

TECHNICKÁ UNIVERZITA V LIBERCI
Hálkova 6, 461 17 Liberec 1, CZ

Fakulta mechatroniky a mezioborových inženýrských studií

Číslicové řízení

Modelování a diskrétní identifikace

Studijní materiály

Doc. Ing. Osvald Modrlák, CSc.



Katedra řídicí techniky

Obsah

1	Úvod.....	3
2	Průchod stacionárního náhodného signálu lineární t-invariantní soustavou.....	3
3	Model náhodného diskrétního stacionárního procesu.....	7
4	Diskrétní model systému při působení stochastického stacionárního signálu.....	8
4.1	Struktura modelu.....	8
4.2	Chyby modelu.....	10
4.3	Struktura diskrétních modelů.....	11
4.4	Predikce výstupu.....	13
5	Odhad parametrů modelu ARX metodou nejmenších čtverců.....	14
5.1	Metoda nejmenších čtverců.....	14
5.2	Vlastnosti odhadů.....	16
5.3	Odhad vektoru parametrů pomocí korelačních funkcí.....	18
6	Softwarová podpora diskrétní parametrické identifikace.....	20
7	Literatura.....	31

Předkládaný studijní materiál seznamuje čtenáře v základních rysech s diskrétním modelováním dynamických procesů při působení stochastických stacionárních signálů. Zavádí modely typu ARX, ARMAX, BJ a ukazuje použití metody nejmenších čtverců pro odhad parametrů modelu ARX. Popisuje základní identifikační funkce softwarové podpory „Toolbox Identification Toolbox“ z MATLABu. Hlubší pochopení problematiky vyžaduje podrobné studium v uvedené literatuře.

1 ÚVOD


Odhad parametrů diskrétního modelu systému z měření, struktura matematického modelu systému, parazitní šumové signály, náhodný proces a jeho statistické charakteristiky, volba prediktoru, struktura modelů, ARMAX a BJ, odhad jejich parametrů. Rekurzivní metody výpočtu.

2 PRŮCHOD STACIONÁRNÍHO NÁHODNÉHO SIGNÁLU LINEÁRNÍ T-INVARIANTNÍ SOUSTAVOU

Uvažujme spojitou soustavu, jejíž dynamické účinky jsou aproximovány diskrétním modelem pomocí Z-přenosu $G(z)$. Zvolená perioda vzorkování je T_s . Podle definice Z-transformace platí

$$G(z) = \sum_0^{\infty} g_k z^{-k}, \text{ kde } g_k = 0, \text{ pro } k < 0, \sum_{k=0}^{\infty} g_k = K, \tag{1-1}$$

kde je $g_k \dots$ diskrétní hodnota váhové funkce,
 $z^{-k} \dots$ operátor Z-transformace,
 $K \dots$ je zesílení soustavy.



Obr. X.1 Diskrétní model

Diskrétní hodnota výstupu na obecný vstupní signál je dána konvolutorním součtem

$$y_k = \sum_{j=0}^k g_j u_{k-j}, \tag{1-2}$$

kde je $y_k \dots$ diskrétní hodnota výstupu
 $g_k \dots$ diskrétní hodnota váhové funkce,
 $u_{k-j} \dots$ diskrétní hodnota akční veličiny.

Uvažujme, že budícím signálem diskrétního modelu dle obr.1.1 je stacionární šum u_k . Střední hodnota u_k je rovna

$$\bar{u} = E\{u_k\} = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{j=-N}^N u_j. \tag{1-3}$$

Střední hodnota výstupního signálu y_k

$$\bar{y}_k = E\{y_k\} = E\left\{ \sum_{j=0}^{\infty} g_j u_{k-j} \right\} = \sum_{j=0}^{\infty} g_j E\{u_{k-j}\} = \sum_{j=0}^{\infty} g_j \bar{u}_{k-j},$$

kde je $\bar{u}_k = E\{u_{k-j}\}$.

Je-li stochastický signál u_k stacionární, pak platí $\bar{u}_k = E\{u_{k-j}\} = \bar{u}$ a střední hodnota výstupního signálu y_k bude rovna

$$\bar{y}_k = \sum_{j=0}^{\infty} g_j \bar{u} = K \bar{u} = \bar{y}. \tag{1-4}$$

Podle definice je autokovariační funkce vstupního signálu u_k rovna

$$\bar{c}_{uu}(k) = E\{\bar{u}_k \bar{u}_{k+s}\} = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{s=-N}^N \bar{u}_s \bar{u}_{s+k} = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{s=-N}^N (u_s - \bar{u})(u_{s+k} - \bar{u}). \quad (1-5)$$

Autokorelační funkce výstupu

$$\bar{c}_{yy}(k) = E\{\bar{y}_i \bar{y}_{i+k}\} = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{i=-N}^N \bar{y}_i \bar{y}_{i+k} \quad (1-6)$$

Vyjádříme-li \bar{y}_i, \bar{y}_{i+k} pomocí diskrétní váhové funkce, dostaneme

$$\bar{y}_i = \sum_{j=0}^{\infty} g_j \bar{u}_{i-j} = \sum_{j=-\infty}^{\infty} g_j \bar{u}_{i-j} \quad (1)$$

$$\bar{y}_{i+k} = \sum_{l=0}^{\infty} g_l \bar{u}_{i+k-l} = \sum_{l=-\infty}^{\infty} g_l \bar{u}_{i+k-l} \quad (2)$$

Dosazením (1, 2) do (1-6) dostaneme

$$\begin{aligned} \bar{c}_{yy}(k) &= \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{i=-N}^N \bar{y}_i \bar{y}_{i+k} = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{i=-N}^N \left[\sum_{j=-\infty}^{\infty} g_j \bar{u}_{i-j} \right] \cdot \left[\sum_{l=-\infty}^{\infty} g_l \bar{u}_{i+k-l} \right] = \\ &= \sum_{j=-\infty}^{\infty} g_j \cdot \sum_{l=-\infty}^{\infty} g_l \cdot \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{i=-N}^N \bar{u}_{i-j} \cdot \bar{u}_{i+k-l}. \end{aligned}$$

Označíme-li $s = i - j \rightarrow i = s + j$ a index $i + k - l = s + j + k - l$, pak je možno autokorelační funkci zapsat ve tvaru


$$\bar{c}_{yy}(k) = \sum_{j=-\infty}^{\infty} g_j \cdot \sum_{l=-\infty}^{\infty} g_l \bar{c}_{uu}(k + j - l). \quad (1-6)$$

Vzájemná korelační funkce $\bar{c}_{uy}(k)$ je rovna

$$\begin{aligned} \bar{c}_{uy}(k) &= \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{i=-N}^N \bar{u}_i \bar{y}_{i+k} = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{i=-N}^N \bar{u}_{i-j} \cdot \left[\sum_{l=-\infty}^{\infty} g_l \bar{u}_{i+k-l} \right] = \\ &= \sum_{l=-\infty}^{\infty} g_l \cdot \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{i=-N}^N \bar{u}_{i-j} \cdot \bar{u}_{i+k-l} = \sum_{l=-\infty}^{\infty} g_l \cdot \bar{c}_{uu}(k - l). \end{aligned} \quad (1-7)$$

Uvažujme diskrétní model dynamického systému dle obr.1.2, jehož vstupem je náhodný stacionární signál u_k , který je popsán podle (1-5) autokorelační funkcí $\bar{c}_{uu}(k)$.

Výstupní signál je možno podle (1-6) a (1-7) popsat autokorelační funkcí výstupu $\bar{c}_{yy}(k)$ a vzájemnou korelační funkcí $\bar{c}_{uy}(k)$.



Obr. X.2 Diskrétní model

Výkonovou spektrální hustotu je možno vyjádřit

$$S_{uu}(\omega) = S_{uu}(z) = S_{uu}(e^{j\omega T_s}) \quad \text{pro } z = e^{j\omega T_s} \rightarrow S_{uu}(z) = \sum_{k=-\infty}^{\infty} \bar{c}_{uu}(k) z^{-k}$$

$$S_{yy}(\omega) = S_{yy}(z) = S_{yy}(e^{j\omega T_s}) \quad \text{pro } z = e^{j\omega T_s} \rightarrow S_{yy}(z) = \sum_{k=-\infty}^{\infty} \bar{c}_{yy}(k) z^{-k}$$

$$S_{yu}(\omega) = S_{yu}(z) = S_{yu}(e^{j\omega T_s}) \quad \text{pro } z = e^{j\omega T_s} \rightarrow S_{yu}(z) = \sum_{k=-\infty}^{\infty} \bar{c}_{yu}(k) z^{-k}$$

Z-obraz výkonové spektrální hodnoty $S_{yu}(z)$ je roven

$$S_{yu}(z) = \sum_{k=-\infty}^{\infty} \bar{c}_{yu}(k) z^{-k} = \sum_{k=-\infty}^{\infty} z^{-k} \cdot \sum_{j=0}^{\infty} g_j \cdot \bar{c}_{uu}(k-j) = \sum_{k=-\infty}^{\infty} \cdot \sum_{j=0}^{\infty} z^{-k} \cdot g_j \cdot \bar{c}_{uu}(k-j) =$$

$$= \sum_{k=-\infty}^{\infty} \cdot \sum_{j=0}^{\infty} z^{-j} \cdot g_j \cdot z^{-(k-j)} \cdot \bar{c}_{uu}(k-j) = \sum_{j=0}^{\infty} z^{-j} \cdot g_j \sum_{k=-\infty}^{\infty} z^{-(k-j)} \cdot \bar{c}_{uu}(k-j) = \quad (1-7)$$

$$= G(z) \cdot S_{uu}(z),$$

kde je $G(z) = \sum_{j=0}^{\infty} g_j z^{-j}$... diskrétní přenos dynamického systému ,

$$S_{uu}(z) = \sum_{k=-\infty}^{\infty} z^{-k} c_{uu}(k) \dots \text{Z-obraz výkonové spektrální hustoty vstupního signálu.}$$

Z-obraz výkonové spektrální hustoty $S_{yy}(z)$ je tedy roven

$$S_{yu}(z) = G(z) \cdot S_{uu}(z) \rightarrow S_{yu}(\omega) = G(e^{j\omega T_s}) \cdot S_{uu}(\omega). \quad (1-8)$$

$$S_{uy}(z) = S_{uu}(z) \cdot \bar{G}(z) \rightarrow S_{uy}(\omega) = S_{uu}(\omega) \cdot G(e^{-j\omega T_s}). \quad (1-9)$$

Z-obraz výkonové spektrální hustoty výstupu je podle definice roven $S_{yy}(z) = \sum_{k=-\infty}^{\infty} \bar{c}_{yy}(k) z^{-k}$.

