \mathbf{x})$  nazývá věrohodnostní funkce. Za věrohodnostní funkci lze též považovat  $\ln p_z(\mathbf{z}; \mathbf{x})$ .



# Klasická teorie odhadu

## Optimální odhad podle maximální věrohodnosti - ML

Odhad ve smyslu maximální věrohodnosti může být nalezen z

$$\frac{\partial p_z(\mathbf{z}; \mathbf{x})}{\partial \mathbf{x}} \Big|_{\mathbf{x}=\hat{\mathbf{x}}} = 0$$

nebo

$$\frac{\partial \ln p_z(\mathbf{z}; \mathbf{x})}{\partial \mathbf{x}} \Big|_{\mathbf{x}=\hat{\mathbf{x}}} = 0$$

což jsou věrohodnostní rovnice.



# Klasická teorie odhadu

## ML odhad pro lineární měření a gaussovské poruchy

Předpokládejme, že existuje lineární vztah mezi měřením  $\mathbf{z}$  a neznámou veličinou  $\mathbf{x}$

$$\mathbf{z} = \mathbf{H}\mathbf{x} + \mathbf{v},$$

kde  $\mathbf{v}$  je šum měření s normálním rozložením

$$p_v(\mathbf{v}) = \frac{1}{\sqrt{(2\pi)^p |\mathbf{R}|}} e^{-\frac{1}{2} \mathbf{v}^T \mathbf{R}^{-1} \mathbf{v}}.$$

Pak je věrohodnostní funkce určena vztahem

$$p_z(\mathbf{z}; \mathbf{x}) = p_v(\mathbf{z} - \mathbf{H}\mathbf{x}) = \frac{1}{\sqrt{(2\pi)^p |\mathbf{R}|}} e^{-\frac{1}{2} (\mathbf{z} - \mathbf{H}\mathbf{x})^T \mathbf{R}^{-1} (\mathbf{z} - \mathbf{H}\mathbf{x})}.$$



# Klasická teorie odhadu

## ML odhad pro lineární měření a gaussovske poruchy

Maximalizace  $p_z(\mathbf{z}; \mathbf{x})$  může být provedena maximalizací  $\ln p_z(\mathbf{z}; \mathbf{x})$  nebo minimalizací

$$J = \frac{1}{2}(\mathbf{z} - \mathbf{H}\mathbf{x})^T \mathbf{R}^{-1}(\mathbf{z} - \mathbf{H}\mathbf{x})$$

. Derivací  $J$  podle  $\mathbf{x}$  dostaneme

$$\frac{\partial J}{\partial \mathbf{x}} = \mathbf{H}^T \mathbf{R}^{-1}(\mathbf{z} - \mathbf{H}\mathbf{x}) = 0.$$

takže optimální odhad je

$$\hat{\mathbf{x}}_{ML} = (\mathbf{H}^T \mathbf{R}^{-1} \mathbf{H})^{-1} \mathbf{H}^T \mathbf{R}^{-1} \mathbf{z}$$



Odhad je nestranný

$$\begin{aligned}\tilde{\mathbf{x}} &= \mathbf{x} - \hat{\mathbf{x}} = \mathbf{x} - (\mathbf{H}^T \mathbf{R}^{-1} \mathbf{H})^{-1} \mathbf{H}^T \mathbf{R}^{-1} (\mathbf{H} \mathbf{x} + \mathbf{v}) \\ &= -(\mathbf{H}^T \mathbf{R}^{-1} \mathbf{H})^{-1} \mathbf{H}^T \mathbf{R}^{-1} \mathbf{v},\end{aligned}$$

a tedy

$$\mathbb{E}[\tilde{\mathbf{x}}] = -(\mathbf{H}^T \mathbf{R}^{-1} \mathbf{H})^{-1} \mathbf{H}^T \mathbf{R}^{-1} \mathbb{E}[\mathbf{v}] = 0.$$

Kovariance chyby odhadu je

$$\mathbf{P}_{\tilde{\mathbf{x}}} = \mathbb{E} \left[ (\tilde{\mathbf{x}} - \mathbb{E}[\tilde{\mathbf{x}}]) (\tilde{\mathbf{x}} - \mathbb{E}[\tilde{\mathbf{x}}])^T \right] = (\mathbf{H}^T \mathbf{R}^{-1} \mathbf{H})^{-1}.$$



# Klasická teorie odhadu

## ML odhad pro lineární měření a gaussovské poruchy

Využitím  $\mathbf{P}_{\tilde{\mathbf{x}}}$  můžeme optimální odhad zapsat

$$\hat{\mathbf{x}}^{ML} = \mathbf{P}_{\tilde{\mathbf{x}}} \mathbf{H}^T \mathbf{R}^{-1} \mathbf{z}.$$

Absence apriorní informace o  $\mathbf{x}$  může být vyjádřena vztahy

$$\bar{\mathbf{x}} = \mathbf{0}$$

$$\mathbf{P}_{\mathbf{x}} \rightarrow \infty.$$

Pak jsou vztahy pro střední kvadratickou chybu a maximální věrohodnost v limitě stejné.



