

Cvičení 10

Kalmanův filtr

Jan Přikryl

ČVUT FD

20. dubna 2020

Příklad 1

Navigace

V této úloze vyzkoušíme KF na syntetických datech polohy vozítka, pohybujícího se po modifikované kruhové dráze.

Prvním krokem je vytvoření generátoru měřených pozic dráhy. Budeme postupovat po etapách.

Etapa 1: Čistě kruhová dráha

Začneme čistou kruhovou dráhou o zadaném poloměru r reprezentovanou n měřeními, vozítka opíše přesně jeden kruh. Výstupem generátoru bude matice $(n \times 2)$, obsahující v každém řádku souřadnice $[x, y]$ vozítka.

Příklad 1

Navigace

Pro generování použijeme polární souřadnice a hodnoty φ rozdělíme rovnoměrně na intervalu $\langle 0; 2\pi \rangle$ pomocí funkce `linspace()`:



```
function gps=gps_generator0(r,n)
    phi = linspace(...);
    x = ....
    y = ....
    gps = [ ..... ];
end
```

Dráhu pak pro zvolené r a n vykreslíme:

```
g=gps_generator0(100,100);
figure(1);
plot(g(:,1), g(:,2));
```

Příklad 1

Kruhová dráha pro $r = 100$ a 9 resp. 900 měřených bodů



Příklad 1

Modulovaná kruhová dráha

Etapu 2: Modulovaná kruhová dráha

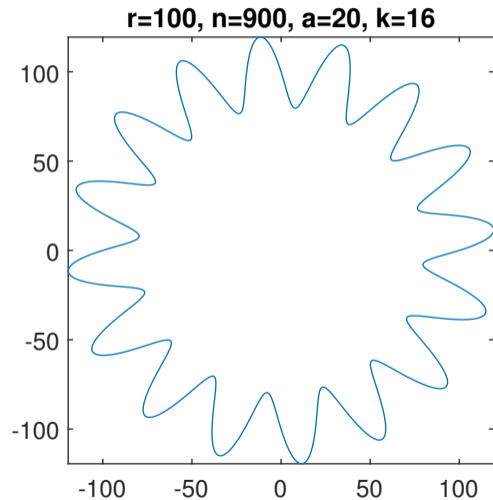

Upravíme `gps_generator0()` o harmonickou modulaci poloměru dráhy. Místo původního poloměru r budeme nyní používat $r + a \sin k\varphi$. Zbytek zůstává.

```
function gps=gps_generator1(r,n,a,k)
    phi = linspace(...);
    ro = r + .....
    x = .....
    y = .....
    gps = [ ..... ];
end
```

Dráhu opět pro zvolené r , n , a a k vykreslíme.

Příklad 1

Modulovaná kruhová dráha pro $r = 100$, 900 měřených bodů a dvě různé modulace



Příklad 1

Simulace měření pozice vozidla na dráze

Etapa 3: Modulovaná kruhová dráha se šumem měření



Upravíme `gps_generator1()` o normálně rozdělený šum pozice se střední hodnotou $\mu = (0,0)$ a nenulovou kovarianční matici Σ . Vzorky z multinomiálního rozdělení generujeme v Matlabu funkcí `mvnrnd()`.

```
function gps=gps_generator2(r,n,a,k,sigma)
    phi = linspace(...);
    ro = r + .....
    err = mvnrnd(...);
    x = .....
    y = .....
    gps = [ ..... ] + err;
end
```

Dráhu opět pro zvolené r , n , a a k vykreslíme.

Příklad 1

Simulace nepřesných měření pozice pro $r = 100$, $a = 4$, $k = 8$ a 100 měřených bodů



Příklad 1

Kalmanův filtr – Model systému

Pro modelování pohybu vozidla použijeme napřed zcela primitivní a nepřesný model, který předpokládá, že vozítko se pohybuje rovnoměrným přímočarým pohybem, a jeho pozice v $k + 1$ kroku je dána vztahem

$$\mathbf{p}_{k+1} = \mathbf{p}_k + \Delta\mathbf{p}.$$

Hodnota $\Delta\mathbf{p}$ je pro rovnoměrný přímočarý pohyb konstantní.

Pohybujeme se ve 2D, uvažujeme tedy

- ▶ poloha je $\mathbf{p}_k = (x_k, y_k)^T$
- ▶ změna polohy je $\Delta\mathbf{p}_k = (a_k, b_k)^T$ a předpokládáme, že se v čase nemění

Příklad 1

Kalmanův filtr – Model systému

Sestavíme rovnice vývoje stavu

$$x_{k+1} = x_k + a_k$$

$$y_{k+1} = y_k + b_k$$

$$a_{k+1} = a_k$$

$$b_{k+1} = b_k$$

Stav je tedy $\mathbf{x}_k = (x_k, y_k, a_k, b_k)^T$.

Měříme pouze pozici, tj. souřadnice x_k a y_k .

