

Možnosti filtrace výstupného signálu snímačov koncentrácie

ANNA VASIČKANINOVÁ - ANNA ZEMANOVIČOVÁ

SÚHRN. Pomocou tepelnovodivostného analyzátoru, ktorý je súčasťou zariadenia, skonštruovaného na Katedre automatizácie [9], boli namerané hodnoty koncentrácie CO₂, ktoré bolo treba po pripojení na počítač filtrovať. Boli použité filtre rôznych typov (číslicové, filter s viaenásobným vzorkovaním, empirický, štatistické filtre). Z použitých filtrov najmenej skresľoval dynamiku signálu empirický filter.

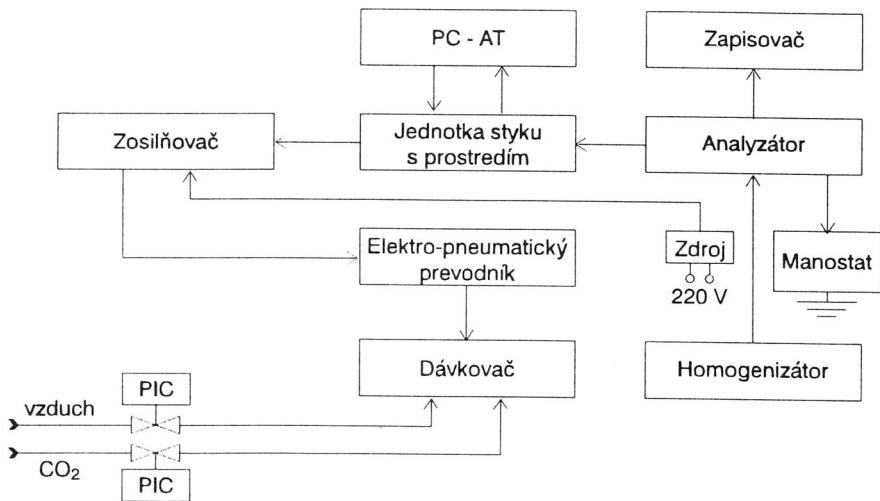
Na meranie procesných parametrov v potravinárskom priemysle sa používajú rôzne snímače, napr. pH-metre, merače vodivosti, hustomery, analyzátoru CO₂, SO₂, O₂, N₂, organických plynov a pod. [8].

Namerané údaje sa spracúvajú na počítači, je teda potrebné použiť A/D prevodník. Použité zariadenia ako samotné snímače, prevodníky, atď sú však aj zdrojom chýb. Je preto vhodné filtrovať vstupy a výstupy reálnych procesov. Filter obvykle vyrovnáva merané údaje, alebo upravuje amplitúdy rôznych frekvencií meraného signálu, prípadne úplne potláča amplitúdy zvolených frekvencií, vylučuje napr. vysokofrekvenčný šum.

Experimentálna časť

Na obr.1 je znázornená schéma reálneho regulačného obvodu na riadenie koncentrácie plynných zmesí. Tento obvod slúži na meranie a riadenie koncentrácie CO₂ vo vzduchu. Vzduch sa do sústavy privádzza z kompresora (miestny laboratórny rozvod). Zdrojom CO₂ je tlaková bomba. Používa sa potravinársky CO₂, dodávaný vo vysokotlakových fľašiach. Aby celý systém pracoval správne, je potrebné stabilizovať tlaky plynov, vstupujúcich do sústavy. Plyny sa privádzajú do zmiešavacej nádrže, kde nastáva homogenizácia tejto plynnej zmesi. Na snímanie koncentrácie CO₂ v nej sa používa analyzátor

Ing. Anna Vasičkaninová, Ing. Anna Zemanovičová, CSc., Katedra automatizácie, Chemickotechnologická fakulta STU, Radlinského 9, 812 37 Bratislava.