# Bayesovský přístup

1. Uvažujme náhodný vektor  $z = [z_1, z_2, \dots, z_N]^T$  s hustotou pravděpodobnosti  $p(z; \Theta)$ , kde  $\Theta = [\Theta_1, \Theta_2, \dots, \Theta_I]^T$  je vektor parametrů.
2. Při klasickém přístupu k problému odhadu  $\Theta$  považujeme parametry za neznámé konstanty a k závěrům o  $\Theta$  použijeme pouze  $z$  a tvar rozdělení  $z$ .
3. Při bayesovském přístupu k závěrům o parametru  $\Theta$ , tentokrát chápaného jako náhodná proměnná použijeme kromě toho ještě apriorní informaci o parametru  $\Theta$ , kterou máme k dispozici nezávisle na realizaci  $z$ .
4. Apriorní informace se vyjadřuje předpokladem, že  $\Theta$  je náhodný vektor s jistým rozložením. Tato informace může mít **objektivní** i **subjektivní** charakter.



# Bayesovský přístup

## Odhad parametru

Aposteriorní hustota pravděpodobnosti  $\Theta$  pro dané  $z^k$  je podle Bayesova pravidla (Thomas Bayes 1761)

$$p(\Theta | z^k) = \frac{p(z^k | \Theta) \cdot p(\Theta)}{p(z^k)}$$

kde  $p(z^k) = \int p(z^k | \Theta) \cdot p(\Theta) d\Theta$ .

Za předpokladu, že  $\Theta$  a  $v^k = (v_0, v_1, \dots, v_k)$  jsou nezávislé,  $p(z^k | \Theta)$  je známa z  $p(v^k)$ , protože vycházíme z platnosti modelu měření

$$z_k = h_k(\Theta) + v_k \quad k = 0, 1, 2, \dots$$

a tedy

$$p(z^k | \Theta) = \prod_{j=0}^k p_{v_j}(z_j - h(\Theta)).$$



# Bayesovský přístup

## Odhad stavu

Určení podmíněné hustoty pravděpodobnosti  $p(x_k | z^l)$  nebo odhadu  $x_k$  na základě pozorování  $z^l$

$k = l$ : filtrace

$l > k$ : vyhlazování

$k > l$ : predikce



# Bayesovský přístup

## Obecné řešení problému odhadu stavu

$$x_{k+1} = f_k(x_k) + w_k \quad k = 0, 1, 2, \dots$$

Náhodný proces  $\{w_k\}$  je bílý šum se známou hustotou pravděpodobnosti  $p(w_k)$  a  $p(x_0)$  je známa.

$$z_k = h_k(x_k) + v_k \quad k = 0, 1, 2, \dots$$

Náhodný proces  $\{v_k\}$  je bílý šum se známou hustotou pravděpodobnosti  $p(v_k)$ .

Cílem je určení podmíněné hustoty pravděpodobnosti  $p(x_k | z^I)$ .



### Výpočet aposteriorní filtrační hustoty

Předpokládejme, že bílé šумы  $\{v_k\}$ ,  $\{w_k\}$  jsou nezávislé a rovněž jsou nezávislé na  $x_0$ . Pak aposteriorní hustota pravděpodobnosti nebo alternativně filtrační hustota pravděpodobnosti může být určena rekurzivně

$$p(x_k | z^k) = \frac{p(z_k | x_k) \cdot p(x_k | z^{k-1})}{p(z_k | z^{k-1})}$$

$$\text{kde } p(z_k | z^{k-1}) = \int p(z_k | x_k) p(x_k | z^{k-1}) dx_k.$$



### Výpočet prediktivní hustoty

Vývoj stavu je popsán

$$\begin{aligned} p(x_k | z^{k-1}) &= \int p(x_k, x_{k-1} | z^{k-1}) dx_{k-1} \\ &= \int p(x_k | x_{k-1}) \cdot p(x_{k-1} | z^{k-1}) dx_{k-1} \end{aligned}$$

přičemž  $p(x_k | x_{k-1})$  je určeno  $p(w_{k-1})$ .



