

# Měření dat

## Filtrace dat, Kalmanův filtr

Matematické metody pro ITS (11MAMY)

Jan Příkryl

Ústav aplikované matematiky  
ČVUT v Praze, Fakulta dopravní

3. přednáška 11MAMY  
čtvrtek 28. února 2018

verze: 2018-03-21 16:45



# Obsah přednášky

## ① Kalmanův filtr



# Kalmanův filtr

## Motivace

Máme signál libovolného typu (měření teploty, zvuk, radarová data o vzdálenosti), tento signál je zašumněný.

Jak odstranit šum?

- Třeba klouzavý průměr – ale z kolika prvků a jaké mají mít váhy?
- V reálném světě to nefunguje.
- Potřebujeme trochu statistiky



# Kalmanův filtr

## Princip

**Princip:** Odhad správné hodnoty měřené veličiny je vážený průměr naměřené a modelované hodnoty.

$$\hat{y}[k] = \mathbf{K}[k]\mathbf{z} + (\mathbf{1} - \mathbf{K}[k])\mathbf{y}[k]$$

Matice  $\mathbf{K}[k]$  je časově proměnná, vážený průměr se adaptuje na

- odhad chyby modelované veličiny
- odhad chyby měřené veličiny

Uvažujeme velmi jednoduchý stavový model systému

$$\mathbf{x}[k + 1] = \mathbf{A}[k]\mathbf{x}[k] + \mathbf{v}[k]$$

$$\mathbf{y}[k] = \mathbf{C}[k]\mathbf{x}[k] + \mathbf{w}[k]$$



# Kalmanův filtr

## Kroky

Postupně vykonáváme následující kroky

- 1 Sestavení dynamického stavového modelu
- 2 Nastavení parametrů (počáteční podmínky, kovariance)
- 3 Iterace:
  - 1 Filtrace (angl. *measurement update*)
  - 2 Predikce (angl. *time update*)



# Kalmanův filtr

## Kroky

Postupně vykonáváme následující kroky

- 1 Sestavení dynamického stavového modelu
- 2 Nastavení parametrů (počáteční podmínky, kovariance)
- 3 Iterace:
  - 1 Predikce (angl. *time update*)
  - 2 Filtrace (angl. *measurement update*)



# Kalmanův filtr

Model lineárního dynamického systému

Nové hodnoty  $\mathbf{x}[k + 1]$  jsou lineární kombinací

- předchozích hodnot
- řídicího signálu  $\mathbf{u}[k]$
- šumu procesu

V mnoha případech je  $\mathbf{u}[k] = 0$

Předpokládaná hodnota měření je lineární kombinací

- stavu
- šumu měření



# Kalmanův filtr

Entity **A**, **B** a **C** jsou obecně časově proměnné matice.

V mnoha problémech zpracování dat ale

- jde pouze o skalární hodnoty, protože i vnitřní stav je skalární,
- jde o hodnoty konstantní v čase

Z již tak zjednodušeného stavového modelu dynamického systému

$$\begin{aligned} \mathbf{x}[k + 1] &= \mathbf{A}[k]\mathbf{x}[k] + \mathbf{v}[k] \\ \mathbf{y}[k] &= \mathbf{C}[k]\mathbf{x}[k] + \mathbf{w}[k] \end{aligned}$$





# Kalmanův filtr

Entity **A**, **B** a **C** jsou obecně časově proměnné matice.

V mnoha problémech zpracování dat ale

- jde pouze o skalární hodnoty, protože i vnitřní stav je skalární,
- jde o hodnoty konstantní v čase

dostaneme zcela primitivní model dynamického SISO systému

$$\begin{aligned}x[k + 1] &= a x[k] + v[k] \\ y[k] &= c x[k] + w[k]\end{aligned}$$



# Kalmanův filtr

Pokud přepíšeme popis modelu do lineární stavové formy (což je ve většině případů možné), potřebujeme pouze nějak zadat **kovariance** (respektive **rozptyl**) šumů  $\mathbf{v}[k]$  a  $\mathbf{w}[k]$ .