Obr. 1. Schéma obvodu merania a riadenia koncentrácie CO₂.
Fig. 1. The measurement and control of CO₂ concentration scheme.

pracujúci na princípe merania tepelnej vodivosti plynnej zmesi. Sústava je riadená počítačom. Pritom je potrebné sústavu identifikovať. Odhad parametrov sústavy sa robí z nameranej prechodovej charakteristiky a práve tieto namerané hodnoty je potrebné filtrovať.

Je možné použiť číslicové filtre. Rekurzívny číslicový systém je opísaný rovnicou

$$y(n) = \sum_{k=0}^M a_k x(n-k) - \sum_{k=1}^N b_k y(n-k) \quad (1)$$

resp. diskrétnym prenosom

$$H(z) = \frac{Y(z)}{X(z)} = \frac{\sum_{k=0}^M a_k z^{-k}}{1 + \sum_{k=1}^N b_k z^{-k}} \quad (2)$$

kde z je operátor Z-transformácie, podľa ktorej je Z obraz reálnej postupnosti $\{h_k\}_{k=0}^{\infty}$ súčtom formálneho mocninového radu:

$$H(z) = \sum_{k=0}^{\infty} h_k z^{-k} \quad (3)$$

(teda z - operátor dopredného posunu, z^{-1} - operátor spätného posunu)

Takýto číslicový filter sa implementuje hard-, alebo softwarovo. Realizácia analógových filtrov predstavuje zmenu prístrojového vybavenia, čo je ľahšie, než iba zmena programu v počítači.

Pri tom sa snažíme, aby filter bol čo najekonomickejší, teda aby prenosová funkcia bola čo najnižšieho stupňa.

Výstupný signál filtru jeme napr. najjednoduchším rekurzívnym číslicovým filtrom [7] (Tabuľka 1.: f_1, f_2)

$$y(k) = K_1 y(k-1) + (1 - K_1) x(k) \quad (4)$$

Podobný číslicový filter uvádzajú autori [6] v tvare :

$$y(k) = \frac{x(k) + K_2 y(k-1)}{1 + K_2} \quad (5)$$

(Tabuľka 1.: f_3, f_4), kde $x(k)$ je meraná hodnota, $y(k)$ je filtrovaná hodnota, K_1, K_2 sú konštance filtrov.

Z mnohých meraní na vyššie opísanom riadiacom obvode vyplýva, že koncentračná sústava je prvého rádu s dopravným oneskorením. Prenosová funkcia takejto sústavy je

$$F(p) = \frac{K}{T_p + 1} e^{-dp} \quad (6)$$

kde K je zosilnenie, T je časová konštantă, d je dopravné oneskorenie.

Ak $R = e^{-\frac{T_{VZ}}{T}}$, kde T_{VZ} je perióda vzorkovania, rovnica filtra prvého rádu je zhodná s rovnicou (4), ale $K_1 = R.K$, resp v rôvnici (5) $K_2 = R.K/(1 - R.K)$.

V závislosti od zmeny žiadanej hodnoty sa mení aj dynamika procesu, teda zosilnenie a časová konštantă sústavy nie sú v priebehu celého merania konštantné a meniť sa môže aj perióda vzorkovania.

Bol skúmaný priebeh filtrovaných hodnôt koncentrácie CO₂ s rôznymi konštantami K_1, K_2 z intervalu <0, 1>, ale ich výber neboli optimálne. V ďalšom bude potrebné volbu konštant K_1, K_2 a štruktúru diskrétneho prenosu optimalizovať pomocou frekvenčnej analýzy.

Zlepšenie môžeme dosiahnuť použitím viacnásobného vzorkovania [2]. Meranú veličinu vzorkujeme viackrát počas periódy vzorkovania. Z takto nameraných hodnôt sa najčastejšie urobí aritmetický priemer, ale to nebýva optimálne. Lepšie vyhovuje lineárna approximácia spojitého priebehu výstupu sústavy v každej perióde vzorkovania. Odhad výstupu sústavy v časovom okamihu t_e je

$$y_e = c_1 \sum_{i=1}^{\tau} t_i x_i + c_2 \sum_{i=1}^{\tau} x_i \quad (7)$$

x_1, x_2, \dots, x_τ sú hodnoty, namerané v priebehu períody, c_1, c_2 nezávisia od nameraných údajov, ale iba od časového rozloženia t_1, t_2, \dots, t_τ .