# Bayesovský přístup

## Obecné řešení problému odhadu stavu

filtrační hustota

$$p(x_k | z^k) = \frac{p(x_k | z^{k-1}) \cdot p(z_k | x_k)}{p(z_k | z^{k-1})}$$

prediktivní hustota

$$p(x_k | z^{k-1}) = \int_{-\infty}^{\infty} p(x_{k-1} | z^{k-1}) p(x_k | x_{k-1}) dx_{k-1}$$

kde

$$p(z_k | z^{k-1}) = \int_{-\infty}^{\infty} p(x_k | z^{k-1}) p(z_k | x_k) dx_k$$



# Lineární filtrace

## Lineární gaussovský systém

Uvažujme lineární gaussovský stochastický systém

$$x_{k+1} = F_k x_k + w_k \quad k = 0, 1, 2, \dots$$

$$z_k = H_k x_k + v_k \quad k = 0, 1, 2, \dots$$

1.  $\{v_k\}$  a  $\{w_k\}$  jsou bílé šумы
2.  $\{v_k\}$  a  $\{w_k\}$  jsou gaussovské s nulovou střední hodnotou
3.  $\{v_k\}$  a  $\{w_k\}$  jsou nezávislé

$$E[v_k v_l^T] = R_k \delta_{k,l}$$


$$E[w_k w_l^T] = Q_k \delta_{k,l}$$

$$E[x_0] = \bar{x}_0 = \hat{x}'_0 \quad E[(x_0 - \bar{x}_0)(x_0 - \bar{x}_0)^T] = \Sigma_0 = P'_0.$$



# Lineární filtrace

## Lineární gaussovský systém



Signálový model lineárního systému.



# Lineární filtrace

## Bayesovský přístup k syntéze filtru

- ▶ Pro aplikaci bayesovského přístupu potřebujeme rozhodnout, zda začít počítat filtrační nebo prediktivní hustotu.
- ▶ Přírozené je začít filtrací pro krok  $k = 0$ .
- ▶ Je nutné znát
  - ▶  $p(\mathbf{x}_k | \mathbf{z}^{k-1})$  - prediktivní hustota
  - ▶  $p(\mathbf{z}_k | \mathbf{x}_k)$  - hustota měření
  - ▶  $p(\mathbf{z}_k | \mathbf{z}^{k-1})$  - normalizační konstanta.



Prediktivní hustota

$$p(x_0 | z^{-1}) = N(x_0 : \hat{x}'_0, P'_0)$$

$$\begin{aligned} \text{kde } E(x_0 | z^{-1}) &= \hat{x}'_0 \\ \text{cov}(x_0 | z^{-1}) &= P'_0. \end{aligned}$$

$N(x_0 : \hat{x}'_0, P'_0)$  označuje, že náhodná veličina  $x_0$  má normální rozložení se střední hodnotou  $\hat{x}'_0$  a kovariancí  $P'_0$ .



# Lineární filtrace

## Bayesovský přístup k syntéze filtru

Hustotu měření  $p(z_k | x_k)$  snadno získáme

$$p(z_0 | x_0) = N(z_0 : H_0 x_0, R_0).$$

Normalizační konstantu

$$p(z_0 | z^{-1}) = N(z_0 : H_0 \hat{x}'_0, H_0 P'_0 H_0^T + R_0).$$

určíme takto

$$\begin{aligned} E[z_0 | z^{-1}] &= E[H_0 x_0 + v_0 | z^{-1}] = H_0 \hat{x}'_0 \\ E[(z_0 - \hat{z}_0)(z_0 - \hat{z}_0)^T | z^{-1}] &= E[(H_0 x_0 + v_0 - H_0 \hat{x}'_0) \\ &\quad (H_0 x_0 + v_0 - H_0 \hat{x}'_0)^T | z^{-1}] \\ &= H_0 P'_0 H_0^T + R_0. \end{aligned}$$



# Lineární filtrace

## Bayesovský přístup k syntéze filtru

Nyní můžeme dosadit do Bayesova vztahu pro filtrační hustotu

$$\begin{aligned} p(x_0 | z^0) &= \frac{p(x_0 | z^{-1})p(z_0 | x_0)}{p(z_0 | z^{-1})} = \frac{N(z_0 : H_0 x_0, R_0)N(x_0 : \hat{x}'_0, P'_0)}{N(z_0 : H_0 \hat{x}'_0, H_0 P'_0 H_0^T + R_0)} \\ &= \frac{1}{(2\pi)^{nz/2}(\det R_0)^{1/2}} e^{-\frac{1}{2}[z_0 - H_0 x_0]^T R_0^{-1}[z_0 - H_0 x_0]} \\ &\times \frac{1}{(2\pi)^{nx/2}(\det P'_0)^{1/2}} e^{-\frac{1}{2}[x_0 - \hat{x}'_0]^T P'^{-1}_0[x_0 - \hat{x}'_0]} \\ &\times \frac{(2\pi)^{nz/2}[\det(H_0 P'_0 H_0^T + R_0)]^{1/2}}{e^{-\frac{1}{2}[z_0 - H_0 \hat{x}'_0]^T [H_0 P'_0 H_0^T + R_0]^{-1}[z_0 - H_0 \hat{x}'_0]}}. \end{aligned}$$



