

## Odhad stavu se stavovým modelem

- stavový lineární model se známými parametry
- simulovaná data

V programu se provádí simulace se stavovým modelem a g generovaného vstupu a výstupu se pomocí Kalmanova filtru průběžně odhaduje stav. Kalmanův filtr je realizován procedurou

```
[x, xf, rx, yp]=Kalman(x, yt, ut, M, N, F, A, B, G, rw, rv, rx)
```

kde x je přeypočítávaný stav, xf je výsledný odhad stavu v daném čase, rx je přeypočítávaná kovariance stavu, yp je predikce výstupu, yt a ut jsou data, M, N, F, A, B, G jsou parametry stavového modelu, rw a rv jsou kovariance stavu a šumu ve stavovém modelu.

Použitý model má tvar

$$\begin{aligned}x_{t+1} &= Mx_t + Nu_t + F + w_t \\y_t &= Ax_t + Bu_t + G + v_t\end{aligned}$$

kde  $x_t$  je v programu označen jako xf

**Předpoklady:** Známe parametry modelu, linearita modelu

**Sci značení:**  $x_{t-1}/x_t/x_{t+1}$  - x,  $x_t$  - xf, (ostatní viz Kalmanův filtr nahoře)

**Úloha:** Odhad neznámé veličiny, filtrace zašuměného signálu.

### Poznámka

Pro správný start odhadování je důležité správné nastavení kovariančních matic. Matice rw se nastavují většinou jako diagonální s velkými čísly na diagonále ( $10^3 - 10^5$ ). Kovarianční matice rw a rv by mely odpovídat kovariančním maticím šumů  $w_t$  a  $v_t$  z modelu. POZOR: nejsou to kovarianční matice stavu a výstupu ale jejich poruch. Na správném nastavení těchto matic velmi záleží celý odhad.

### Doporučené experimenty

1. Měřte parametry stavového modelu pro simulaci a sledujte, kdy je odhad stavu obtížný.  
Poznámka  
Jestliže matice  $[A, AM, AM^2, \dots, AM^{n-1}]$ , kde  $n$  je dimenze stavu, má hodnost menší než  $n$ , pak systém je tzv. nepozorovatelný a stav nelze odhadnout.
2. Měřte rozptyly šumů rw a rv. Pro velké rozptyly bude odhad méně přesný.
3. Měřte počáteční kovarianční matici rx. Nastavená hodnota 1000 na diagonále znamená, že Kalmanovu filtru necháváme volnost v jeho odhadu z dat. Pro menší diagonálu odhad tzv. "utahujeme", tj. dáváme větší váhu počátečním podmínkám. Tím se ale odhad stabilizuje - snižuje se nebezpečí, že nějaká hodně chybná data na začátku celý odhad rozhodí natolik, že nekonverguje.

## Program

```
// Estimation of state variable with KF
[u,t,n]=file();                                // find working directory
chdir(dirname(n(1)));                          // set working directory
clear("u","t","n")                            // clear auxiliary data
exec("ScIntro.sce",-1),mode(0)                // intro to sesion

nd=100;                                         // number of data

// State-space model
Fil.Cy.rw=.1*eye(2);                         // state covariance
Fil.Cy.rv=.01;                                 // output covariance
Fil.Cy.rx=1000*eye(2);                        // state estimate covariance
Fil.Cy.M=[.2 .1;                             // state-space
          .2 .4];                           // model
Fil.Cy.N=[1; -1];                           // parameters
Fil.Cy.F=[1; -1];                           // "
Fil.Cy.A=[1 0];                            // "
Fil.Cy.B=1;                                  // "
Fil.Cy.G=2;                                  // parameters

// declarations
xt=zeros(2,nd);                           // state declaration (initial state)
x=zeros(2,nd);                             // initial state estimate
ut=zeros(1,nd);                           // input
yt=zeros(1,nd);                           // output
yp=zeros(1,nd);                           // output prediction
rw=Fil.Cy.rw; rv=Fil.Cy.rv; rx=Fil.Cy.rx; // KF covariances
M=Fil.Cy.M; N=Fil.Cy.N; F=Fil.Cy.F;       // state model parameters
A=Fil.Cy.A; B=Fil.Cy.B; G=Fil.Cy.G;       // output model parameters

// TIME LOOP
for t=2:nd
    // simulation
    xt(:,t) = M*xt(:,t-1)+N*ut(t)+F+rw*rand(2,1,'norm');
    yt(t)   = A*xt(:,t) + B*ut(t)+G+rv*rand(1,1,'norm');
    // estimation
    [x(:,t),rx,yp(t)]=...
        Kalman(x(:,t-1),yt(t),ut(t),M,N,F,A,B,G,rw,rv,rx);
end
Fil.Cy.ut=ut;
Fil.Cy.yt=yt;
Fil.Cy.xt=x;

// RESULTS
s=1:nd;
subplot(311),plot(s,xt(1,s),s,x(1,s))
set(gca(),"data_bounds",[1,nd,0 2]);
```

```
title('First state and its estimate')
subplot(312),plot(s,xt(2,s),s,x(2,s))
set(gca(),"data_bounds",[1,nd,-2 1]);
title('Second state and its estimate')
subplot(313),plot(s,yp(s),s,yt(s))
set(gca(),"data_bounds",[1,nd,2 4]);
title('Output and its prediction')
set(gcf(),"position",[500 50 600 500])
// Note: xf is the result of state estimation (not x)
// at time t, xf(t) is the result. x(t+1) aims at the next time

save _data/dataT44.dat Fil
```