

Kalmánův filtr – LETKF (Local Ensemble Transform Kalman Filter)

Úloha:

Máme diferenciální rovnici:

$$\frac{d\mathbf{x}}{dt} = \mathbf{F}(\mathbf{x}, t) \quad (1)$$

a naměřené hodnoty \mathbf{y}_j v časech t_j , naměřené hodnoty obsahují chyby.

Úkolem je nalézt „optimální-nejlepší“ trajektorii $\mathbf{x}(t)$ splňující rovnici (1).

Co to je „optimální-nejlepší“ trajektorie ?

Matematická formulace problému:

- Máme modelovou rovnici (model je přesný):

$$\frac{dx}{dt} = f(t, x)$$

- V časech t_j , $j=1, \dots, n$ máme následující informace:

y_j^o .. naměřené hodnoty

H_j a R_j .. popisují vztah mezi y_j^o a $x(t_j)$

$$y_j^o = H_j(x(t_j)) + \varepsilon_j$$

ε_j je chyba s Gaussovým rozdělením s průměrem **0**

a kovariancí $R_j = E(\varepsilon_j \varepsilon_j^T)$

$$t_1 < t_2 < \dots < t_n$$

Pravděpodobnost trajektorie :

$$\prod_{j=1}^n \exp \left(- \frac{1}{2} [\mathbf{y}_j^O - H_j(\mathbf{x}(t_j))]^T \mathbf{R}_j^{-1} [\mathbf{y}_j^O - H_j(\mathbf{x}(t_j))] \right)$$

Maximalizace pravděpodobnosti $J(\{\mathbf{x}(t_j)\}) = \sum_{j=1}^n [\mathbf{y}_j^O - H_j(\mathbf{x}(t_j))]^T \mathbf{R}_j^{-1} [\mathbf{y}_j^O - H_j(\mathbf{x}(t_j))]$ vede k minimalizaci funkcionálu:

$$\{\mathbf{x}(t_j)\} = [\mathbf{x}(t_1), \mathbf{x}(t_2), \dots, \mathbf{x}(t_n)]$$

kde

$$M_{t,t_j}(\mathbf{x}) : \mathbf{x}(t) \rightarrow \mathbf{x}(t_j) .$$

Označme

pak $J_t(\mathbf{x}) = \sum_{j=1}^n [\mathbf{y}_j^O - H_j M_{t,t_j}(\mathbf{x})]^T \mathbf{R}_j^{-1} [\mathbf{y}_j^O - H_j M_{t,t_j}(\mathbf{x})]$

kde \mathbf{x} je počáteční podmínka v čase t

Lineární případ:

$$\mathbf{H}_j \mathbf{x} = \mathbf{H}_j(\mathbf{x}(t_j))$$

$$\mathbf{M}_{t,t'} \mathbf{x} = \mathbf{M}_{t,t'}(\mathbf{x})$$

Pokud je model diskretní ve tvaru

$$\mathbf{x}_n = \mathbf{M} \mathbf{x}_{n-1}$$

pak

$$\mathbf{M}_{k,m}(\mathbf{x}) = \mathbf{M}^{m-k} \mathbf{x} \quad .$$

Pro výpočet $\mathbf{x}(t_{n-1})$ se minimalizuje:

$$J_{t_{n-1}}(\mathbf{x}) = \sum_{j=1}^{n-1} [\mathbf{y}_j^O - \mathbf{H}_j \mathbf{M}_{t_{n-1}, t_j} \mathbf{x}]^T \mathbf{R}_j^{-1} [\mathbf{y}_j^O - \mathbf{H}_j \mathbf{M}_{t_{n-1}, t_j} \mathbf{x}] \quad (3)$$

Předpokládejme, že v čase t_{n-1} je analýza $\bar{\mathbf{x}}_{n-1}^a$ a tomu odpovídá kovarianční matice \mathbf{P}_{n-1}^a .

Z hlediska pravděpodobnosti je



- průměr



- kovariance pro Gaussovo rozdělení pravděpodobnosti

za předpokladu, že máme naměřené hodnoty v t_1, \dots, t_{n-1} .