# Lineární filtrace

## Bayesovský přístup k syntéze filtru

Po relativně zdlouhavých úpravách lze dokázat, že

$$p(x_0 | z_0) = N(x_0 : \hat{x}_0, P_0).$$

$$\hat{x}_0 = \hat{x}'_0 + P'_0 H_0^T [R_0 + H_0 P'_0 H_0^T]^{-1} [z_0 - H_0 \hat{x}'_0]$$

$$P_0 = P'_0 - P'_0 H_0^T [R_0 + H_0 P'_0 H_0^T]^{-1} H_0 P'_0$$

kde

$$\hat{x}'_0 = E[x_0 | z^{-1}] = \bar{x}_0$$

$$P'_0 = \text{cov}[x_0 | z^{-1}] = \Sigma_0.$$



# Lineární filtrace

## Bayesovský přístup k syntéze prediktoru

Odvození prediktivní hustoty pravděpodobnosti  $p(x_1 | z^0)$

přechodovou hustotu lze spočítat z modelu systému

$$p(x_1 | x_0) = N(x_1 : F_0 x_0, Q_0)$$

kde

$$\begin{aligned} E[x_1 | x_0] &= E[F_0 x_0 + w_0 | x_0] = F_0 x_0 \\ E[(x_1 - \hat{x}'_1)((x_1 - \hat{x}'_1)^T | x_0] &= E[(F_0 x_0 - F_0 x_0 + w_0) \\ &\quad (F_0 x_0 - F_0 x_0 + w_0)^T | x_0] \\ &= E[w_0 w_0^T | x_0] = Q_0. \end{aligned}$$



# Lineární filtrace

## Bayesovský přístup k syntéze prediktoru

Dosazením do Bayesova vztahu

$$\begin{aligned} p(x_1 | z^0) &= \int N(x_0 : \hat{x}_0, P_0) N(x_1 : F_0 x_0, Q_0) dx_0 \\ &= \int \frac{1}{(2\pi)^{n_x/2} \cdot (\det P_0)^{1/2}} e^{-\frac{1}{2} [x_0 - \hat{x}_0]^T P_0^{-1} [x_0 - \hat{x}_0]} \\ &\quad \times \frac{1}{(2\pi)^{n_x/2} (\det Q_0)^{1/2}} e^{-\frac{1}{2} [x_1 - F_0 x_0]^T Q_0^{-1} [x_1 - F_0 x_0]} dx_0 \\ &= \frac{1}{(2\pi)^{n_x} (\det P_0)^{1/2} (\det Q_0)^{1/2}} \\ &\quad \times \int e^{-\frac{1}{2} \{ [x_0 - \hat{x}_0]^T P_0^{-1} [x_0 - \hat{x}_0] + [x_1 - F_0 x_0]^T Q_0^{-1} [x_1 - F_0 x_0] \}} dx_0 \end{aligned}$$



# Lineární filtrace

## Bayesovský přístup k syntéze prediktoru

Po zdlouhavých úpravách dostaneme

$$p(x_1 | z^0) = N(x_1 : \hat{x}'_1, P'_1)$$

kde

$$\hat{x}'_1 = F_0 \hat{x}_0$$

$$P'_1 = F_0 P_0 F_0^T + Q_0$$

$$\hat{x}'_1 = E[x_1 | z^0]$$

$$P'_1 = cov[x_1 | z^0].$$



# Lineární filtrace

## Kalmanův filtr ve formě filtr - prediktor

Výpočet filtrační hustoty pravděpodobnosti:

$$p(x_k | z^k) = N(x_k : \hat{x}_k, P_k) \quad k = 0, 1, 2, \dots$$

$$\hat{x}_k = \hat{x}'_k + P'_k H_k^T [R_k + H_k P'_k H_k^T]^{-1} [z_k - H_k \hat{x}'_k]$$

$$P_k = P'_k - P'_k H_k^T [R_k + H_k P'_k H_k^T]^{-1} H_k P'_k.$$

Výpočet prediktivní hustoty pravděpodobnosti:

$$p(x_{k+1} | z^k) = N(x_{k+1} : \hat{x}'_{k+1}, P'_{k+1}) \quad k = 0, 1, 2, \dots$$

$$\hat{x}'_{k+1} = F_k \hat{x}_k$$

$$P'_{k+1} = F_k P_k F_k^T + Q_k$$



# Lineární filtrace

## Kalmanův filtr ve formě prediktor

### ► Prediktor

$$\hat{x}'_{k+1} = F_k[\hat{x}'_k + P'_k H_k^T (R_k + H_k P'_k H_k^T)^{-1} (z_k - H_k \hat{x}'_k)]$$

$$P'_{k+1} = F_k[P'_k - P'_k H_k^T (R_k + H_k P'_k H_k^T)^{-1} H_k P'_k] F_k^T + Q_k$$



$$\hat{x}'_{k+1} = (F_k - K'_k H_k) \hat{x}'_k + K'_k z_k$$

### ► Kalmanovy zisky


$$K_k = P'_k H_k^T (R_k + H_k P'_k H_k^T)^{-1}$$

$$K'_k = F_k P'_k H_k^T (R_k + H_k P'_k H_k^T)^{-1}$$



# Lineární filtrace

## Kalmanův filtr ve formě prediktor




Signálový model prediktoru



# Lineární filtrace

## Kalmanův filtr ve formě prediktor



Signálový model prediktoru podle obsahující "kopii" struktury systému, jehož stav je odhadován