V praxi býva bežným prípadom, že vzorky sú snímané v pravidelných časových intervaloch

$$t_i - t_{i-1} = \text{konst.} \quad (8)$$

a časový okamih, v ktorom požadujeme odhad výstupu sústavy, sa rovná okamihu namerania poslednej vzorky t.j.

$$t_e = t_\tau$$

Spojity časový interval môžeme v rámci períody T merať od ľubovoľného pevného bodu a v ľubovoľných jednotkách, preto si výhodne zvolíme

$$t_i = i \text{ pre } i=1, 2, \dots, \tau$$

Pre c_1, c_2 dostaneme

$$c_1 = \frac{6}{\tau(\tau + 1)} \quad (9)$$

$$c_2 = -\frac{2}{\tau} \quad (10)$$

a výsledný vzťah je

$$y_e = c_1 \sum_{i=1}^{\tau} i x_i + c_2 \sum_{i=1}^{\tau} x_i \quad (11)$$

Aj keď v [2] sa odporúča volba τ 10 až 50, v našom prípade bola potrebná volba $\tau = 100$, aby sa dosiahli dobré výsledky (Tabuľka 1.: f5).

Využitím fyzikálnej podstaty procesu môžeme získať jednoduchý empirický filter ktorý je však orientovaný len na daný konkrétny systém (Tabuľka 1.: f6).

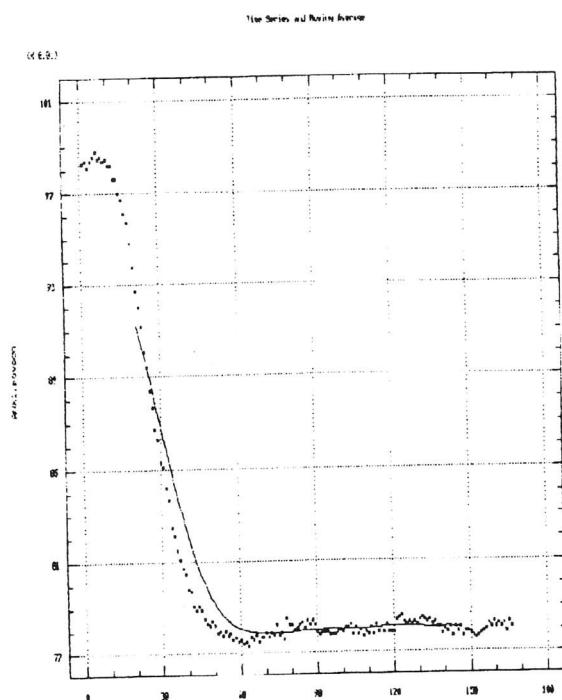
V našom prípade napr. pozorovaním signálu, zosnímaného z A/D prevodníka bolo zistené, že rozdiel dvoch za sebou nasledujúcich hodnôt by nemal byť väčší ako 2. V opačnom prípade ide o nejakú poruchu v prevodníku. Preto sa údaje filtrovali tak, že sa urobil podľa poradia rozdiel dvoch hodnôt a ak bol v absolútnej hodnote väčší ako 2, vylúčila sa odľahlá hodnota a vždy z 5 hodnôt sa vypočítal aritmetický priemer [1].