Lze tedy psát:

$$J_{t_{n-1}}(\mathbf{x}) = \sum_{j=1}^{n-1} [\mathbf{y}_j^O - \mathbf{H}_j \mathbf{M}_{t_{n-1}, t_j} \mathbf{x}]^T \mathbf{R}_j^{-1} [\mathbf{y}_j^O - \mathbf{H}_j \mathbf{M}_{t_{n-1}, t_j} \mathbf{x}] =$$

$$[\mathbf{x} - \bar{\mathbf{x}}_{n-1}^a](\mathbf{P}_{n-1}^a)^{-1} [\mathbf{x} - \bar{\mathbf{x}}_{n-1}^a] + c \quad (4)$$

Máme $\bar{\mathbf{x}}_{n-1}^a$ a $\bar{\mathbf{x}}_{n-1}^b$, chceme vypočítat $\bar{\mathbf{x}}_n^a$ a $\bar{\mathbf{x}}_n^b$.

Kalmánův filtr:

$$\bar{\mathbf{x}}_n^b = \mathbf{M}_{t_{n-1}, t_n} \bar{\mathbf{x}}_{n-1}^a \quad (5)$$

$$\mathbf{P}_n^b = \mathbf{M}_{t_{n-1}, t_n} \mathbf{P}_{n-1}^a \mathbf{M}_{t_{n-1}, t_n}^T \quad (6)$$

} 1. krok - předpověď

$$\begin{aligned} J_{t_{n-1}} &= \sum_{j=1}^{n-1} [\mathbf{y}_j^O - \mathbf{H}_j \mathbf{M}_{t_{n-1}, t_j} \mathbf{x}_{t_{n-1}}]^T \mathbf{R}_j^{-1} [\mathbf{y}_j^O - \mathbf{H}_j \mathbf{M}_{t_{n-1}, t_j} \mathbf{x}_{t_{n-1}}] = \\ &= \sum_{j=1}^{n-1} [\mathbf{y}_j^O - \mathbf{H}_j \mathbf{M}_{t_{n-1}, t_j} \mathbf{M}_{t_n, t_{n-1}} \mathbf{x}_{t_n}]^T \mathbf{R}_j^{-1} [\mathbf{y}_j^O - \mathbf{H}_j \mathbf{M}_{t_{n-1}, t_j} \mathbf{M}_{t_n, t_{n-1}} \mathbf{x}_{t_n}] = \\ &= \sum_{j=1}^{n-1} [\mathbf{y}_j^O - \mathbf{H}_j \mathbf{M}_{t_n, t_j} \mathbf{x}_{t_n}]^T \mathbf{R}_j^{-1} [\mathbf{y}_j^O - \mathbf{H}_j \mathbf{M}_{t_n, t_j} \mathbf{x}_{t_n}] = \\ &= [\mathbf{x} - \bar{\mathbf{x}}_n^b]^T (\mathbf{P}_n^b)^{-1} [\mathbf{x} - \bar{\mathbf{x}}_n^b] + c \end{aligned}$$

Pro \mathbf{x} v čase t_n :

$$J_{t_n}(\mathbf{x}) = [\mathbf{x} - \bar{\mathbf{x}}_n^b] (\mathbf{P}_n^b)^{-1} [\mathbf{x} - \bar{\mathbf{x}}_n^b]^T [\mathbf{y}_n^O - \mathbf{H}_n \mathbf{x}]^T \mathbf{R}_n^{-1} [\mathbf{y}_n^O - \mathbf{H}_n \mathbf{x}] + c \quad (7)$$

a zároveň J vyjádříme ve tvaru:

$$J_{t_n}(\mathbf{x}) = [\mathbf{x} - \bar{\mathbf{x}}_n^a] (\mathbf{P}_n^a)^{-1} [\mathbf{x} - \bar{\mathbf{x}}_n^a]^T + c,$$

Porovnáním mocnin u \mathbf{x} dostaneme:

$$\mathbf{P}_n^a = [(\mathbf{P}_n^b)^{-1} + \mathbf{H}_n^T \mathbf{R}_n^{-1} \mathbf{H}_n]^{-1} \quad (8)$$

$$\bar{\mathbf{x}}_n^a = \mathbf{P}_n^a [(\mathbf{P}_n^b)^{-1} \bar{\mathbf{x}}_n^b + \mathbf{H}_n^T \mathbf{R}_n^{-1} \mathbf{y}_n^O] \quad (9)$$