Vyjádříme-li autokovariační funkci $\bar{c}_{yy}(k)$ signálu pomocí (1-6), dostaneme

$$S_{yy}(z) = \sum_{k=-\infty}^{\infty} \bar{c}_{yy}(k) z^{-k} = \sum_{k=-\infty}^{\infty} z^{-k} \sum_{j=-\infty}^{\infty} g_j \sum_{l=-\infty}^{\infty} g_l \cdot \bar{c}_{uu}(k+j-l) = \sum_{k=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} \sum_{l=-\infty}^{\infty} z^{-k} \cdot g_j \cdot g_l \cdot \bar{c}_{uu}(k+j-l) =$$

$$= \sum_{k=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} \sum_{l=-\infty}^{\infty} z^{-j} \cdot g_j \cdot z^{+l} g_l \cdot z^{-(k+j-l)} \bar{c}_{uu}(k+j-l) =$$

$$= \sum_{j=-\infty}^{\infty} z^{-j} g_j \sum_{k=-\infty}^{\infty} z^{-(k+j-l)} \bar{c}_{uu}(k+j-l) \sum_{l=-\infty}^{\infty} z^{+l} g_l = \sum_{j=0}^{\infty} z^{-j} g_j \sum_{k=-\infty}^{\infty} z^{-(k+j-l)} \bar{c}_{uu}(k+j-l) \sum_{l=0}^{\infty} z^{+l} g_l.$$

Jednotlivé součty jsou rovny

$$\sum_0^{\infty} z^{-j} g_j = G(z), \quad \sum_{k=-\infty}^{\infty} z^{-(k+j-l)} c_{uu}(k+j-l) = \sum_{k=-\infty}^{\infty} z^{-s} \bar{c}_{uu}(s) = S(z),$$

$$\sum_0^{\infty} z^{+l} g_l = \sum_0^{\infty} \left(\frac{1}{z}\right)^{-l} g_l = G\left(\frac{1}{z}\right) = \bar{G}(z).$$

Budiž zdůrazněno, pruh nad Z-přenosem neoznačuje střední hodnotu!!! Pro tato označení je pak možno autokovariční funkci $\bar{c}_{yy}(k)$ vyjádřit ve tvaru

$$S_{yy}(z) = \sum_{k=-\infty}^{\infty} \bar{c}_{yy}(k) z^{-k} = G(z) \cdot S_{uu}(z) \cdot \bar{G}(z) \quad (1-10)$$

Ve frekvenční oblasti pak platí

$$S_{yy}(\omega) = |G(e^{-j\omega Ts})|^2 \cdot S_{uu}(\omega), \quad (1-11)$$

kde je $|G(e^{-j\omega Ts})|^2 = G(e^{j\omega Ts}) \cdot G(e^{-j\omega Ts})$.

Je-li vstupujícím signálem bílý šum, pak platí

$$\bar{c}_{uu}(k) = \delta(k) = \delta(0), \quad S_{uu}(z) = \sum \bar{c}_{uu}(k) z^{-k} = z^0 = 1 \rightarrow S_{uu}(\omega) = 1$$

Vzájemná kovariační funkce $\bar{c}_{yu}(k)$ je rovna

$$\bar{c}_{yu}(k) = \sum_{l=-\infty}^{\infty} g_l \cdot \bar{c}_{uu}(k-l) = \sum_{l=-\infty}^{\infty} g_l \cdot \delta(k-l) = g_k$$

Vzájemná výkonová spektrální hustota $S_{yu}(\omega)$ je rovna

$$S_{yu}(\omega) = G(e^{j\omega Ts}) \cdot S_{uu}(\omega) = G(e^{j\omega Ts}) \cdot 1 = G(e^{j\omega Ts})$$

Vstupuje-li do dynamického systému dle obr.X.2 bílý šum, pak

- vzájemná kovariační funkce $\bar{c}_{yu}(k)$ je přímo rovna diskrétní impulzní charakteristice
- vzájemná spektrální hustota $S_{yu}(\omega)$ je rovna jeho frekvenčnímu přenosu

Věta o realizaci

Pro každou racionální spektrální hustotu $S_{yy}(\omega) \geq 0$ existuje právě jeden dynamický systém s přenosem $G(z)$ který má jednotkový koeficient u nejvyšší mocniny z a má všechny póly a nuly uvnitř jednotkové kružnice nebo na jednotkové kružnici, takový, že stacionární proces s danou spektrální hustotou můžeme získat jako výstup z tohoto systému, je-li na vstupu bílý šum.

3 MODEL NÁHODNÉHO DISKRÉTNÍHO STACIONÁRNÍHO PROCESU

Modelování náhodných stacionárních procesů je založeno na průchodu bílého šumu $v_k = v(k)$ lineární diskrétní soustavou - filtrem. Stacionární stochastický proces $y_F(k)$ který vzniká průchodem bílého šumu $v(k)$ diskrétním filtrem můžeme popsat pomocí **stochastické diferenciální rovnice**

$$y_F(k) + d_1 y_F(k-1) + \dots + d_n y_F(k-n) = c_0 v(k) + c_1 v(k-1) + \dots + c_m v(k-m), \quad (2-1)$$

kde $\dots y_F(k)$ je výstupní stacionární stochastický signál (šedý, barevný)
 $v(k)$ je diskrétní bílý šum, pro který platí $E\{v(k)v(k+i)\} = \begin{cases} \sigma^2; & \text{pro } i = 0 \\ 0; & \text{pro } i \neq 0 \end{cases}$
 d_i, c_j jsou koeficienty diferenciální rovnice filtru.

Diskrétní přenos filtru je pak ve tvaru

$$G_F(z) = \frac{c_0 + c_1 z^{-1} + \dots + c_m z^{-m}}{1 + d_1 z^{-1} + \dots + d_n z^{-n}} = \frac{C(z^{-1})}{D(z^{-1})} = \frac{C}{D} \quad (2-2)$$

Poznámka: Je třeba si uvědomit, že vstupní signál $v(k)$ je diskrétní náhodný signál - bílý šum. Proto i výstupní signál $y_F(k)$ je náhodným signálem. Výstup $y_F(k)$ je funkcí bílého šumu $v(k)$ a nemůže proto také být bílým šumem. Průchodem lineární soustavou se vytvoří stacionární stochastický signál, který se často označuje jako šum barevný - šedý.

Stochastickou diferenciální rovnici (2-1) je možno ještě modifikovat. Dostáváme tak speciální modely, které mají při analýze stochastických systémů veliký význam. Jsou to:

1) Model stochastického procesu, který se označuje jako **autoregresní** proces řádu n , jehož matematický model značíme zkratkou **AR (AutoRegresiv)**. Je popsán rovnicí

$$y_F(k) + d_1 y_F(k-1) + \dots + d_n y_F(k-n) = c_0 v(k). \quad (2-3)$$

Diskrétní hodnoty $y_F(k)$ závisí na okamžité hodnotě bílého šumu $v(k)$ a na minulých hodnotách výstupu $y_F(k-1)$, $y_F(k-2)$, ..., které jsou váženy koeficienty d_i , $i = 1, 2, 3, \dots$. Odtud název autoregresní.

$$\text{Přenos filtru je } G_F(z^{-1}) = \frac{c_0}{D(z^{-1})}, \quad y_F(k) = \frac{c_0}{D} v_k. \quad (2-4)$$

2) Model náhodného procesu s **klouzavým průměrem MA (Moving Average)** má diferenciální rovnici

$$y_F(k) = c_0 v(k) + c_1 v(k-1) + \dots + c_m v(k-m). \quad (2-5)$$

Pravou stranu představuje vážený součet hodnot bílého šumu $v(k)$, $v(k-1)$, $v(k-2)$, ..., což lze chápat jako časově závislou střední hodnotu.

$$\text{Přenos filtru je: } G_F(z^{-1}) = C(z^{-1}) = c_0 + c_1 z^{-1} + c_2 z^{-2} + \dots + c_m z^{-m}. \quad (2-6)$$

3) Použijeme-li pro model stochastickou diferenční rovnici, nebo též kombinaci obou modelů **AR** a **MA** pak je tento model označován jako **ARMA** model (**AutoRegresiv Moving Average**). Jeho diferenční rovnice je

$$y_F(k) + d_1 y_F(k-1) + \dots + d_n y_F(k-n) = c_0 v(k) + c_1 v(k-1) + \dots + c_m v(k-m)$$

Můžeme zkráceně psát

$$y_F(k) * D = C * v(k) \rightarrow y_F(k) = \frac{C}{D} * v(k). \quad (2-7)$$

4 DISKRÉTNÍ MODEL SYSTÉMU PŘI PŮSOBNÍ STOCHASTICKÉHO STACIONÁRNÍHO SIGNÁLU

Odezva identifikovaného dynamického systému $y(k)$ obsahuje podle (1-7) složku deterministickou $y_u(k)$ a stochastickou $y_v(k)$. Podle předpokladů (1-7) je $y_v(k)$ stacionární stochastický signál. Platí rovnost pro $y_d(t) = \chi(t) = \lambda(t) = 0$

$$y(k) = y_u(k) + y_v(k). \quad (3-1)$$

Pro obě složky výstupu je třeba nalézt vhodný matematický popis, což je ukázáno v následujících kapitolách.

4.1 STRUKTURA MODELU

Diskrétní popis tohoto systému pak musí také obsahovat jak deterministickou, tak stochastickou část modelu. Deterministická část modelu je zřejmě dána diskrétním přenosem (1-4) a za předpokladu, že operátor z^{-1} chápeme jako operátor posunu $y(k-1) = z^{-1}y(k)$, můžeme psát

$$G_U(z^{-1}) = \frac{B(z^{-1})}{A(z^{-1})} = \frac{B}{A} \rightarrow y_u(k) = \frac{B}{A} u(k) \quad (3-2)$$

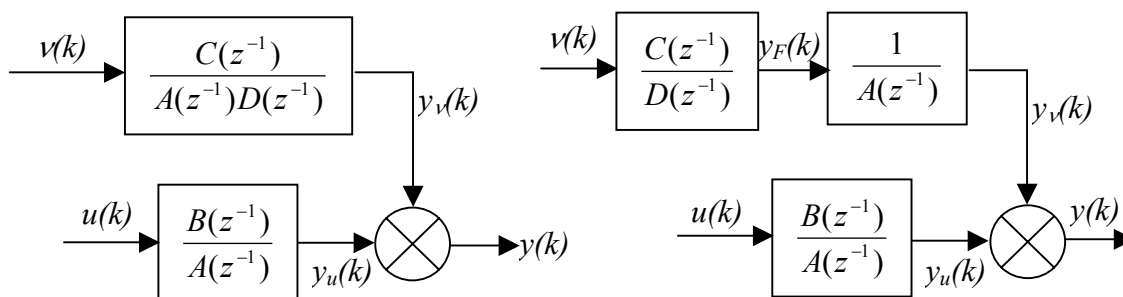
kde $A = A(z^{-1}) = 1 + a_1 z^{-1} + a_2 z^{-2} + a_3 z^{-3} + \dots + a_n z^{-n}$
 $B = B(z^{-1}) = z^{-v} (b_0 + b_1 z^{-1} + b_2 z^{-2} + b_3 z^{-3} + \dots + b_m z^{-m})$,
 $n, m, v \dots$ jsou stupně polynomů, které je **třeba zvolit**.