Příklad 1

Kalmanův filtr – Model systému

Přepíšeme do maticového zápisu

$$\mathbf{x}_{k+1} = \mathbf{A}\mathbf{x}_k$$

$$\mathbf{z}_k = \mathbf{C}\mathbf{x}_k$$

s nulovými pomocnými maticemi \mathbf{B} a \mathbf{D}

$$\mathbf{A} = \begin{bmatrix} 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad \mathbf{B} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \quad \mathbf{C} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}, \quad \mathbf{D} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}.$$

Příklad 1

Kalmanův filtr – Skript v Matlabu

Nastavíme základní parametry:

```
radius = 1000; % r = 1000 m
num_coords = 200; % stačí 200 hodnot
a = 4;
k = 8;
R_true = diag([10,10]); % simulované R
```

Vygenerujeme referenční souřadnice a souřadnice měřených pozic zatížené chybou s kovariancí \mathbf{R}_{true} :

```
coord0 = gps_generator1(radius, num_coords, a, k);
coords = gps_generator2(radius, num_coords, a, k, R_true);
```

Příklad 1

Kalmanův filtr – Skript v Matlabu

Zadáme matice soustavy, budeme potřebovat i **B** a **D**:

```
A = [ 1 0 1 0; 0 1 0 1; 0 0 1 0; 0 0 0 1 ];  
B = [ 0; 0; 0; 0];  
C = [ 1 0 0 0; 0 1 0 0];  
D = [ 0; 0 ];
```

Zadáme počáteční podmínky:

```
% Více důvěřujeme měřeným hodnotám  
Q = diag([100,100,100,100]); % šum (chyba) modelu  
R = diag([10,10]); % šum (chyba) měření  
% Počáteční šum procesu a stav  
P0 = diag([10, 10, 10, 10]); % bez měření roste o Q, jinak klesá  
x0 = [ coords(1,:)'; 0; 0]; % stav je sloupcový vektor!
```

Příklad 1

Kalmanův filtr – Skript v Matlabu

Celkem provedeme `num_coords` iterací. Alokujeme si prostor, kam uložíme predikované souřadnice $\hat{\mathbf{p}}$ a filtrované (měřením korigované) souřadnice $\hat{\mathbf{p}}^*$

```
pred_history = zeros(4, num_coords);  
filt_history = zeros(4, num_coords);
```

Nyní nás čeká vytvoření klíčové části skriptu, smyčky, která prochází „změřené“ hodnoty, uložené v proměnné `coords`, pro každou z nich zavolá externí funkci `kalman()` a aktualizuje stav systému a kovarianci šumu procesu. Ve smyčce si zároveň budeme pro pozdější vykreslení ukládat hodnoty predikovaných a filtrovaných souřadnic do matic `pred_history` a `filt_history`.

Podívejme se ale nejprve na rozhraní funkce `kalman()`,

Příklad 1

Kalmanův filtr – Volání `kalman()`

Funkci, implementující Kalmanův filtr, voláme jako

```
[x0f, x1p, Pf, P1] = kalman(x0, u0, zm, A, B, C, D, P, Q, R)
```

kde vstupní parametry jsou

`x0` ... stav \mathbf{x}_k

`u0` ... vstup \mathbf{u}_k , v našem případě bude $\mathbf{u}_k = u_k = 0$

`zm` ... měřené \mathbf{z}_k

`A, B, C, D` ... matice stavového modelu

`P` ... apriorní odhad kovariance stavu $\hat{\mathbf{x}}_k$

`Q, R` ... kovariance šumu model a měření

Příklad 1

Kalmanův filtr – Volání `kalman()`

Funkci, implementující Kalmanův filtr, voláme jako

```
[x0f, x1p, Pf, P1] = kalman(x0, u0, zm, A, B, C, D, P, Q, R)
```

kde výstupní parametry jsou

x0f ... filtrovaný stav \mathbf{x}_k^*

x1p ... predikovaný stav $\hat{\mathbf{x}}_{k+1}$, založený na \mathbf{x}_k^*

Pf ... aposteriorní odhad kovariance stavu $\hat{\mathbf{x}}_k$

P1 ... apriorní odhad kovariance stavu $\hat{\mathbf{x}}_{k+1}$

Příklad 1

Kalmanův filtr – Skript v Matlabu

Doplňte kostru základní smyčky:

```
for k=1:num_coords
    ym = coords(k,:)'; % simulované měření, sloupcov vektor
    % aktualizace stavu modelu na základě starého stavu a měření
    [x0f,x1p,P0f,P1p]=kalman(x0,0,ym,A,B,C,D,P0,Q,R);
    % uložíme pro vykreslení
    pred_history(:,k) = ....; % predikovaný příští stav
    filt_history(:,k) = ....; % filtrovaný současný stav
    % příprava pro další krok
    x0 = ....; % odhad budoucího stavu
    P0 = ....; % odhad nepřesnosti budoucího stavu
end
```

Příklad 1

Kalmanův filtr – Obrázek filtrované trajektorie

Vykreslíme

```
figure(1);  
plot(coord0(:,1),coord0(:,2),'-m', ...  
      coords(:,1),coords(:,2),'.b', ...  
      filt_history(1,:),filt_history(2,),'-r', ...  
      pred_history(1,:),pred_history(2,),'-g');  
legend('True_position', 'Measured_position', 'Filtered',  
       'Predicted');  
xlabel('x_m');  
ylabel('y_m');
```

Příklad 1

Obrázek části filtrované trajektorie