# Lineární filtrace

## Zajímavý vedlejší výsledek

- ▶ Analytické řešení násobení normálních hustot

$$N(x_k : \hat{x}_k, P_k) = \frac{N(x_k : \hat{x}'_k, P'_k) N(z_k : H_k x_k, R_k)}{N(z_k : H_k \hat{x}'_k, H_k P'_k H_k^T + R_k)}$$

- ▶ Analytické řešení konvoluce

$$N(x_{k+1} : \hat{x}'_{k+1}, P'_{k+1}) = \int N(x_k : \hat{x}_k, P_k) N(x_{k+1} : F_k x_k, Q_k) dx_k$$



### Příklad 1:

Uvažujme skalární rovnici měření

$$z = x + v$$

$$\begin{aligned} p(x) &= \frac{1}{2} & x \in (-1, 1) \\ &= 0 & \text{jinak} \end{aligned}$$

$$\begin{aligned} p(v) &= \frac{1}{2} & v \in (-1, 1) \\ &= 0 & \text{jinak} \end{aligned}$$

Cílem je spočítat  $p(x | z)$  a  $E(x | z)$ ,  $\text{cov}(x | z)$ .



# Základy nelineární filtrace

## Motivační příklady

Aproximační řešení náhradou  $p(x)$  a  $p(z)$  normálním rozložením

$$p_x(x) = \mathcal{N}\{x; 0, \frac{1}{3}\}$$

$$p_v(v) = \mathcal{N}\{v; 0, \frac{1}{3}\}$$

$$p(x|z) = \mathcal{N}\{x; \hat{x}, P\}$$

$$\hat{x} = \frac{1}{2}z$$

$$P = \frac{1}{6}$$



# Základy nelineární filtrace

## Motivační příklady

$$p(x | z) = \frac{p(z | x)p(x)}{p(z)} = \frac{p(z - x)p(x)}{\int p(z - x)p(x)dx}$$

kde

$$\begin{aligned} p(z - x) &= \frac{1}{2} & z \in (-1 + x, 1 + x) \\ &= 0 & \text{jinak} \end{aligned}$$

$$\begin{aligned} p(z) &= \frac{z + 2}{4} & z \in (-2, 0) \\ &= \frac{2 - z}{4} & z \in (0, 2) \\ &= 0 & \text{jinak} \end{aligned}$$



# Základy nelineární filtrace

## Motivační příklady

$$p(x | z) = \frac{[\text{sign}(1+z-x) - \text{sign}(-1+z-x)][\text{sign}(x+1) - \text{sign}(x-1)]}{2[2 - z\text{sign}(z)][\text{sign}(z+2) - \text{sign}(z-2)]}$$

$$E(x | z) = z/2$$

podmíněná kovariance pro  $z \in (0, 2)$  je funkcí  $z$

$$\text{cov}(x | z) = \frac{1}{3(2-z)}[1 - (z-1)^3] - \frac{z^2}{4}$$

pro  $z \in (-2, 0)$


$$\text{cov}(x | z) = \frac{1}{3(z+2)}[1 + (z+1)^3] - \frac{z^2}{4}$$

opět funkcí  $z$ .



# Základy nelineární filtrace

## Motivační příklady



Podmíněná hustota pravděpodobnosti a střední hodnota



### Příklad 2:

Uvažujme skalární nelineární stavovou rovnici

$$x_{k+1} = f_k x_k + g_k x_k^2 + w_k$$

a dále předpokládejme

$$\begin{aligned} E(x_k | z^k) &= \hat{x}_k \\ E[(x_k - \hat{x}_k)^2 | z^k] &= P_k. \end{aligned}$$

Cílem je vypočítat

$$E(x_{k+1} | z^k) = \hat{x}'_{k+1} \quad a \quad cov(x_{k+1} | z^k) = P'_{k+1}.$$