Rovnice (8) a (9) lze upravit:

$$\bar{\mathbf{x}}_n^a = \bar{\mathbf{x}}_n^b + \mathbf{P}_n^a \mathbf{H}_n^T \mathbf{R}_n^{-1} (\mathbf{y}_n^O - \mathbf{H}_n \bar{\mathbf{x}}_n^b) \quad (10)$$

$$\mathbf{P}_n^a = (\mathbf{I} + \mathbf{P}_n^b \mathbf{H}_n^T \mathbf{R}_n^{-1} \mathbf{H}_n)^{-1} \mathbf{P}_n^b \quad (11)$$

Shrnutí:

$$\bar{\mathbf{x}}_n^b = \mathbf{M}_{t_{n-1}, t_n} \bar{\mathbf{x}}_{n-1}^a$$

$$\mathbf{P}_n^b = \mathbf{M}_{t_{n-1}, t_n} \mathbf{P}_{n-1}^a \mathbf{M}_{t_{n-1}, t_n}^T$$



1. Krok - předpověď

$$\bar{\mathbf{x}}_n^a = \bar{\mathbf{x}}_n^b + \mathbf{P}_n^a \mathbf{H}_n^T (\mathbf{R}_n^{-1} (\mathbf{y}_n^O - \mathbf{H}_n \bar{\mathbf{x}}_n^b))$$

$$\mathbf{P}_n^a = (\mathbf{I} + \mathbf{P}_n^b \mathbf{H}_n^T \mathbf{R}_n^{-1} \mathbf{H}_n)^{-1} \mathbf{P}_n^b$$



2. Krok - analýza

Počáteční podmínky:

1. Nekonečná chyba

$$P_1 \rightarrow (P_1) = 0$$

To je rozumné, pokud je k dispozici hodně naměřených dat v čase t_1 , aby analýza využívající pouze tato data byla dostatečně přesná.

3. Velká chyba

$$P_1^b \rightarrow \infty$$

Označení – dimenze

m

... dimenze modelu , tj. dimenze x

l

... dimenze měření

k

... velikost ansámblu

Nelineární případ: M a H jsou nelineární

V čase t_{n-1} máme ansámbl počátečních podmínek stavového vektoru \mathbf{x} v m dimensionálním prostoru

$$\left\{ \mathbf{x}_{n-1}^{a(i)}, i=1, \dots, k \right\}$$

Aplikujeme model a dostaneme k předpovědí, které se použijí jako předběžná pole

$$\mathbf{x}_n^{b(i)} = \mathbf{M}_{t_{n-1}, t_n}(\mathbf{x}_{n-1}^{a(i)})$$

a vypočteme výběrový průměr a kovarianci:

$$\bar{\mathbf{x}}^b = \frac{1}{k} \sum_{i=1}^k \mathbf{x}^{b(i)}$$

$$\mathbf{P}^b = (k-1)^{-1} \sum_{i=1}^k (\mathbf{x}^{b(i)} - \bar{\mathbf{x}}^b)(\mathbf{x}^{b(i)} - \bar{\mathbf{x}}^b)^T = (k-1)^{-1} \mathbf{X}^b (\mathbf{X}^b)^T$$

$$\mathbf{X}^b = \left(\mathbf{x}^{b(1)} - \bar{\mathbf{x}}^b, \dots, \mathbf{x}^{b(k)} - \bar{\mathbf{x}}^b \right), \quad \dim(\mathbf{X}^b) = m \times k$$

Pro hodnoty matic platí

$$\text{rank}(\mathbf{P}^b) = \text{rank}(\mathbf{X}^b), \quad \dim(\mathbf{X}^b) \leq k - 1$$

protože

$$\sum_{i=1}^k \mathbf{x}^b = \mathbf{0}$$

Je třeba určit nejen

$$\bar{\mathbf{x}}^a \mathbf{P}^a$$

, ale i

$$\{\mathbf{x}_{n-1}^{a(i)}, i=1, \dots, k\}$$

s průměry a kovariancí:

$$\bar{\mathbf{x}}^a = \frac{1}{k} \sum_{i=1}^k \mathbf{x}^{a(i)}$$

$$\mathbf{P}^a = (k-1)^{-1} \sum_{i=1}^k (\mathbf{x}^{a(i)} - \bar{\mathbf{x}}^a)(\mathbf{x}^{a(i)} - \bar{\mathbf{x}}^a)^T = (k-1)^{-1} \mathbf{X}^a (\mathbf{X}^a)^T$$

$$\mathbf{X}^a = \begin{pmatrix} \mathbf{x}^{a(1)} - \bar{\mathbf{x}}^a, \dots, \mathbf{x}^{a(k)} - \bar{\mathbf{x}}^a \end{pmatrix}, \quad \dim(\mathbf{X}^a) = m \times k$$

Jak vybrat $\left\{ \mathbf{x}_{n-1}^{a(i)}, \{1, \dots, k\} \right\}$ na základě $\left\{ \mathbf{x}_{n-1}^{b(i)}, \{1, \dots, k\} \right\}$?

Předpokládáme: $k < m, k < 1$

Hledáme \mathbf{x} minimalizující J :

$$J(\mathbf{x}) = (\mathbf{x} - \bar{\mathbf{x}}^b)^T (\mathbf{P}^b)^{-1} (\mathbf{x} - \bar{\mathbf{x}}^b) + (\mathbf{y}^O - H(\mathbf{x}))^T \mathbf{R}^{-1} (\mathbf{y}^O - H(\mathbf{x}))$$

$$\dim(\mathbf{P}^b) = m \times m, \quad h(\mathbf{P}^b) = k - 1$$

\mathbf{P}^b je jednoznačné zobrazení $\left\{ \mathbf{x}_{n-1}^{b(i)}, \{1, \dots, k\} \right\}$ na $\left\{ \mathbf{x}_{n-1}^{b(i)}, \{1, \dots, k\} \right\}$,

protože
$$\mathbf{P}^b = (k - 1)^{-1} \sum_{i=1}^k (\mathbf{x}^{b(i)} - \bar{\mathbf{x}}^b)(\mathbf{x}^{b(i)} - \bar{\mathbf{x}}^b)^T = (k - 1)^{-1} \mathbf{X}^b (\mathbf{X}^b)^T .$$

Definujeme se lineární prostor S ,

$$S = \text{lin. prostor} \{ \mathbf{x}_{n-1}^{b(i)}, i = 1, \dots, k \}$$

ve kterém potřebujeme najít řešení (analyzovanou hodnotu).

Řešení je lineární kombinací sloupců matice \mathbf{X}^b .

Řešíme v prostoru \tilde{S} :

$\mathbf{X}^b: \tilde{S} \rightarrow S$ lineární zobrazení na

$$\mathbf{w} \in \mathbb{R}^k \quad \mathbf{X}^b \mathbf{w}$$

$$\mathbf{x} = \mathbf{x}^{-b} + \mathbf{X}^b \mathbf{w}$$

\mathbf{x} je perturbovaná modelová stavová hodnota,

\mathbf{w} má Gaussovo rozdělení s $\mu=0$ a $\mathbf{P}^b=(k-1)^{-1} \mathbf{I}$, pak

\mathbf{x} má Gaussovo rozdělení s $\mu=0$ a $\mathbf{P}^b=(k-1)^{-1} \mathbf{X}^b(\mathbf{X}^b)^T$

$$J(\mathbf{x}) = (\mathbf{x} - \bar{\mathbf{x}}^b)^T (\mathbf{P}^b)^{-1} (\mathbf{x} - \bar{\mathbf{x}}^b) + (\mathbf{y}^O - H(\mathbf{x}))^T \mathbf{R}^{-1} (\mathbf{y}^O - H(\mathbf{x})) \quad (16)$$

$$\tilde{J}(\mathbf{w}) = (k-1)\mathbf{w}^T \mathbf{w} + (\mathbf{y}^O - H(\bar{\mathbf{x}}^b + \mathbf{X}^b \mathbf{w}))^T \mathbf{R}^{-1} (\mathbf{y}^O - H(\bar{\mathbf{x}}^b + \mathbf{X}^b \mathbf{w})) \quad (15)$$

Jestliže $\bar{\mathbf{x}}^a$ minimalizuje \tilde{J} , pak $\bar{\mathbf{x}}^a = \bar{\mathbf{x}}^b + \mathbf{X}^b \bar{\mathbf{w}}^a$ minimalizuje J .