Stochastický signál $y_v(k)$ je třeba v stochastické části modelu aproximovat průchodem bílého šumu vhodným diskrétním přenosem. Základem stochastické části modelu může být diskrétní přenos (2-2), který popisuje dynamické vlastnosti lineárního diskrétního filtru, jestliže na vstupu filtru je bílý šum $v(k)$. Na přednáškách z Teorie řízení I (Struktura regulačního obvodu s měřenými i neměřenými poruchami) byl diskutován problém aproximace dynamických účinků poruch pomocí obrazových přenosů $F_d(s)$ a $F_m(s)$. Bylo ukázáno, že je-li možno dynamický systém popsat stavovou rovnicí, pak jmenovatele obrazových přenosů $F_u(s)$, $F_d(s)$ a $F_m(s)$ obsahují stejný polynom, který je charakteristickým

polynomem přenosové matice. Proto obrazový přenos stochastické části modelu zvolíme ve tvaru

$$G_v(z^{-1}) = \frac{1}{A(z^{-1})} G_F(z^{-1}) = \frac{C(z^{-1})}{A(z^{-1})D(z^{-1})} \rightarrow y_v(k) = \frac{C}{A} * \frac{1}{D} * v(k) \quad (3-3)$$

Blokové schéma tohoto modelu je na obr.3.1a. Je zřejmé, že tento model má dva vstupy, jeden pro determinovaný vstup $u(k)$ a druhý pro speciální stochastický signál - bílý šum $v(k)$, který prochází přes lineární filtr $G_F = C/D$, jehož výstupem je stacionární stochastický signál $y_F(k)$, viz obr.3.1b.



Obr.3.1a *Blokové schéma modelu* Obr.3.1b *Blokové schéma modelu se signálem*
 Dosazením (3 – 2) a (3 – 3) do (3 – 1) dostaneme

$$y(k) = y_u(k) + y_v(k) = \frac{B(z^{-1})}{A(z^{-1})}u(k) + G_F(z^{-1})\frac{1}{A(z^{-1})}v(k) = \frac{B(z^{-1})}{A(z^{-1})}u(k) + \frac{C(z^{-1})}{A(z^{-1})D(z^{-1})}v(k) \quad (3-4)$$

Vynásobíme-li rovnici (3 – 4) polynomem $A(z^{-1})$, můžeme diskrétní model přepsat do tvaru

$$y(k)A(z^{-1}) - B(z^{-1})u(k) = \frac{C(z^{-1})}{D(z^{-1})}v(k) = G_F(z^{-1})v(k) \quad (3-5)$$

Rovnost (3 – 5) je možno vyjádřit ve tvaru diferenční rovnice

$$y(k) + a_1y(k-1) + \dots + a_ny(k-n) - [b_0u(k-1) + b_1u(k-2) + \dots + b_mu(k-m)] = \frac{C(z^{-1})}{D(z^{-1})}v(k),$$

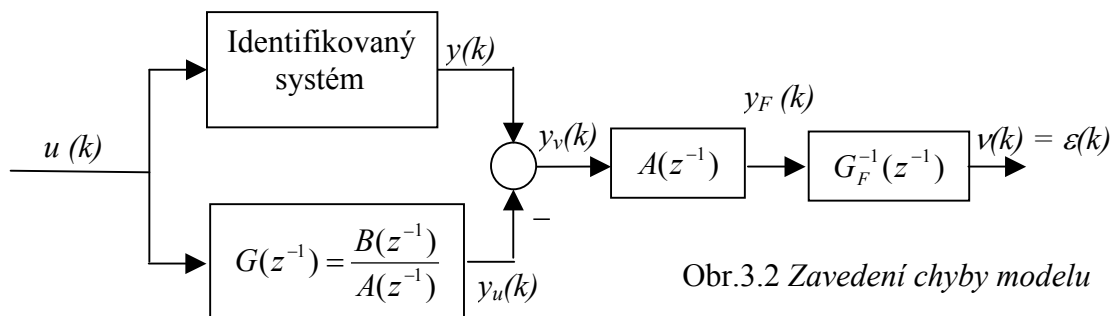
zkráceně pak ve tvaru

$$\boxed{y(k)A(z^{-1}) - B(z^{-1})u(k) = G_F(z^{-1})v(k)}. \quad (3-6)$$

4.2 CHYBY MODELU

Připomeneme si nyní, že hledaný model má sloužit k identifikaci dynamických systémů. Bude nás tedy určitě zajímat, jaké chyby je možno s požadovaným modelem dosáhnout. Pro vyjádření chyby existuje více možností.

a) Jedna z možných struktur chyb je zobrazena na obr.3.2. Pro posouzení vlastností chyby modelů budeme uvažovat ideální situaci, kdy se předpokládá, že odhady parametrů polynomů A, B, C, D jsou rovny skutečným parametrům. Určíme rozdíl $y(k) - y_u(k) = y_v(k)$



Obr.3.2 Zavedení chyby modelu

Na základě předpokladů o odhadech parametrů platí $\Delta(k) = y(k) - y_u(k) = y_v(k)$. Vyjádříme-li $\Delta(k) = y_v(k)$ pomocí rovnice (3 – 4) pak platí

$$\Delta(k) = A(z^{-1})G_F^{-1}(z^{-1})\varepsilon(k) \rightarrow y_v(k) = A(z^{-1})G_F^{-1}(z^{-1})v(k). \quad (3 - 7)$$

Chyba výstupu modelu je rovna

$$\varepsilon(k) = A(z^{-1})G_F^{-1}(z^{-1})\Delta(k) = A(z^{-1})G_F^{-1}(z^{-1})[y(k) - \frac{B(z^{-1})}{A(z^{-1})}u(k)] = v(k), \quad (3 - 8a)$$

kde $\varepsilon(k)$ je **chyba výstupu modelu**.

Z rovnosti (3 – 8a) vyplývá, že chyba modelu, jsou-li odhady parametrů polynomů A, B, C, D rovny skutečným parametrům, je rovna právě diskrétním hodnotám bílého šumu $\varepsilon(k) = v(k)$.

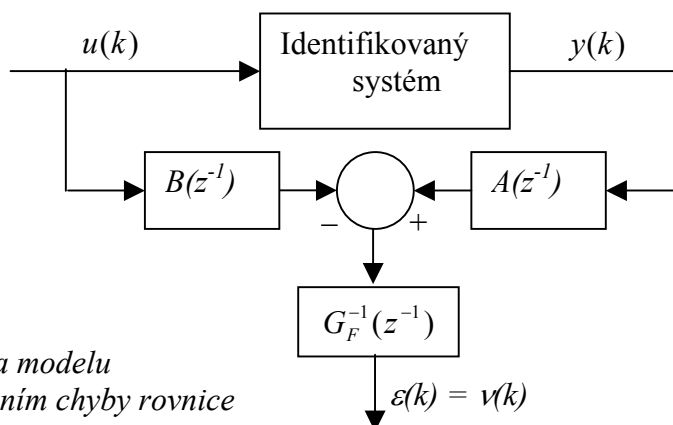
b) Budeme-li vycházet z diferenční rovnice (3 – 6) pak pro chybu platí

$$y(k)A(z^{-1}) - B(z^{-1})u(k) = G_F(z^{-1})\varepsilon(k).$$

S využitím (2 – 7) můžeme chybu $\varepsilon(k)$ vyjádřit rovností

$$\varepsilon(k) = G_F^{-1}(z^{-1})[y(k)A(z^{-1}) - B(z^{-1})u(k)] = v(k) \quad (3 - 8b)$$

Takto zavedená chyba se označuje jako **chyba rovnice** a její struktura je na obr.3.3.




Obr.3.3 Struktura modelu se zavedením chyby rovnice


4.3 STRUKTURA DISKRÉTNÍCH MODELŮ

Při identifikaci se používají různé struktury modelů, které vycházejí z rovnosti (3 – 8b) a podle konkrétního šumového signálu se volí přenos $G_F(z^{-1})$.

1) Zvolíme-li $G_F(z^{-1}) = 1$, pak dostaneme blokové schéma modelu dynamické soustavy dle obr.3.4, který se označuje zkratkou model **ARX** (**A**uto-**R**egresiv with **e**Xogenous variable).



Obr.3.4 Struktura ARX modelu



Obr.3.5 Struktura OE modelu

Výstup modelu lze vyjádřit rovností

$$y(k) = \frac{B(z^{-1})}{A(z^{-1})}u(k) + \frac{1}{A(z^{-1})}v(k) \quad (3 - 9)$$

Diferenční rovnice modelu ARX je

$$y(k) = -a_1y(k-1) - \dots - a_ny(k-n) + b_0u(k-1) + \dots + b_mu(k-m) + v(k) \quad (3 - 10)$$

2) Zvolíme-li $G_F(z^{-1}) = A(z^{-1})$, pak výstup modelu je roven

$$y(k) = \frac{B(z^{-1})}{A(z^{-1})}u(k) + v(k). \quad (3 - 11)$$

Diferenční rovnice má tvar

$$y(k) = -a_1y(k-1) - \dots - a_ny(k-n) + b_0u(k-1) + \dots + b_mu(k-m) + v(k) + a_1v(k-1) + \dots + a_nv(k-n)$$

Tento model se označuje zkratkou **OE** (**O**utput **E**rror) a jeho blokové schéma je na obr.3.5.


3) Zvolíme-li $G_F(z^{-1}) = C(z^{-1})$, pak výstup modelu je roven

$$y(k) = \frac{B(z^{-1})}{A(z^{-1})}u(k) + \frac{C(z^{-1})}{A(z^{-1})}v(k), \quad (3 - 12)$$


Diferenční rovnice má tvar

$$y(k) = -a_1y(k-1) - \dots - a_ny(k-n) + b_0u(k-1) + \dots + b_mu(k-m) + c_0v(k) + c_1v(k-1) + \dots + c_nv(k-n). \quad (3-13)$$

Blokové schéma a tohoto modelu je na obr.3.6 a označuje se zkratkou **ARMAX** model (**A**uto-**R**egresive **M**oving **A**verage with **e**Xogenous variable), což znamená autoregresní model s klouzavým průměrem a s externí proměnnou – akční veličinou $u(k)$.