# Základy nelineární filtrace

## Motivační příklady

Začneme střední hodnotou

$$\begin{aligned}\hat{x}'_{k+1} &= f_k E[x_k | z^k] + g_k E[x_k^2 | z^k] \\ &= f_k \hat{x}_k + g_k (P_k + \hat{x}_k^2)\end{aligned}$$

pro výpočet predikované střední hodnoty potřebujeme filtrační střední hodnotu a kovarianci

$$\begin{aligned}E(\tilde{x}_{k+1}^2 | z^k) &= (f_k + 2g_k \hat{x}_k)^2 E[\tilde{x}_k^2 | z^k] + g_k^2 E(\tilde{x}_k^4 | z^k) \\ &+ g_k^2 P_k^2 + E(w_k^2 | z^k) + 2g_k(f_k + 2g_k \hat{x}_k) E(\tilde{x}_k^3 | z^k) \\ &- 2g_k P_k (f_k + 2g_k \hat{x}_k) E(\tilde{x}_k | z^k) \\ &- 2g_k^2 P_k E(\tilde{x}_k^2 | z^k) = (f_k + 2g_k \hat{x}_k)^2 P_k + g_k^2 \gamma_k \\ &- g_k^2 P_k + Q_k + 2g_k(f_k + 2g_k \hat{x}_k) \delta_k\end{aligned}$$

$$\text{kde } \gamma \triangleq E(\tilde{x}_k^4 | z^k) \quad \delta_k \triangleq E[\tilde{x}_k^3 | z^k].$$



# Základy nelineární filtrace

## Lokální metody

- ▶ Lokální metody
  - ▶ aproximace nelineárních funkcí systému
  - ▶ výsledky mají lokální platnost
  - ▶ EKF, iterační filtry, filtr druhého řádu, bezderivační filtry (unscentovaná transformace, difference, ne derivate)
- ▶ Globální metody
  - ▶ pokrytí celého stavového prostoru
  - ▶ globální platnost



# Základy nelineární filtrace

## Rozšířený Kalmanův filtr

Uvažujme systém

$$x_{k+1} = f_k(x_k) + w_k$$

$$z_k = h_k(x_k) + v_k$$

$$p(x_0) = N(x_0 : \hat{x}_0', P_0)$$

$$p(w_k) = N(w_k : 0, Q_k)$$

$$p(v_k) = N(v_k : 0, R_k)$$



# Základy nelineární filtrace

## Rozšířený Kalmanův filtr

Analytická řešitelnost filtračního kroku - diskuse

$$p(z_k | x_k) = N(z_k : h_k(x_k), R_k)$$

$$p(x_0 | z^0) = \frac{N(x_0 : \hat{x}'_0, P'_0) N(z_0 : h_0(x_0), R_0)}{\int N(x_0 : \hat{x}'_0, P'_0) N(z_0 : h_0(x_0), R_0) dx_0}$$

nejde analyticky řešit, protože  $h(x_0)$  je nelineární funkce.



# Základy nelineární filtrace

## Rozšířený Kalmanův filtr

Aproximace nelineární funkce měření

$$h_0(x_0) \simeq h_0(\hat{x}'_0) + H_0(\hat{x}'_0)(x_0 - \hat{x}'_0)$$

kde

$$H_0(\hat{x}'_0) = \frac{\partial h_0(x_0)}{\partial x_0} \Big|_{\hat{x}'_0}.$$

Taylorův rozvoj  $h_0(x_0)$  na okolí bodu  $\hat{x}'_0 = E(x_0 | z^{-1})$ .



# Základy nelineární filtrace

## Rozšířený Kalmanův filtr

Bayesův vztah je analyticky řešitelný

$$p_A(x_0 | z^0) = \frac{N(x_0 : \hat{x}'_0, P'_0) N(z_0 : h_0(\hat{x}'_0) + H_0(\hat{x}'_0)(x_0 - \hat{x}'_0), R_0)}{\int N(x_0 : \hat{x}'_0, P'_0) N(z_0 : h_0(\hat{x}'_0) + H_0(\hat{x}'_0)(x_0 - \hat{x}'_0), R_0) dx_0}$$

protože

$$H_0(\hat{x}'_0)x_0 + h_0(\hat{x}'_0) - H_0(\hat{x}'_0)\hat{x}'_0$$

je lineární funkce.



# Základy nelineární filtrace

## Rozšířený Kalmanův filtr

Aproximační filtrační hustota pravděpodobnosti

$$p_A(x_0 | z^0) = N(x_0 : \hat{x}_0, P_0)$$

$$\hat{x}_0 = \hat{x}'_0 + P'_0 H_0^T(\hat{x}'_0) [H_0(\hat{x}'_0) P'_0 H_0^T(\hat{x}'_0) + R_0]^{-1} [z_0 - h_0(\hat{x}'_0)]$$

$$P_0 = P'_0 - P'_0 H_0^T(\hat{x}'_0) [H_0(\hat{x}'_0) P'_0 H_0^T(\hat{x}'_0) + R_0]^{-1} H_0(\hat{x}'_0) P'_0$$

$H_0^T(\hat{x}'_0)$  je funkce měření.