Minimalizujeme:

$$\tilde{J}(\mathbf{w}) = (k-1)\mathbf{w}^T \mathbf{w} + (\mathbf{y}^O - H(\bar{\mathbf{x}}^b + \mathbf{X}^b \mathbf{w}))^T \mathbf{R}^{-1} (\mathbf{y}^O - H(\bar{\mathbf{x}}^b + \mathbf{X}^b \mathbf{w}))$$

H je nelineární - co s tím?

Linearizace H např.:

Potřebujeme umět spočítat

$$H_j(\bar{\mathbf{x}}^b + \mathbf{X}^b \mathbf{w}) \quad \text{pro } \mathbf{w} \in \tilde{S}$$

Postupujeme takto:

$$\mathbf{y}^{b(i)} = H(\mathbf{x}^{b(i)})$$

$$\bar{\mathbf{y}}^b = \frac{1}{k} \sum_{i=1}^k \mathbf{y}^{b(i)}, \quad \mathbf{Y}^b = \begin{pmatrix} \mathbf{y}^{b(1)} - \bar{\mathbf{y}}^b, \dots, \mathbf{y}^{b(k)} - \bar{\mathbf{y}}^b \end{pmatrix}$$

$$H(\bar{\mathbf{x}}^b + \mathbf{X}^b \mathbf{w}) \approx \bar{\mathbf{y}}^b + \mathbf{Y}^b \mathbf{w}$$

... linearizace

Původní funkcionál:

$$\tilde{J}(\mathbf{w}) = (k-1)\mathbf{w}^T \mathbf{w} + (\mathbf{y}^O - H(\bar{\mathbf{x}}^b + \mathbf{X}^b \mathbf{w}))^T \mathbf{R}^{-1} (\mathbf{y}^O - H(\bar{\mathbf{x}}^b + \mathbf{X}^b \mathbf{w}))$$

Po linearizaci:

$$\tilde{J}(\mathbf{w}) = (k-1)\mathbf{w}^T \mathbf{w} + (\mathbf{y}^O - \bar{\mathbf{y}}^b - \mathbf{Y}^b \mathbf{w})^T \mathbf{R}^{-1} (\mathbf{y}^O - \bar{\mathbf{y}}^b - \mathbf{Y}^b \mathbf{w})$$

Obdobně jako předtím (vztah 7) dostaneme:

$$\bar{\mathbf{w}}^a = \tilde{\mathbf{P}}^a (\mathbf{Y}^b)^T \mathbf{R}^{-1} (\mathbf{y}^O - \bar{\mathbf{y}}^b)$$

$$\tilde{\mathbf{P}}^a = ((k-1)\mathbf{I} + (\mathbf{Y}^b)^T \mathbf{R}^{-1} \mathbf{Y}^b)^{-1}$$

a v modelovém prostoru:

$$\bar{\mathbf{x}}^a = \bar{\mathbf{x}}^b \mathbf{X}^b \bar{\mathbf{w}}^a$$

$$\mathbf{P}^a = \mathbf{X}^b (\mathbf{X}^b)^T$$

Potřebujeme vybrat ansámbl $\mathbf{x}_a(i)$ s vlastnostmi $\bar{\mathbf{x}}^a$.

Jak na to?

Vytvoříme ansámbl následujícím způsobem:

$$\mathbf{X}^a = \mathbf{X}^b \mathbf{W}^a,$$

kde

$$\mathbf{W}^a = [(\mathbf{k} - 1) \tilde{\mathbf{P}}^a]^{-\frac{1}{2}} \quad \tilde{\mathbf{P}}^a = (\mathbf{k} - 1)^{-1} \mathbf{W}^a (\mathbf{W}^a)^T$$

Vlastnosti „odmocniny“ symetrické matice $\tilde{\mathbf{P}}^a$:

- zajišťuje, že suma sloupců matice \mathbf{X}^a je nula
- matice \mathbf{W}^a spojitě závisí na $\tilde{\mathbf{P}}^a$, což umožňuje lokální aplikaci algoritmu
- matice \mathbf{W}^a minimalizuje průměrný čtverec vzdálenosti mezi \mathbf{W}^a a identickou maticí

