

# 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: 2018-02-28 12:20



# 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.

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

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

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

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





# Kalmanův filtr

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

$$x[k + 1] = a x[k] + v[k]$$

$$y[k] = c x[k] + w[k]$$



# 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

Predikce:

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

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

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

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



# Kalmanův filtr

The most remaining painful thing is to determine  $R$  and  $Q$ .  $R$  is rather simple to find out, because, in general, we're quite sure about the noise in the environment. But finding out  $Q$  is not so obvious. And at this stage, I can't give you a specific method.

To start the process, we need to know the estimate of  $x_0$ , and  $P_0$ .



# Kalmanův filtr

- 1 aktualizujeme hodnotu Kalmanova zisku

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

- 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

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



# Kalmanův filtr



# Kalmanův filtr





# Kalmanův filtr



# Kalmanův filtr



# Kalmanův filtr



# 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.