Obr.3.6 Blokové schéma ARMAX modelu



Obr.3.7 Blokové schéma BJ modelu

4) Blokové schéma modelu **BJ** (**B**ox – **J**enkins) je na obr.3.7 a jeho výstup je definován rovnicí

$$y(k) = \frac{B(z^{-1})}{A(z^{-1})}u(k) + \frac{C(z^{-1})}{A(z^{-1})D(z^{-1})}v(k). \quad (3-14)$$

Diferenční rovnice ve zkráceném tvaru je

$$y(k)A(z^{-1})D(z^{-1}) - B(z^{-1})D(z^{-1})u(k) = C(z^{-1})A(z^{-1})v(k). \quad (3-15)$$

Zavedeme-li označení

$$A^*(z^{-1}) = A(z^{-1})D(z^{-1}); B^*(z^{-1}) = B(z^{-1})D(z^{-1}); C^*(z^{-1}) = C(z^{-1})A(z^{-1}), \quad (3-16)$$

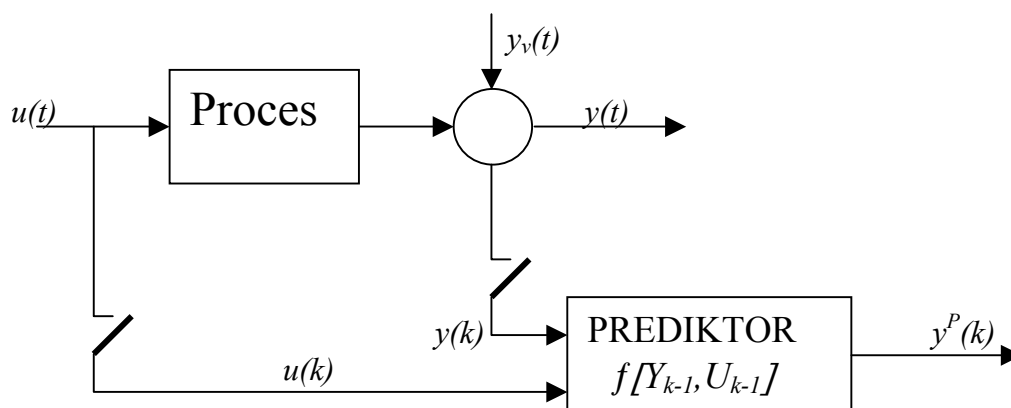
pak diferenční rovnice má tvar:

$$y(k)A^*(z^{-1}) - B^*(z^{-1})u(k) = C^*(z^{-1})v(k) \quad (3-17)$$

Porovnáním (3-17) a (3-12) je zřejmé, že model BJ je možno převést na ARMAX model.

4.4 PREDIKCE VÝSTUPU

Stochastická diferenční rovnice a její modifikace je obsažena v modifikovaném tvaru v modelech ARX, OE, ARMAX, BJ. Tyto modely popisují dynamické vlastnosti soustav za přítomnosti šumů a jak bylo ukázáno, obsahují ve své struktuře modelu na vstupu složky bílého šumu $v(k-i)$, $i = 0, 1, \dots, n$, které **nejsou měřitelné**. Proto, ani při znalosti všech koeficientů takovýchto modelů, není možno **vypočítat výstup $y(k)$** při známých hodnotách vstupu $u(k-j)$, $j = 0, \dots, m$ a měřených minulých hodnotách výstupu $y(k-i)$, pro $i = 1, \dots, n$. Tato úloha je řešena třídou matematických modelů, které se nazývají prediktory. Odhad výstupu $y^P(k)$ pomocí prediktoru je znázorněn na obr. 3.8. Predikce výstupu je obecně nelineární



Obr.3.8 Odhad výstupu pomocí prediktoru

funkce

$$y^P(k) = f[Y_{k-1}, U_{k-1}],$$

kde ... Y_{k-1} je množina měřených výstupů, U_{k-1} je množina měřených vstupů.

V dalším výkladu se omezíme pouze na **model ARX**, jehož výstup je popsán diferenční rovnicí (3 – 10). Vyjádříme-li výstup $y(k) = y_k$ pomocí vektoru parametrů \mathbf{p} a vektoru měření \mathbf{z}_k v časovém okamžiku “ k “, pak platí

$$y_k = \mathbf{p}^T \mathbf{z}_k + v_k, \quad (3 - 18)$$

kde ... $\mathbf{p}^T = [-a_1, -a_2, \dots, -a_n, b_0, b_1, \dots, b_m]$; $\mathbf{z}_k^T = [y_{k-1}, y_{k-2}, \dots, y_{k-n}, u_{k-1}, u_{k-2}, \dots, u_{k-m}]$.

Predikci výstupu je možno vyjádřit jako podmíněnou střední hodnotu

$$\hat{y}_k = E\{y_k / y_{k-1}, y_{k-2}, \dots, y_{k-n}, u_{k-1}, u_{k-2}, \dots, u_{k-m}\}.$$

S použitím rovnosti (3 – 18) dostaneme

$$E\{\hat{y}_k\} = \mathbf{p}^T \mathbf{z}_k + E\{v_k\}.$$

Protože střední hodnota bílého šumu je rovna nule ($E\{v_k\} = 0$), je predikce rovna výrazu

$$y_k^P = \mathbf{p}^T \mathbf{z}_k = -\sum_{i=1}^n a_i y_{k-i} + \sum_{j=0}^m b_j u_{k-j-v} \quad (3-19)$$

Jednoduchým použitím operátoru střední hodnoty jsme získali z modelu ARX jednoduchý prediktor, pomocí kterého můžeme na základě měřených vstupů a výstupů predikovat - odhadovat výstup systému y_k .

5 ODHAD PARAMETRŮ MODELU ARX METODOU NEJMENŠÍCH ČTVERCŮ

Pokud vektor parametrů \mathbf{p} není znám, ale bude v procesu vyhodnocování měření odhadnut, pak hovoříme o vektoru odhadu parametrů $\hat{\mathbf{p}}$. Odhad výstupu z prediktoru pak označíme \hat{y}_k a jeho popis bude

$$\hat{y}_k = \hat{\mathbf{p}}^T \mathbf{z}_k = -\sum_{i=0}^n \hat{a}_i y_{k-i} + \sum_{j=0}^m \hat{b}_j y_{k-j-v},$$

kde pro v platí: $\tau_D = (v-1) * T + \xi * T$;
 τ_D je dopravní zpoždění, T je perioda vzorkování, $\xi \in \langle 0,1 \rangle$

Chyba predikce je definována

$$e(k) = y_k - \hat{y}_k = y_k - \hat{\mathbf{p}}^T \mathbf{z}_k = y_k + \sum_{i=0}^n \hat{a}_i y_{k-i} - \sum_{j=0}^m \hat{b}_j y_{k-j-v}. \quad (4-1)$$

5.1 METODA NEJMENŠÍCH ČTVERCŮ

Pro odhad parametrů na základě měření a volby diskrétního modelu existuje celá řada metod. V našem kurzu bude použita pro odhad vektoru parametrů $\hat{\mathbf{p}}$ metoda nejmenších čtverců, kterou jako první použil a publikoval K. G. Gauss již v roce 1795. Základní myšlenka spočívá v tom, že odhad vektoru parametrů $\hat{\mathbf{p}}$ minimalizuje součet kvadrátů chyb, tj. že je splněna podmínka

$$J_2(\hat{\mathbf{p}}) = \sum_{k=1}^N e(k)^2 \rightarrow MIN, \quad (4-2)$$

kde ... N je počet měření.

Celý postup si ukážeme na následujícím příkladě. Budeme uvažovat N měřených dvojic (y_k, u_k) a diferenční rovnici prediktoru ve tvaru

$$\hat{y}_k = -\hat{a}_1 y_{k-1} + \hat{b}_0 u_{k-1}.$$

Vyjádříme-li chybu predikce pro $k = 1, 2, 3, \dots, N$, pak získáme soustavu rovnic ve tvaru

$$\begin{aligned}
k = 1; & \quad e_1 = y_1 - \hat{y}_1 = y_1 + \hat{a}_1 y_0 - \hat{b}_0 u_0; \\
k = 2; & \quad e_2 = y_2 - \hat{y}_2 = y_2 + \hat{a}_1 y_1 - \hat{b}_0 u_1; \\
k = 3; & \quad e_3 = y_3 - \hat{y}_3 = y_3 + \hat{a}_1 y_2 - \hat{b}_0 u_2; & \Rightarrow & \quad (4-3) \\
& \quad \vdots \\
k = N; & \quad e_N = y_N - \hat{y}_N = y_N + \hat{a}_1 y_{N-1} - \hat{b}_0 u_{N-1};
\end{aligned}$$

Zavedeme-li vektory $\mathbf{e}, \mathbf{y}, \hat{\mathbf{p}}$ a matici \mathbf{W} ve tvaru

$$\mathbf{e} = \begin{bmatrix} e_1 \\ e_2 \\ e_3 \\ \vdots \\ e_N \end{bmatrix}; \quad \mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ \vdots \\ y_N \end{bmatrix}; \quad \mathbf{W} = \begin{bmatrix} y_0; u_0 \\ y_1; u_1 \\ y_2; u_2 \\ \vdots \\ y_{N-1}; u_{N-1} \end{bmatrix}; \quad \hat{\mathbf{p}} = \begin{bmatrix} -\hat{a}_1 \\ +\hat{b}_0 \end{bmatrix};$$

pak soustavu rovnic (4-3) můžeme vyjádřit v maticovém tvaru

$$\mathbf{e} = \mathbf{y} - \mathbf{W}\hat{\mathbf{p}}. \quad (4-4)$$

Hodnota kvadratického kriteria $J(-\hat{a}_1, \hat{b}_0)$ v závislosti na zatím neurčených parametrech modelu je rovna

$$J(-\hat{a}_1, \hat{b}_0) = \sum_{k=1}^N e_k^2 = \mathbf{e}^T \mathbf{e} = (\mathbf{y} - \mathbf{W}\hat{\mathbf{p}})^T (\mathbf{y} - \mathbf{W}\hat{\mathbf{p}}) = \mathbf{y}^T \mathbf{y} - 2\hat{\mathbf{p}}^T \mathbf{W}^T \mathbf{y} + \hat{\mathbf{p}}^T \mathbf{W}^T \mathbf{W} \hat{\mathbf{p}}, \quad (4-5)$$

jestliže je splněna rovnost $\hat{\mathbf{p}}^T \mathbf{W}^T \mathbf{y} = \mathbf{y}^T \mathbf{W}\hat{\mathbf{p}}$.