Analytická řešitelnost prediktivního kroku - diskuse

$$p(x_1 | z^0) = \int p(x_0 | z^0) p(x_1 | x_0) dx_0$$

$$p(x_1 | x_0) = \mathcal{N}\{x_1 : f(x_0), Q_0\}$$

$$p_A(x_1 | z^0) = \int N(x_0 : \hat{x}_0, P_0) N(x_1 : f_0(x_0), Q_0) dx_0$$

nejde analyticky řešit, protože  $f(x_0)$  je nelineární funkce.



# Základy nelineární filtrace

## Rozšířený Kalmanův filtr

Aproximace nelineární funkce dynamiky

Taylorův rozvoj funkce  $f_0(x_0)$  na okolí  $\hat{x}_0$

$$f_0(x_0) \simeq f_0(\hat{x}_0) + F_0(\hat{x}_0)(x_0 - \hat{x}_0)$$

$$F_0(\hat{x}_0) = \left. \frac{\partial f(x_0)}{\partial x_0} \right|_{\hat{x}_0}$$



# Základy nelineární filtrace

## Rozšířený Kalmanův filtr

Bayesův vztah analyticky řešitelný

$$p_A(x_1 | z^0) = \int N(x_0 : \hat{x}_0, P_0) N(x_1 : f_0(\hat{x}_0) + F_0(\hat{x}_0)(x_0 - \hat{x}_0), Q_0) dx_0$$

aproximační prediktivní hustota pravděpodobnosti

$$\begin{aligned} p_A(x_1 | z^0) &= N(x_1 : \hat{x}'_1, P'_1) \\ \hat{x}'_1 &= f_0(\hat{x}_0) \\ P'_1 &= F_0(\hat{x}_0)P_0F_0^T(\hat{x}_0) + Q_0 \end{aligned}$$

$$F_0(\hat{x}_0)x_0 + f_0(\hat{x}_0) - F_0(\hat{x}_0)\hat{x}_0$$

je lineární funkce.



# Základy nelineární filtrace

## Rozšířený Kalmanův filtr

Rozšířený Kalmanův filtr (EKF)

Aproximační filtrační hustota pravděpodobnosti:

$$p_A(x_k | z^k) = N(x_k : \hat{x}_k, P_k)$$

$$\hat{x}_k = \hat{x}'_k + P'_k H_k^T (\hat{x}'_k) [H_k(\hat{x}'_k) P'_k H_k(\hat{x}'_k) + R_k]^{-1} [z_k - h_k(\hat{x}'_k)]$$

$$P_k = P'_k - P'_k H_k^T (\hat{x}'_k) [H_k(\hat{x}'_k) P'_k H_k(\hat{x}'_k) + R_k]^{-1} H_k(\hat{x}'_k) P'_k$$

Aproximační prediktivní hustota pravděpodobnosti:

$$p_A(x_{k+1} | z^k) = N(x_{k+1} : \hat{x}'_{k+1}, P'_{k+1})$$

$$\hat{x}'_{k+1} = f_k(\hat{x}'_k)$$

$$P'_{k+1} = F_k(\hat{x}_k) P_k F_k^T(\hat{x}_k) + Q_k$$



### Vlastnosti EKF

1. Kovarianční matice  $P_k, P'_{k+1}$  není možné počítat off-line, protože jsou funkcemi měření
2. Filtrační a prediktivní hustoty jsou pouze aproximace skutečných hustot daných exaktním řešením problému na rozdíl od hustot generovaných Kalmanovým filtrem, které představují exaktní řešení problému.
3. Konvergence odhadu není zaručena
4. Oblíbený v praxi pro svoji jednoduchost



# Základy nelineární filtrace

## Filtr druhého řádu

Aproximace Taylorovou řadou s ponecháním i členů druhého řádu

$$h_k(x_k) \simeq h_k(\hat{x}'_k) + H_k(\hat{x}'_k)(x_k - \hat{x}'_k) + \frac{1}{2}(x_k - \hat{x}'_k)^T \frac{\partial^2 h_k}{\partial x_k^2} \bigg|_{\hat{x}'_k} (x_k - \hat{x}'_k)$$

kde

$$\frac{\partial^2 h_k}{\partial x_k^2} \bigg|_{\hat{x}'_k}$$

je soubor  $m$  matic  $\dim n \times n$  ( $\dim$  vektorové funkce  $h_k(\cdot)$  je  $m$  a  $\dim$  vektoru stavu  $x_k$  je  $n$ ).