Šumy  $\mathbf{v}[k]$  i  $\mathbf{w}[k]$  jsou

- Gaussovské

$$\mathbf{v}[k] \sim \mathcal{N}(0, \mathbf{Q})$$

$$\mathbf{w}[k] \sim \mathcal{N}(0, \mathbf{R})$$

- navzájem statisticky nezávislé



# Kalmanův filtr

V praxi stačí, že oba šумы jsou **přibližně normální**.

I v případě, kdy kovarianční matice  $\mathbf{Q}$  a  $\mathbf{R}$  odhadneme pouze nepřesně, algoritmus Kalmanova filtru většinou konverguje ke korektním odhadům.

*Základní pravidlo zní: Jak dobrý je váš odhad šumových parametrů, tak kvalitní dostanete odhady veličiny.*



# Kalmanův filtr

Ze zbývajících kroků je nejvíce bolestivé určení  $R$  a  $Q$ .

Relativně snadné je určit  $R$ , protože obecně jsme si zcela jisti úrovní šumu v okolním prostředí. Stanovit vhodné hodnoty prvků  $Q$  není vůbec jednoduché a neexistuje na to ani vhodná metodika. Většinou se  $Q$  vybírá z několika kandidátů, určených kvalifikovaným odhadem.

Pro zahájení celého procesu potřebujeme znát počáteční stav  $x[0]$  a odhad jeho šumu  $P[0]$ .



# Kalmanův filtr

## Filtrace

Filtrace:

- 1 aktualizujeme hodnotu Kalmanova zisku

$$\mathbf{K}[k] = \mathbf{P}[k]\mathbf{C}^T (\mathbf{C}\mathbf{P}[k]\mathbf{C}^T + \mathbf{R})^{-1}$$

- 2 korigujeme stav na základě odchylky výstupu modelu  $\mathbf{y}[k]$  od měření  $\mathbf{z}[k]$

$$\hat{\mathbf{x}}[k] = \mathbf{x}[k] + \mathbf{K}[k] (\mathbf{z}[k] - \mathbf{y}[k])$$

- 3 aktualizujeme kovarianci chyb stavu

$$\mathbf{P}[k] = (\mathbf{I} - \mathbf{K}[k]\mathbf{C}) \mathbf{P}[k]$$



# Kalmanův filtr

## Predikce

Predikce:

- 1 předpovíme stav pro  $k + 1$  pomocí rovnice vývoje stavu (střední hodnota šumu je nulová, ve stavu se tedy neprojeví nijak)

$$\hat{\mathbf{x}}[k + 1] = \mathbf{A}\hat{\mathbf{x}}[k] + \mathbf{B}\mathbf{u}[k]$$

- 2 promítneme současné zašumnění stavu do dalšího kroku kovariance stavu nulová není, navíc máme nenulové  $\mathbf{Q}$

$$\mathbf{P}[k + 1] = \mathbf{A}\mathbf{P}[k]\mathbf{A}^T + \mathbf{Q}$$

Výstupem je korigovaný odhad stavu  $\hat{\mathbf{x}}[k]$  a predikovaný budoucí stav  $\hat{\mathbf{x}}[k + 1]$ .



# Kalmanův filtr

## Shrnutí

Kalmanův filtr hledá optimální průměrování pro každý diskrétní časový okamžik. Díky modelu systému má uloženy informace o historii stavu.

Není to signálový filtr, je to **estimátor**. Lze ukázat, že se jedná o rekurzivní Bayesovský estimátor.

Považován za jeden z nejvýznamnějších objevů 20. století.

Plné odvození je netriviální, ale jsou k dispozici implementace pro většinu běžných programovacích jazyků.

Odvozen pro lineární systémy, existují i varianty pro nelineární systémy (EKF, UKF, DD1). Ty jsou však výrazně složitější a pomalejší.