Algoritmus – lokální implementace

$m_{[g]}$

... dimenze modelu , tj. dimenze x

$l_{[g]}$

... dimenze měření

k

... velikost ansámblu

$\{ \mathbf{x}_{[g]}^{b(i)}, i=1, \dots, k \}$

... ansámbl předběžných hodnot

$H_{[g]} (m_{[g]} \rightarrow l_{[g]})$

... operátor převádějící modelové hodnoty na stanice

$\mathbf{y}_{[g]}^o$

... vektor naměřených hodnot

$\mathbf{R}_{[g]} (l_{[g]} \times l_{[g]})$

... kovarianční matice naměřených hodnot

Krok 1:

$$\mathbf{y}_{[g]}^{b(i)} = \mathbf{H}_{[g]} \left(\mathbf{x}_{[g]}^{b(i)} \right) \quad \text{pro } i = 1, \dots, k$$

$$\bar{\mathbf{y}}_{[g]}^b = \frac{1}{k} \sum_{i=1}^k \mathbf{y}_{[g]}^{b(i)}$$

$$\mathbf{Y}_{[g]}^b = \left(\mathbf{y}_{[g]}^{b(1)} - \bar{\mathbf{y}}_{[g]}^b, \dots, \mathbf{y}_{[g]}^{b(k)} - \bar{\mathbf{y}}_{[g]}^b \right)^T$$

Krok 2:

$$\bar{\mathbf{x}}_{[g]}^b = \frac{1}{k} \sum_{i=1}^k \mathbf{x}_{[g]}^{b(i)}$$

$$\mathbf{X}_{[g]}^b = \left(\mathbf{x}_{[g]}^{b(1)} - \bar{\mathbf{x}}_{[g]}^b, \dots, \mathbf{x}_{[g]}^{b(k)} - \bar{\mathbf{x}}_{[g]}^b \right)^T$$

Krok 3:

Pro uzlový bod se vyberou „odpovídající“ řádky z matic-vektorů

$$\mathbf{x}_{[g]}^{-b}, \mathbf{X}_{[g]}^b, \mathbf{y}_{[g]}^b, \mathbf{Y}_{[g]}^b$$

Odpovídající znamená blízké k uzlovému bodu.

Vybere se m řádků, což určuje rozměry matic-vektorů:

$$\mathbf{x}^{-b}, \mathbf{X}^b, \mathbf{y}^b, \mathbf{Y}^b$$

Krok 4:

Vypočte se:

$$\mathbf{C} = (\mathbf{Y}^b)^T \mathbf{R}^T \quad (k \times 1)$$

$$\mathbf{RC} \mathbf{Y}^b$$

Krok 5:

Vypočte se:

$$\tilde{\mathbf{P}}^a = \left[(k-1)\mathbf{I} / \rho + \mathbf{C}^T \mathbf{Y} \mathbf{C} \right]^{-1} \quad (k \times k)$$

ρ uměle navyšuje kovarianci na diagonále – zvyšuje se vliv naměřených hodnot

Krok 6:

Vypočte se:

$$\mathbf{W}^a = \left[(k-1)\tilde{\mathbf{P}}^a \right]^{-\frac{1}{2}} \quad \tilde{\mathbf{P}}^a = (k-1)^{-1} \mathbf{W}^a (\mathbf{W}^a)^T$$

Krok 7:

Vypočte se:

$$\bar{\mathbf{w}}^a = \tilde{\mathbf{P}}^a \mathbf{C}(\mathbf{y}^O - \mathbf{y}) \quad (k \times 1)$$

a přičte se ke každému sloupci matice \mathbf{W} .

Krok 8:

Vypočte se:

$$\mathbf{x}^{a(i)} = \bar{\mathbf{x}}^b + \mathbf{X}^b \mathbf{w}^{a(i)} \quad \text{pro } i = 1, \dots, k$$

Krok 9:

Výsledky pro jednotlivé uzly se složí dohromady a dostane se ansámbl analyzovaných hodnot $\left\{ \mathbf{x}_{[g]}^{a(i)} \right\}$ pro $i = 1, \dots, k$