$$h_k(\cdot) \triangleq [h_{1k}(\cdot), h_{2k}(\cdot), \dots, h_{mk}(\cdot)]$$

$$M_{ik} \triangleq \frac{\partial^2 h_{ik}}{\partial x_k^2} \Big|_{\hat{x}'_k} = \begin{bmatrix} \frac{\partial^2 h_{ik}}{\partial x_1 \partial x_1} & \frac{\partial^2 h_{ik}}{\partial x_1 \partial x_2} & \dots & \frac{\partial^2 h_{ik}}{\partial x_1 \partial x_n} \\ \vdots & \vdots & \vdots & \vdots \\ \frac{\partial^2 h_{ik}}{\partial x_n \partial x_1} & \dots & Idots & \frac{\partial^2 h_{ik}}{\partial x_n \partial x_n} \end{bmatrix}$$
$$i = 1, 2, \dots, m$$



# Základy nelineární filtrace

## Filtr druhého řádu

$$\bar{h}_{ik} \triangleq (x_k - \hat{x}'_k)^T M_{ik} (x_k - \hat{x}'_k)$$

$$\bar{h}_k \triangleq \begin{bmatrix} \bar{h}_{1k} \\ \bar{h}_{2k} \\ \vdots \\ \bar{h}_{mk} \end{bmatrix}$$

$$h_k(x_k) \simeq h_k(\hat{x}'_k) + H_k(\hat{x}'_k)(x_k - \hat{x}'_k) + \bar{h}_k$$



Náhrada střední hodnotou - odstranění nelinearity

$$\bar{h}_{ik} = (x_k - \hat{x}'_k)^T M_{ik} (x_k - \hat{x}'_k) \simeq \text{tr}(P'_k M_{ik}) \triangleq \bar{h}_{aik}$$

$$\bar{h}_{ak} = [\bar{h}_{a1k}, \bar{h}_{a2k}, \dots, \bar{h}_{amk}]^T$$

$$h_k(x_k) \simeq h_k(\hat{x}'_k) + H_k(\hat{x}'_k)(x_k - \hat{x}'_k) + \bar{h}_{ak}$$



Filtrační hustota pravděpodobnosti

$$p_A(x_k | z^k) = N(x_k : \hat{x}'_k, P_k)$$

$$\hat{x}_k = \hat{x}'_k + P'_k H_k^T (\hat{x}'_k) [H_k(\hat{x}'_k) P'_k H_k^T (\hat{x}'_k) + R_k]^{-1} [z_k - h_k(\hat{x}'_k) - \bar{h}_{ak}]$$

$$P_k = P'_k - P'_k H_k^T (\hat{x}'_k) [H_k(\hat{x}'_k) P'_k H_k^T (\hat{x}'_k) + R_k]^{-1} H_k(\hat{x}'_k) P'_k$$



# Základy nelineární filtrace

## Filtr druhého řádu

Rozvoj funkce  $f_k(\cdot)$  pro predikci

$$f_k(x_k) \simeq f_k(\hat{x}_k) + F_k(\hat{x}_k)(x_k - \hat{x}_k) + \bar{f}_k.$$

kde

$$\bar{f}_k \triangleq \begin{bmatrix} \bar{f}_{1k} \\ \bar{f}_{2k} \\ \vdots \\ \bar{f}_{nk} \end{bmatrix}$$



# Základy nelineární filtrace

## Filtr druhého řádu

$$\bar{f}_{ik} \triangleq (x_k - \hat{x}_k)^T N_{ik} (x_k - \hat{x}_k)$$

$$N_{ik} \triangleq \frac{\partial^2 f_{ik}}{\partial x_k^2} \Big|_{\hat{x}_k} = \begin{bmatrix} \frac{\partial^2 f_{ik}}{\partial x_1 \partial x_1} & \frac{\partial^2 f_{ik}}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f_{ik}}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f_{ik}}{\partial x_2 \partial x_1} & \cdots & \cdots & \cdots \\ \vdots & & & \\ \frac{\partial^2 f_{ik}}{\partial x_n \partial x_1} & \cdots & \cdots & \frac{\partial^2 f_{ik}}{\partial x_n \partial x_n} \end{bmatrix}$$

$$i = 1, 2, \dots, n$$



Odstraněním nelinearity ustředněním dostaneme

$$\bar{f}_{aik} = \text{tr}(P_k N_{ik})$$

$$\bar{f}_{ak} = [\bar{f}_{a1k}, \bar{f}_{a2k}, \dots, \bar{f}_{ank}]^T$$

$$f_k(x_k) \simeq f_k(\hat{x}_k) + F_k(\hat{x}_k)(x_k - \hat{x}_k) + \bar{f}_{ak}$$



# Základy nelineární filtrace

## Filtr druhého řádu

Prediktivní hustota pravděpodobnosti

$$p_a(x_{k+1} | z^k) = N(x_{k+1} : \hat{x}'_{k+1}, P'_{k+1})$$

$$\hat{x}'_{k+1} = F_k(\hat{x}_k) + \bar{f}_{ak}$$

$$P'_{k+1} = F_k(x_k)P_kF_k^T(x_k) + Q_k$$

Závěr: většinou kvalitnější odhad než EKF