Nutná podmínka existence minima (4-2) je

$$\frac{\partial J(\hat{\mathbf{p}})}{\partial \hat{\mathbf{p}}} = 0 \rightarrow -2\mathbf{W}^T \mathbf{y} + 2(\mathbf{W}^T \mathbf{W}) \hat{\mathbf{p}} = 0. \quad (4-6)$$

Hledaný vektor odhadů parametrů vypočteme z (4-6)

$$\hat{\mathbf{p}} = (\mathbf{W}^T \mathbf{W})^{-1} \mathbf{W}^T \mathbf{y}. \quad (4-7)$$

Aplikaci rovnosti (4-7) a struktury vektorů a matice \mathbf{W} ukážeme na Př.3.

Příklad 3

Uvažujme naměřenou diskrétní posloupnost z Př.2, která je bez šumu. $N = 3$.

$$y_k = \{0; 0,5; 0,75; 0,875\} \text{ a } u_k = \{1; 1; 1; 1\}, (k = 0, 1, 2, 3)$$

Model prediktoru zvolíme ve tvaru $\hat{y}_k = -\hat{a}_1 y_{k-1} + \hat{b}_0 u_{k-1}$. Datové struktury vektorů \mathbf{y} , $\hat{\mathbf{p}}$ a matice \mathbf{W} pak jsou

$$\mathbf{y} = \begin{bmatrix} 0,500 \\ 0,750 \\ 0,875 \end{bmatrix}; \mathbf{W} = \begin{bmatrix} 0,00;1 \\ 0,50;1 \\ 0,75;1 \end{bmatrix}; \mathbf{W}^T = \begin{bmatrix} 0,00;0,50;0,75 \\ 1,00;1,00;1,00 \end{bmatrix}; \mathbf{W}^T * \mathbf{W} = \begin{bmatrix} 0,8125;1,25 \\ 1,250;3,000 \end{bmatrix}; \hat{\mathbf{p}} = \begin{bmatrix} -a_1 \\ +b_0 \end{bmatrix};$$

$$(\mathbf{W}^T * \mathbf{W})^{-1} = \begin{bmatrix} +3,4286; -1,4286 \\ -1,4286; +0,9286 \end{bmatrix}; \mathbf{W}^T * \mathbf{y} = \begin{bmatrix} 1,0313 \\ 2,1250 \end{bmatrix}$$

$$\hat{\mathbf{p}} = (\mathbf{W}^T \mathbf{W})^{-1} \mathbf{W}^T \mathbf{y} = \begin{bmatrix} +3,4286; -1,4286 \\ -1,4286; +0,9286 \end{bmatrix} * \begin{bmatrix} 1,0313 \\ 2,1250 \end{bmatrix} = \begin{bmatrix} 0,5 \\ 0,5 \end{bmatrix}; a_1 = -0,5; b_0 = 0,5$$

Z výsledku je zřejmé, že podle očekávání byly nalezeny stejné parametry modelu jako výpočtem v Př.2. Obdobným způsobem sestavíme datové struktury i pro jiný řád modelu a počet vzorků.

Konec příkladu

5.2 VLASTNOSTI ODHADŮ

V této kapitole se pokusíme ukázat základní vlastnosti odhadů parametrů.

1) První otázkou je, jaká je souvislost mezi odhadnutým vektorem parametrů $\hat{\mathbf{p}}$ a skutečným vektorem parametrů \mathbf{p} . Můžeme vycházet z předpokladu, že měřený vektor výstupu soustavy \mathbf{y} můžeme vyjádřit ve tvaru

$$\mathbf{y} = \mathbf{W}\mathbf{p} + \mathbf{e}, \quad (4-8)$$

kde ... \mathbf{p} je vektor skutečných parametrů,
 \mathbf{W} je matice dat,
 \mathbf{e} je vektor šumu.

Dosazením (4-8) do (4-7) dostaneme

$$\hat{\mathbf{p}} = (\mathbf{W}^T \mathbf{W})^{-1} \mathbf{W}^T \mathbf{y} = (\mathbf{W}^T \mathbf{W})^{-1} \mathbf{W}^T * (\mathbf{W}\mathbf{p} + \mathbf{e}) = \mathbf{p} + (\mathbf{W}^T \mathbf{W})^{-1} \mathbf{W}^T \mathbf{e}. \quad (4-9)$$

V rovnici (4-9) je na pravé straně vektor šumu \mathbf{e} . Z toho vyplývá, že parametry odhadovaného vektoru $\hat{\mathbf{p}}$ jsou náhodné veličiny. Můžeme tedy určit jejich střední hodnotu

$$E\{\hat{\mathbf{p}}\} = E\{\mathbf{p} + (\mathbf{W}^T \mathbf{W})^{-1} \mathbf{W}^T \mathbf{e}\} = E\{\mathbf{p}\} + E\{(\mathbf{W}^T \mathbf{W})^{-1} \mathbf{W}^T \mathbf{e}\},$$

kde E je operátor střední hodnoty. Označíme-li $E\{\hat{\mathbf{p}}\} = \hat{\mathbf{p}}$; $E\{\mathbf{p}\} = \mathbf{p}$; a budeme-li předpokládat, že prvky datové matice \mathbf{W} a vektoru šumu \mathbf{e} jsou statisticky nezávislé, pak platí

$$\hat{\mathbf{p}} = \mathbf{p} + E\{(\mathbf{W}^T \mathbf{W})^{-1} \mathbf{W}^T\} * E\{\mathbf{e}\}.$$

Je-li střední hodnota šumového signálu nulová, pak dostaneme rovnost

$$E\{\mathbf{e}\} = \mathbf{0} \rightarrow \hat{\mathbf{p}} = \mathbf{p} \quad (4 - 10)$$

a je možno zformulovat tvrzení

Odhad parametrů vektoru $\hat{\mathbf{p}}$ metodou nejmenších čtverců je nestranný (nevychýlený), je-li střední hodnota složek vektoru \mathbf{e} nulová a jsou-li sloupce datové matice \mathbf{W} a vektoru \mathbf{e} vzájemně statisticky nezávislé.

Poznámka: Informace o rozptylech a kovariancích vektoru chyb \mathbf{e} je obsažena v kovariační matici. Za předpokladu, že vektor šumu \mathbf{e} obsahuje prvky statisticky nezávislé, platí

$$\bar{\mathbf{c}}_{ee} = E\{\mathbf{e}\mathbf{e}^T\} = \sigma_e^2 \mathbf{I}, \quad (4 - 11)$$

kde σ_e^2 je rozptyl šumového signálu.

Další informace o možnostech numerických výpočtů střední hodnoty, rozptylu, směrodatné odchylky, kovariační matice, korelačních koeficientů naleznete ve "Stručném manuálu MATLABu pro předměty teorie řízení" v oddíle "Náhodný proces" na adrese

http://www.fm.vslib.cz/~krt/krt_cz/vyuka/text/matlab/html.htm.

2) Jistě nás bude taky zajímat, jak "přesné" jsou nalezené odhady, jinými slovy, jaké vlastnosti má rozdíl $\Delta = \hat{\mathbf{p}} - \mathbf{p}$. Víme již, že střední hodnota $E\{\Delta\}$ je rovna nule viz (4 - 10). Informace o rozptylech vektoru Δ určíme z jeho kovariační matice

$$\mathbf{R}_{\Delta\Delta} = E\{\Delta\Delta^T\} = E\{(\hat{\mathbf{p}} - \mathbf{p})(\hat{\mathbf{p}} - \mathbf{p})^T\}.$$

Vyjádříme-li $(\hat{\mathbf{p}} - \mathbf{p})$ z (4 - 9) dostaneme

$$\mathbf{R}_{\Delta\Delta} = E\{[(\mathbf{W}^T \mathbf{W})^{-1} \mathbf{W}^T \mathbf{e}] [(\mathbf{W}^T \mathbf{W})^{-1} \mathbf{W}^T \mathbf{e}]^T\} = E\{(\mathbf{W}^T \mathbf{W})^{-1} \mathbf{W}^T \mathbf{e} \mathbf{e}^T \mathbf{W} (\mathbf{W}^T \mathbf{W})^{-1}\}.$$

Vzhledem k předpokládané statistické nezávislosti prvků vektoru \mathbf{e} a prvků matice \mathbf{W} a s využitím věty o střední hodnotě součinu statisticky nezávislých veličin dostaneme

$$\mathbf{R}_{\Delta\Delta} = E\{(\mathbf{W}^T \mathbf{W})^{-1} \mathbf{W}^T\} E\{\mathbf{e} \mathbf{e}^T\} E\{\mathbf{W} (\mathbf{W}^T \mathbf{W})^{-1}\} = E\{\mathbf{e} \mathbf{e}^T\} E\{(\mathbf{W}^T \mathbf{W})^{-1}\}.$$

S využitím (4 - 11) pak má kovariační matice tvar

$$\mathbf{R}_{\Delta\Delta} = E\{\Delta\Delta^T\} = E\{(\hat{\mathbf{p}} - \mathbf{p})(\hat{\mathbf{p}} - \mathbf{p})^T\} = \sigma_e^2 (\mathbf{W}^T \mathbf{W})^{-1} \quad (4-12)$$

Pro rovnost (4-12) je možno zformulovat tvrzení

Jsou-li složky matice \mathbf{W} a vektoru \mathbf{e} statisticky nezávislé: $E\{e_i\} = 0; E\{e_i^2\} = \sigma_e^2$ pro $i = 1, 2, \dots$, pak platí

$$E\{(\hat{\mathbf{p}} - \mathbf{p})(\hat{\mathbf{p}} - \mathbf{p})^T\} = \sigma_e^2 (\mathbf{W}^T \mathbf{W})^{-1}.$$