Ak chceme získať vyhľadený graf nameraných hodnôt, sú vhodné štatistické filtre, založené na metódach, ktoré sa používajú pri vyrovnaní časových radov [3,4,5]. Najjednoduchšie je mechanické vyrovnanie časového radu metódou kľzavých priemerov. Najprv zistíme kľzavé súčty. Sú to postupne vytvárané súčty hodnôt časového radu za počet období r .

$$1. \text{ kĺzavý súčet: } \sum_{t=1}^r y_t \quad (12)$$

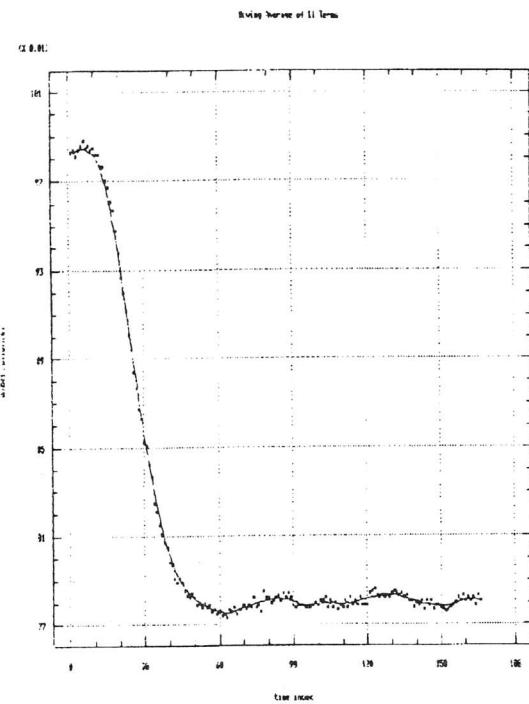
$$2. \text{ kĺzavý súčet: } \sum_{t=2}^{r+1} y_t \quad \text{atd.} \quad (13)$$

Ak jednotlivé kĺzavé súčty delíme počtom období r , súčtom ktorých vznikli, dostaneme kĺzavé priemery a priradujeme ich k prostrednému z období za ktoré boli vypočítané. Ak je počet páry, priemery centrujeme. Nevýhodou je, že pri počte hodnôt $r=2m+1$, z ktorých kĺzavé priemery počítame, strácamo m hodnôt na začiatku a m hodnôt na konci celého radu hodnôt, ako to vidno z obr.2, na ktorom sú znázornené pôvodné hodnoty a hodnoty, vyrovnané pomocou jednoduchých kĺzavých priemerov, kde dĺžka kĺzavých priemerov $r = 41$, teda $m = 20$. Aby sme nestratili $2m$ hodnôt z celkového počtu hodnôt, môžeme m prvých a m posledných hodnôt dopočítať lineárhou interpoláciou, ako je to na obr.3 a obr.4. Sú na nich priebehy pôvodných a vyrovnaných hodnôt, pričom na obr.3 je $m = 5$ (Tabuľka 1.: f₇) a na obr.4 $m = 20$ (Tabuľka 1.: f₈). Z obrázkov vidíme, že m je potrebné voliť tak, aby nebolo príliš malé, lebo vtedy je graf málo vyhladený, a ak je väčšie, graf nesleduje dynamiku procesu. Na vyhladenie grafu možno použiť aj iné štatistické postupy, napr.



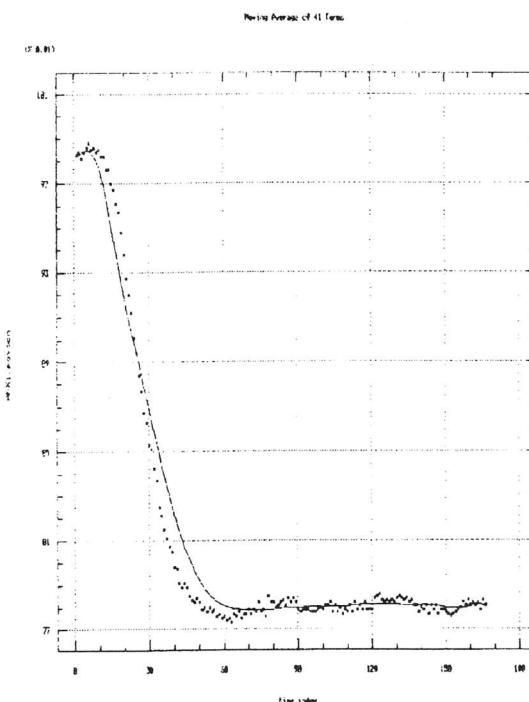
Obr.2. Namerané nefiltrované hodnoty a hodnoty vyhladené pomocou jednoduchých kĺzavých priemerov ($m = 20$).