5.3 ODHAD VEKTORU PARAMETRŮ POMOCÍ KORELAČNÍCH FUNKCÍ

Uvažujme diferenční rovnici ARX modelu druhého řádu ve tvaru

$$y(k) = -a_1 y(k-1) - a_2 y(k-2) + b_0 u(k-1) + b_1 u(k-2). \quad (4-13)$$

Vektor odhadu parametrů je pak $\hat{\mathbf{p}} = [-a_1, -a_2, b_0, b_1]$. Vyjádříme-li strukturu součiny matic $\mathbf{A} = \mathbf{W}^T \mathbf{W}$ z výrazu (4-7) pro zvolenou strukturu modelu, dostaneme strukturu

$$\begin{aligned} \mathbf{A} = \mathbf{W}^T \mathbf{W} &= \begin{bmatrix} y_0 & y_1 & y_2 & \dots & y_{N-1} \\ y_{-1} & y_0 & y_1 & \dots & y_{N-2} \\ u_0 & u_1 & u_2 & \dots & u_{N-1} \\ u_{-1} & u_0 & u_1 & \dots & u_{N-2} \end{bmatrix} \cdot \begin{bmatrix} y_0 & y_{-1} & u_0 & u_{-1} \\ y_1 & y_0 & u_1 & u_0 \\ y_2 & y_1 & u_2 & u_1 \\ \vdots & & & \\ y_{N-1} & y_{N-2} & u_{N-1} & u_{N-2} \end{bmatrix} = \\ &= N \begin{bmatrix} \frac{1}{N} \sum_{i=0}^{N-1} y_i^2 & \frac{1}{N} \sum_{i=0}^{N-1} y_i y_{i-1} & \frac{1}{N} \sum_{i=0}^{N-1} y_i u_i & \frac{1}{N} \sum_{i=0}^{N-1} y_i u_{i-1} \\ \frac{1}{N} \sum_{i=0}^{N-1} y_{i-1} y_i & \frac{1}{N} \sum_{i=0}^{N-1} y_{i-1}^2 & \frac{1}{N} \sum_{i=0}^{N-1} y_{i-1} u_i & \frac{1}{N} \sum_{i=0}^{N-1} y_{i-1} u_{i-1} \\ \frac{1}{N} \sum_{i=0}^{N-1} u_i y_i & \frac{1}{N} \sum_{i=0}^{N-1} u_i y_{i-1} & \frac{1}{N} \sum_{i=0}^{N-1} u_i^2 & \frac{1}{N} \sum_{i=0}^{N-1} u_i u_{i-1} \\ \frac{1}{N} \sum_{i=0}^{N-1} u_{i-1} y_i & \frac{1}{N} \sum_{i=0}^{N-1} u_{i-1} y_{i-1} & \frac{1}{N} \sum_{i=0}^{N-1} u_{i-1} u_i & \frac{1}{N} \sum_{i=0}^{N-1} u_{i-1}^2 \end{bmatrix} = \\ &= N \begin{bmatrix} c_{yy}(0) & c_{yy}(-1) & c_{yu}(0) & c_{yu}(-1) \\ c_{yy}(-1) & c_{yy}(0) & c_{yu}(-1) & c_{yu}(0) \\ c_{uy}(0) & c_{uy}(-1) & c_{uu}(0) & c_{uu}(-1) \\ c_{uy}(-1) & c_{uy}(0) & c_{uu}(-1) & c_{uu}(0) \end{bmatrix}. \end{aligned}$$

Ze struktury součiny $\mathbf{W}^T \mathbf{W}$ je zřejmé, že prvky matice \mathbf{A} tvoří hodnoty autokorelační a vzájemné korelační funkce $c_{yy}(k), c_{uy}(k), c_{yu}(k)$ a $c_{uu}(k)$ pro $k = 0, -1$ výstupního a

vstupního signálu y_k , u_k (viz Příloha). Všechny prvky matice jsou vynásobené počtem měření N . Pro součin $\mathbf{b} = \mathbf{W}^T \mathbf{y}$ dostaneme strukturu

$$\mathbf{b} = \mathbf{W}^T \mathbf{y} = \begin{bmatrix} y_0 & y_1 & y_2 & \cdots & y_{N-1} \\ y_{-1} & y_0 & y_1 & \cdots & y_{N-2} \\ u_0 & u_1 & u_2 & \cdots & u_{N-1} \\ u_{-1} & u_0 & u_1 & \cdots & u_{N-2} \end{bmatrix} \cdot \begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ \vdots \\ y_N \end{bmatrix} = N \begin{bmatrix} \frac{1}{N} \sum_{i=1}^N y_{i-1} y_i \\ \frac{1}{N} \sum_{i=1}^N y_{i-2} y_i \\ \frac{1}{N} \sum_{i=1}^N u_{i-1} y_i \\ \frac{1}{N} \sum_{i=1}^N u_{i-2} y_i \end{bmatrix} = N \begin{bmatrix} c_{yy}(1) \\ c_{yy}(2) \\ c_{uy}(1) \\ c_{uy}(2) \end{bmatrix}.$$

Je možno konstatovat, že prvky vektoru \mathbf{b} tvoří *hodnota* autokorelační a korelační funkce $c_{yy}(1)$, $c_{yy}(2)$, $c_{uy}(1)$, $c_{uy}(2)$. Vektor parametrů $\hat{\mathbf{p}}$ je pak možno určit z rovnosti

$$\hat{\mathbf{p}} = \mathbf{A}^{-1} \mathbf{b} = \begin{bmatrix} c_{yy}(0); c_{yy}(-1); c_{yu}(0); c_{yu}(-1) \\ c_{yy}(-1); c_{yy}(0); c_{yu}(-1); c_{yu}(0) \\ c_{uy}(0); c_{uy}(-1); c_{uu}(0); c_{uu}(-1) \\ c_{uy}(-1); c_{uy}(0); c_{uu}(-1); c_{uu}(0) \end{bmatrix}^{-1} * \begin{bmatrix} c_{yy}(1) \\ c_{yy}(2) \\ c_{uy}(1) \\ c_{uy}(2) \end{bmatrix}. \quad (4-14)$$

Prakticky lze z naměřených dat určit vektor parametrů $\hat{\mathbf{p}}$ buď přímo ze vztahu (4-7), nebo můžeme pomocí vhodného software nejdříve určit hodnoty korelačních a autokorelačních funkcí vstupního a výstupního signálu pro $k = 0, -1, +1, -2, +2, \dots$ podle zvolené struktury diferenční rovnice a následně použít rovnosti (4-14).

6 SOFTWAREOVÁ PODPORA DISKRÉTNÍ PARAMETRICKÉ IDENTIFIKACE

Aplikace metod diskrétní parametrické identifikace se opírají o softwarovou podporu v prostředí MATLABu. Využívá se SIMULINKu, Control System Toolboxu ale především „System Identification Toolbox“. Jedná se o velmi rozsáhlý programový produkt, ze kterého předkládáme opravdu jen malý zlomek, několik málo vybraných funkcí. Tyto však umožní studentům studovanou látku nejen ověřovat pomocí numerických experimentů ale i získat nezbytné profesní návyky a zkušenosti z identifikace. Podrobný popis a přehled všech funkcí je možno najít v "Helpu".

Předpokládáme, že data, se kterými se operuje, jsou uložena ve workspace.

Funkce **arx**

Odhad - výpočet parametrů ARX modelu

Model ARX s jedním vstupem a jedním výstupem v prostředí MATLABu je vyjádřen zkrácenou diferenční rovnicí tvaru

$$A(q)y(t) = B(q)u(t - nk) + e(t),$$

kde je	$y(t)$	diskrétní výstupní veličina ($t = k$ je diskrétní čas),
	$u(t - nk)$	diskrétní vstupní veličina,
	nk	kladné celé číslo charakterizující diskrétní dopravní zpoždění jako celočíselný násobek periody vzorkování,
	$e(t)$	diskrétní šumový-stochastický signál,
	$A(q)$	polynom stupně $\partial A = na$, $q = z^{-1}$, $A(q) = 1 + a_1q^1 + \dots + a_naq^{na}$,
	$B(q)$	polynom stupně $\partial B = m = nb - 1$, $B(q) = b_0 + b_1q^1 + \dots + b_mq^m$,
	nb	počet koeficientů polynomu $B(q)$

Příkaz pro výpočet parametrů ARX modelu metodou nejmenších čtverců má syntaxi

$$\mathbf{th} = \mathbf{arx}(\mathbf{z}, \mathbf{nn}) \quad (5 - 1)$$

1)

kde je	th	datová struktura - matice, obsahující ve 3. řádku vektor parametrů ,
	z=[y u];	matice výstupních - vstupních dat (output - input data),
	y, u	sloupcové vektory,
	nn	jednořádková matice se třemi sloupci, nn=[na nb nk] .

Strukturou matice **th** – „modelem theta“ se nebudeme zabývat, protože to přesahuje rámec našeho předmětu. Požadované informace nebo struktury modelů vhodných pro další výpočty získáme pomocí transformačních příkazů a funkcí.

Příkaz **present (th)**

(5 - 2)

zobrazí z datové struktury matice **th**, která byla vytvořena příkazem (5 - 1), koeficienty polynomů $B(q)$, $A(q)$ společně s jejich směrodatnými odchylkami, hodnotou kvadratického

funkcionálu (loss function) a Akaikeho chybou predikce (Akaike's Final Prediction Error Criterion (FPE)).

Př.5.1

Ukažme použití příkazu **arx** na datech z Př.2. kap.2. Naměřená data uložíme do matice **mz**. Zvolme: stupeň polynomu $\partial A = na = 1$, $\partial B = m = 0$, pak počet koeficientů polynomu B je $nb = m + 1 = 1$. Diskrétní dopravní zpoždění je $nk = 1$ a datová struktura parametrů je **thz**. Na displeji se zobrazí: matice **mz**, jednořádková matice **nn**, datová struktura **thz**.

```

>> mz
mz =
      0      1.0000
    0.5000  1.0000
    0.7500  1.0000
    0.8750  1.0000

>> nn
nn =
      1      1      1

>> thz=arx(mz,nn)
thz =
Columns 1 through 7
    0.0000    1.0000    1.0000    1.0000    1.0000         0         0
    0.0000   20.0100    9.0000    4.0000   11.0000   21.0000    1.0000
   -0.5000    0.5000         0         0         0         0         0
    0.0000    0.0000         0         0         0         0         0
    0.0000    0.0000         0         0         0         0         0

Columns 8 through 9
      0      1.0000
      0         0
      0         0
      0         0
      0         0

```

Obr.5.1 Použití funkce **arx** v příkazovém řádku

Pomocí příkazu **present** zobrazíme koeficienty polynomů $A(q)$, $B(q)$ a jejich směrodatné odchylky.

*Poznámka: Je třeba si uvědomit, že příkaz **present** uvedené koeficienty polynomů a další informace pouze zobrazuje. Není je možno použít pro další výpočty. K tomu jsou určeny další příkazy a funkce, které budou dále ještě vysvětleny.*

Použití příkazu **present** z příkazového řádku a koeficienty diferenční rovnice jsou na obr.5.2

```

> present(thz)
This matrix was created by the command ARX on 9/4 2001 at 11:21
Loss fcn: 1.2326e-032 Akaike's FPE: 3.6978e-032 Sampling interval 1
The polynomial coefficients and their standard deviations are

B =

      0      0.5000
      0      0.0000

A =

  1.0000  -0.5000
      0      0.0000

>

```

Obr.5.2 Zobrazení parametrů diferenční rovnice pomocí příkazu **present**

Diferenční rovnice je rovna

$$y(k) = -a_1 y(k-1) + b_0 u(k-1) = 0.5y(k-1) + 0.5u(k-1)$$

Konec příkladu 5.1

Aby bylo možno pro odhadnuté parametry spočítat v prostředí MATLABu např. diskrétní přechodovou funkci nebo použít nalezené polynomy pro syntézu regulátoru, je třeba datovou strukturu-matici **th** transformovat na koeficienty diferenční rovnice nebo polynomy diskrétních přenosů. K tomu jsou připraveny v toolboxu identifikace procedury, které slouží k těmto přepočtům - ke konverzi modelů. Jednou z významných transformačních funkcí je přepočet matice **th** na parametry diferenční rovnice ARX modelu.

Funkce **th2arx**

Transformace matice **th** na parametry diferenční rovnice ARX

Syntaxe funkce

$$[A, B] = \text{th2arx}(\text{th}), \quad (5-3)$$

$$[A, B, dA, dB] = \text{th2arx}(\text{th}). \quad (5-4)$$

kde je **th** matice (datová struktura) označována jako "theta model"
A, B matice, které popisují vícerozměrný ARX model a jejichž struktura je $A = [I \ A_1 \ A_2 \ \dots \ A_{na}]$; $B = [B_0 \ B_1 \ B_2 \ \dots \ B_m]$, **I** jednotková matice
dA, dB matice směrodatných odchylek parametrů diferenční rovnice

Po provedení příkazu vrací tato funkce matice zobecněného vícerozměrového ARX modelu do tvaru diferenční rovnice, která má v maticovém zápisu tvar

$$y(t) + A_1 y(t-1) + \dots + A_{na} y(t-na) = B_0 u(t) + B_1 u(t-1) + \dots + B_{nb} u(t-nb),$$

V dalším popisu výklad omezíme pouze na modely ARX s jedním vstupem a jedním výstupem. Matice **A**, **B** jsou jednořádkové matice $\mathbf{A}=[1 \ a_1 \ a_2 \ \dots \ a_n]$; $\mathbf{B}=[b_0 \ b_1 \ \dots \ b_m]$. Aplikace z příkazového řádku bude demonstrována na následujícím příkladě.

Př.5.2 Uvažujme matici **thz** z Př.5.1. Ukažme použití příkazu **th2arx** a příkazu **dstep**.

```

> [A,B]=th2arx(thz)

A =

    1.0000    -0.5000

B =


     0     0.5000

> hd=dstep(B,A)

hd =

     0
    0.5000
    0.7500
    0.8750
    0.9375
    0.9688
    0.9844
    0.9922
    0.9961
    0.9980
    0.9990
    0.9995
    0.9998

> dstep(B,A)
    
```



Obr.5.4 Diskrétní přechodová funkce k Př.5.2

Pořadnice diskrétní přechodové funkce jsou na obr.5.3 a její průběh je zobrazen na obr.5.4.

Obr.5.3 Příkazy **th2arx,dstep**

Konec příkladu. 5.2

Funkce th2tf

Transformace matice **th** na koeficienty polynomů diskrétních přenosů

Syntaxe funkce

$$[\text{num}, \text{den}] = \text{th2tf}(\text{th}), \quad (5-5)$$

kde je **th** datová struktura označována jako "theta model"
num, den koeficienty maticových polynomů čitatele a jmenovatele diskrétního obrazového přenosu.

Pro systémy s jedním vstupem a jedním výstupem jsou pak v maticích **num**, **den** uloženy přímo koeficienty polynomu čitatele a jmenovatele. Chceme-li diskrétní obrazový přenos přímo vytvořit, pak použijeme funkci

$$s = \text{tf}(\mathbf{B}, \mathbf{A}, T_s, \text{'variable'}, 'z^{-1}'), \quad (5-6)$$

kde jsou

s	jméno,
B, A	polynomy obrazového přenosu v čitateli a jmenovateli,
Ts	perioda vzorkování,
'variable'	parametr,
'z⁻¹'	typ proměnné.

Použití této funkce včetně výpočtu obrazového přenosu ukážeme na následujícím příkladě.

Příklad 5.3

```

> [BN,AD]=th2tf(thz)

BN =

      0      0.5000

AD =

  1.0000  -0.5000

> tfd=tf(BN,AD,1,'variable','z^-1')

Transfer function:
  0.5 z^-1
-----
 1 - 0.5 z^-1

Sampling time: 1

```

Konec příkladu 5.3

Obr.5.5 Výpočet polynomů BN, AD a diskrétního přenosu

V prostředí MATLABu je zaveden zobecněný popis diskrétního systému, který si stručně popíšeme včetně transformace matice **th** na polynomy tohoto přenosu.

Funkce **th2poly**

Transformace matice th na matice koeficientů polynomů zobecněného diskrétního modelu

Syntaxe funkce

$$[\mathbf{A}, \mathbf{B}, \mathbf{C}, \mathbf{D}, \mathbf{F}, \mathbf{LAM}, \mathbf{T}] = \text{th2poly}(\text{th}). \quad (5-7)$$

Po provedení příkazu jsou uloženy na maticích **A, B, C, D, F** koeficienty polynomů zobecněného diskrétního vícerozměrového modelu, který má v maticovém zápisu tvar

$$A(q)y(t) = \frac{B_1(q)}{F_1(q)} u_1(t - nk_1) + \frac{B_2(q)}{F_2(q)} u_2(t - nk_2) + \dots + \frac{B_{nu}(q)}{F_{nu}(q)} u_{nu}(t - nk_{nu}) + \frac{C(q)}{D(q)} e(t),$$

Matice **A**, **B**, **C**, **D** a **F** obsahují koeficienty polynomiálních matic.
Matice **LAM** je kovariační matice vektoru šumu $e(t)$, T je perioda vzorkování.

V další části výkladu se omezíme pouze na modely ARX a ARMAX s jedním vstupem a jedním výstupem. Matice **A**, **B**, **C** jsou pak jednořádkové matice: $A = [1 \ a_1 \ a_2 \ \dots \ a_{na}]$; $B = [b_0 \ b_1 \ \dots \ b_m]$, $C = [1 \ c_1 \ \dots \ c_{nc}]$. Matici **LAM** i periodu vzorkování můžeme nechat prázdnou. Použití tohoto příkazu ukážeme na jednoduchém příkladě. Tuto funkci je zřejmě možno také použít pro modely ARMAX i BJ.

Př.5.4 Použití příkazu **th2poly** na matici **thz** z Př.5.1

Př.5.5 Nalezněte parametry ARX modelu z měření dle obr.5.5. Měřená data jsou v matici **z**.

```

» [A,B,T]=th2poly(thz)

A =

    1.0000    -0.5000

B =

         0     0.5000

T =

     1

» g=dstep(B,A)

g =


         0
    0.5000
    0.7500
    0.8750
    0.9375
    0.9688
    0.9844
    0.9922
    0.9961
    0.9980
    0.9990
    0.9995
    0.9998

» dstep(B,A)
»

```

Obr.5.4 Aplikace příkazu "th2poly"

Konec příkladu 5.4



Obr.5.5 Graf měření z Př.5.5

```

» th2=arx(z,[2 2 1]);
» [A2,B2]=th2poly(th2)

A2 =

    1.0000    -0.4298    -0.4459

B2 =


         0     0.2997    -0.0461

» dstep(B2,A2)
»

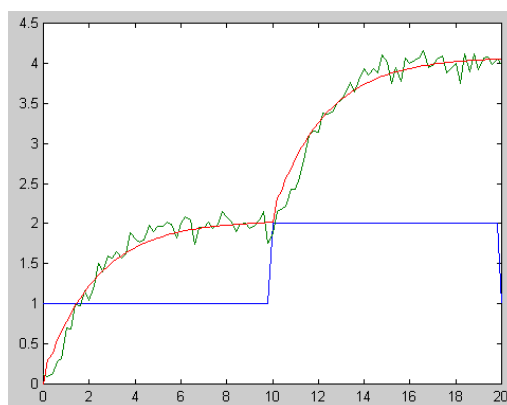
```

Obr.5.6 Identifikace modelu ARX z měření

Diskrétní přechodová funkce získaného modelu je na obr.5.7. Porovnání výstupu modelu a měření je na obr.5.8. Informace o směrodatných odchylkách odhadů parametrů diferenční rovnice je na obr.5.9. Připomeňme, že se zvolil model druhého řádu $na = 2$, počet koeficientů čitatele $nb = 2$ a diskrétní dopravní zpoždění $nk = 1$.



Obr.5.7 Přechodová funkce



Obr.5.8 Porovnání výstupu modelu a měření

```

» present(th2)
This matrix was created by the command ARX on 9/5 2001 at 11:32
Loss fcn: 0.013694 Akaike`s FPE: 0.014823 Sampling interval 1
The polynomial coefficients and their standard deviations are

B =
      0      0.2997     -0.0461
      0      0.1177      0.1228

A =
  1.0000     -0.4298     -0.4459
      0      0.0873      0.0812
    
```

Obr.5.9 Koeficienty diferenční rovnice ARX modelu a jejich směrodatné odchylky

Konec příkladu 5.5

Funkce th2ss

Transformace matice **th** na matice diskrétního stavového popisu

Syntaxe funkce

$$[A, B, C, D, K, X0] = th2ss(th), \quad (5 - 8)$$

kde je **th** datová struktura označována jako "theta model"
A, B, C, D, K matice diskrétního stavového popisu.
X0 vektor počátečních podmínek

Stavový popis je uvažován ve tvaru

$$x(t + 1) = Ax(t) + Bu(t) + Ke(t); x(0) = X0 ,$$

$$y(t) = Cx(t) + Dx(t) + e(t) .$$

Př.5.6

Transformace modelu v Z-přenosu na stavový model bude ukázána na Př.5.5. (Je třeba si uvědomit, že není možno volit Frobeniovy normální formy.)

```

> [AS,BS,CS,DS,KS,XS]=th2ss(th2)
AS =
    0.4298    1.0000
    0.4459         0
BS =
    0.2997
   -0.0461
CS =
     1         0
DS =
     0
KS =
    0.4298
    0.4459
XS =
     0
     0
    
```

Stavová rovnice má tvar

$$\begin{bmatrix} x_1(k+1) \\ x_2(k+1) \end{bmatrix} = \begin{bmatrix} 0.4298; 1.000 \\ 0.4459; 0 \end{bmatrix} \begin{bmatrix} x_1(k) \\ x_2(k) \end{bmatrix} + \begin{bmatrix} +0.2997 \\ -0.0461 \end{bmatrix} u(k) + \begin{bmatrix} 0.4298 \\ 0.4459 \end{bmatrix} e(k).$$

Výstup soustavy

$$y(k) = x_1(k); D = 0;$$

Počáteční vektor stavu

$$x(0) = \begin{bmatrix} x_1(0) \\ x_2(0) \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix};$$

Konec příkladu 5.6

Obr.5.10 Matice stavového popisu

Funkce compare

Porovná výstup modelu s měřením.

Syntaxe funkce

$$\text{compare}(z, th)$$

(5 – 9)

kde jsou **z** matice výstupních - vstupních dat, **z=[y u]**
th matice "theta model"

Použití tohoto příkazu je ukázáno v Př.5.8.

Funkce **armax**

Odhad parametrů ARMAX modelu

Diferenční rovnici ARMAX modelu v prostředí MATLABu vyjádříme:

$$A(q)y(t) = B(q)u(t - nk) + C(q)e(t),$$

kde je	$y(t)$	diskrétní výstupní veličina a $t = k$ je diskrétní čas,
	$u(t - nk)$	diskrétní vstupní veličina,
	nk	kladné celé číslo charakterizující diskrétní dopravní zpoždění jako celočíselný násobek periody vzorkování
	$e(t)$	diskrétní šumový signál,
	$A(q)$	polynom stupně $\partial A = na$, $q = z^{-1}$, $A(q) = 1 + a_1q^1 + \dots + a_naq^{na}$,
	$B(q)$	polynom stupně $\partial B = m = nb - 1$; $B(q) = b_0 + b_1q^1 + \dots + b_mq^m$,
	$C(q)$	polynom stupně $\partial C = nc$, $q = z^{-1}$, $C(q) = 1 + c_1q^1 + \dots + c_nqc^{nc}$,

Příkaz pro výpočet parametrů ARMAX modelu

$$\mathbf{th} = \mathbf{armax}(\mathbf{z}, \mathbf{nn}), \quad (5 - 10)$$

kde je	th	datová struktura - matice obsahující ve 3. řádku vektor parametrů
	z = [y u];	matice výstupních - vstupních dat, y, u sloupcové vektory
	nn	jednořádková matice se třemi sloupci, nn = [na nb nc nk]

```

>> thr=armax(z,[2 2 2 1]);
>> thr=sett(thr,0.2);
>> present(thr)
This matrix was created by the command ARMAX on 9/5 2001 at 14:37
Loss fcn: 0.0089211 Akaike`s FPE: 0.010048 Sampling interval 0.2
The polynomial coefficients and their standard deviations are

B =
      0      0.0470      0.0242
      0      0.0252      0.0376

A =
  1.0000  -1.6127      0.6483
      0      0.0623      0.0558

C =
  1.0000  -1.6779      0.6880
      0      0.0926      0.0916

>> |

```

Obr.5.11 Výpočet koeficientů ARMAX modelu z příkazového řádku

Př.5.7

Vypočtete parametry ARMAX modelu ze souboru měření Př.5.6.

- a) Zvolte soustavu 2. řádu. Jednořádkovou matici **nn** tvoří prvky **nn** = [2 2 2 1]
 b) Spočtete a nakreslete diskrétní přechodové funkce y/u a y/e

Řešení:

- a) Výpočet koeficientů, příkaz **sett** a **present** zadané z příkazového řádku jsou na obr.5.11.
 b) Transformace matice **thr** na polynomy Ad , Bd , Cd , Dd , Fd a příkazy **dstep** pro výpočet diskrétních přechodových funkcí jsou na obr.5.12. Přechodové funkce jsou na obr.5.13,14.

```

» [Ad,Bd,Cd,Dd,Fd,Lan]=th2poly(thr)

Ad =
    1.0000   -1.6127    0.6483

Bd =
         0    0.0470    0.0242



Cd =
    1.0000   -1.6779    0.6880

Dd =
     1

Fd =
     1

Lan =
    0.0089

» dstep(Bd,Ad)
» dstep(Cd,Ad)
.. |
  
```

Obr.5.12 Výpočet polynomů A,B,C Obr.5.13 Diskrétní přechodová funkce y/u Obr.5.14 Diskrétní přechodová funkce y/e

*Poznámka: Jak již bylo řečeno, příkaz **th2poly** může být zapsán zkráceně*

[Ad, Bd, Cd] = th2poly(thr).

Konec příkladu 5.7

Pro posouzení vlastností odhadů je významná chyba rovnice dle (3 – 8). Tuto chybu učíme pomocí funkce **resid**.

Funkce **resid**

Vypočte a testuje chybu modelu.

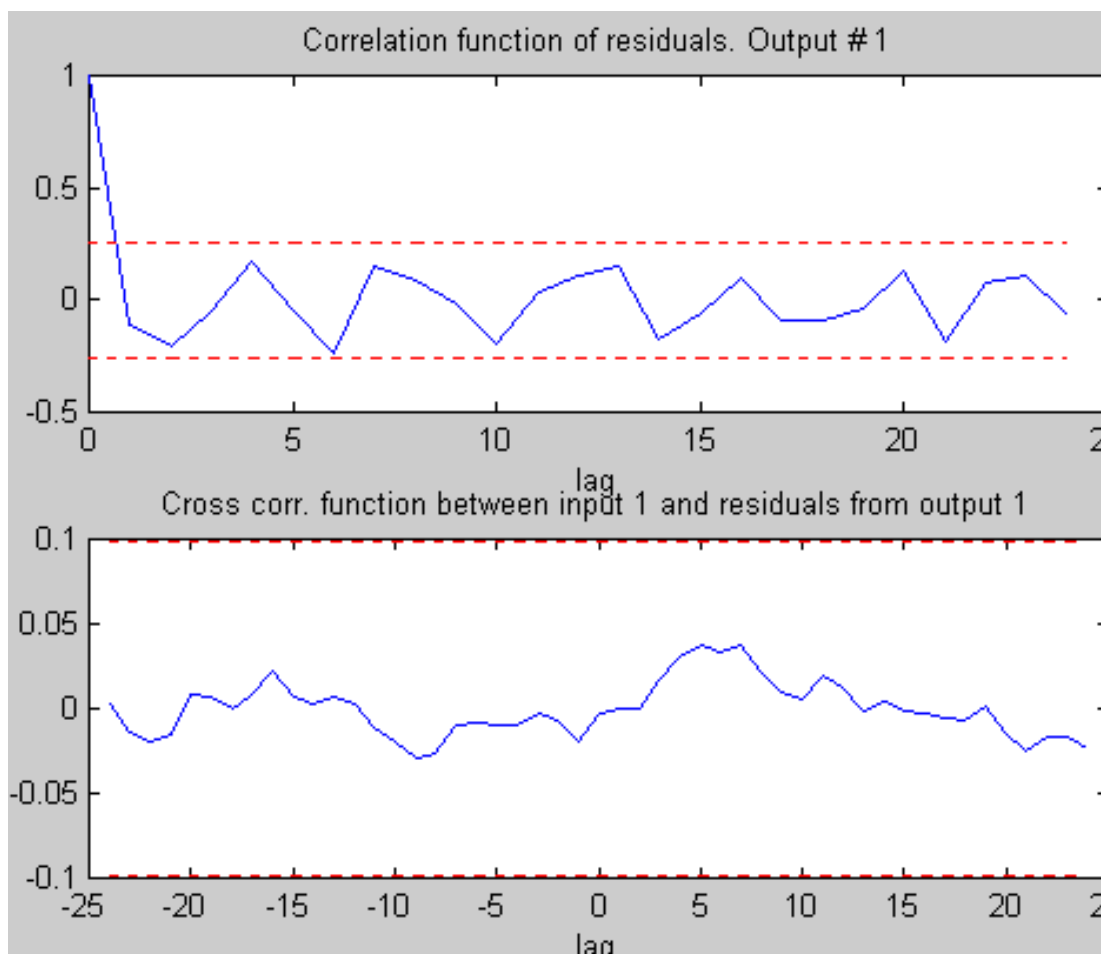
Syntaxe funkce

$$[e,r] = \text{resid}(z,th), \quad (5-11)$$

kde je **z** = [**y** **u**]; matice výstupních - vstupních dat, **y**, **u** sloupcové vektory
th matice (theta model)
e vektor chyb predikce
r korelační funkce

Př.5.8

Na datech z Př.5.6 ověřte příkazy **resid** a **compare**. Zadané funkce z příkazového řádku jsou na obr.5.16. Průběh autokovariační funkce chyby a vzájemné kovariační funkce vstupu a chyb odhadu je na obr.5.15. Výsledkem činnosti funkce **compare** je graf výstupu z modelu a změřeného výstupu soustavy viz obr.5.17.



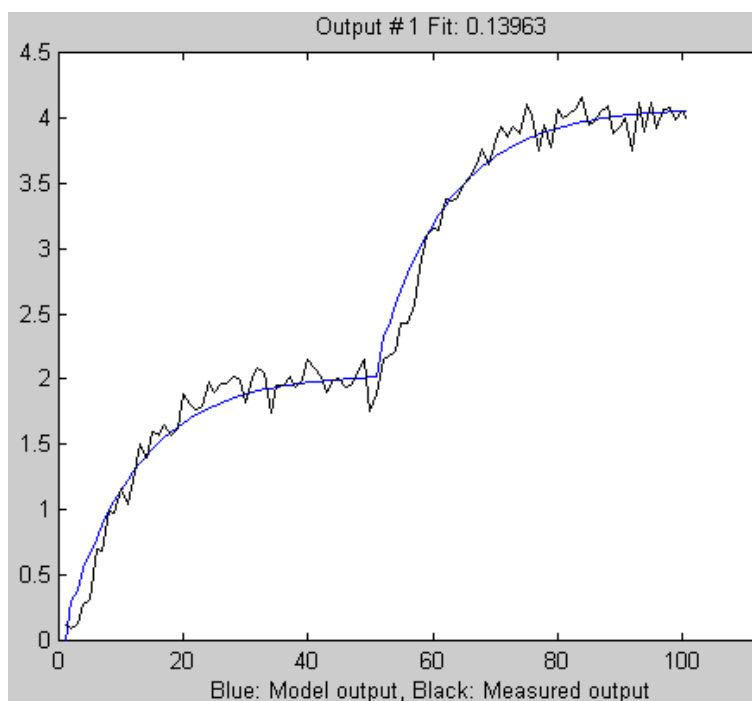
Obr.5.15 Autokovariační funkce r_e a vzájemná kovariační funkce r_{eu}

```

>
> [e,r]=resid(z,th);
> compare(z,th);
> |

```

Obr.5.16 Příkazy



Konec příkladu 5.8

Obr.5.17 Porovnání měřeného výstupu soustavy a modelu

7 LITERATURA

- [1] NOSKIEVIČ, P.: Modelování a identifikace systémů, MONTANEX a.s., 1999.
- [2] SOUKUP, J.: Identifikace soustav, Skripta ČVUT, Praha 1998.
- [3] HANUŠ, B., OLEHLA, M., MODRLÁK, O.: Číslicová regulace technologických procesů. VUT Brno, VUTIUM 2000.
- [5] DRÁBEK, O., MACHÁČEK, J.: Experimentální identifikace, Skripta VŠCHT Pardubice 1987.
- [6] LJUNG, L.: System Identification. *Theory for the User*. Prentice - Hall, Inc. Upper Saddle River, New Jersey, 1999.
- [7] FRANKLIN, F. G., POWEL, J. D., WORKMAN, L. M.: Digital Control of Dynamic Systems. Addison Wesley Longman, Inc. Third edition, 2003.