Fig. 2. Time dependence for unfiltered measured signals and smoothing with simple moving averages ($m = 20$).



Obr.3. Namerané nefiltrované hodnoty a hodnoty vyhladené pomocou jednoduchých klzavých priemerov s lineárnom aproximáciou prvých a posledných hodnôt ($m = 5$).

Fig.3. Time dependence for unfilters mesured signals and smoothing with simple moving averages and linear aproxiimation first and final signals ($m = 5$).



Obr.4. Namerané nefiltrované hodnoty a hodnoty vyhladené pomocou jednoduchých klzavých priemerov s lineárnom aproximáciou prvých a posledných hodnôt ($m = 20$).

Fig.4. Time dependence for unfilters mesured signals and smoothing with simple moving averages and linear aproximation first and final signals ($m = 20$).

využiť vážené kĺzavé priemery, mediány, rôzne kombinácie týchto vyhľadení a pod., pre nás však ich aplikácia neprinesla požadovaný efekt.

V tabuľke 1. sú koeficienty poradovej korelácie pre hodnoty pôvodné a filtrované, kde:

- f₁ - číslicový filter (4), K₁ = 0,1
- f₂ - číslicový filter (4), K₁ = 0,05
- f₃ - číslicový filter (5), K₂ = 0,01
- f₄ - číslicový filter (5), K₂ = 0,05
- f₅ - filter s viacnásobným vzorkovaním
- f₆ - empirický filter
- f₇ - štatistický filter, m = 5
- f₈ - štatistický filter, m = 20

Najlepšia zhoda pôvodných a filtrovaných údajov je v prípade, ak sa korelačný koeficient blíži k hodnote 1.

Ta b u l k a 1. Koeficienty poradovej korelácie pôvodných
a filtrovaných hodnôt pre rôzne typy filtrov.

Table 1. Rank correlation coefficients original and filtering data for various filters.

FILTER ¹	KORELAČNÝ KOEFICIENT ²
f ₁	0,8512
f ₂	0,8646
f ₃	0,8658
f ₄	0,8732
f ₅	0,9127
f ₆	0,9910
f ₇	0,9218
f ₈	0,7280

1 - filter, 2 - correlation coefficient.

Záver

Najvhodnejší filter, ako to vyplýva aj z tabuľky, z porovnania korelačných koeficientov, je filter empirický, ktorý vychádza z fyzikálnej podstaty a poznatkov o procese, ale platí len pre konkrétny proces. Dobré výsledky sa dajú dosiahnuť aj so štatistickými filtrami, ktoré vyhľadia graf nameraných signálov pomocou jednoduchých kĺzavých priemerov, ale je potrebné vhodne zvoliť počet hodnôt, z ktorých sa kĺzavé priemery počítajú. Ak je počet privelký, graf

je vyhľadený, ale nesleduje dynamiku procesu, v opačnom prípade je zachovaná dynamika, ale graf je vyhľadený menej. Aplikácia ďalších postupov, napr. vážených klzavých prieberov, mediánov, rôznych kombinácií týchto postupov, nepriniesla významné zlepšenie filtrovaných hodnôt. Využitím viačnásobného vzorkovania sa dosiahli tiež postačujúce výsledky. V prípade filtrov číslicových bude potrebné pomocou frekvenčnej analýzy optimalizovať volbu konštánt, aj štruktúru filtrov.

Literatúra

1. IVANICKÝ, M.: Diplomová práca, Bratislava, CHTF STU 1992.
2. HEBKÝ, Z.: Automatizace, 1984, č.6, s.142-145.
3. KOSCHIN, F. a kolektív: STATGRAPHICS aneb statistika pro každého. GRADA a.s., 1992.
4. KANDEROVÁ, M. - ÚRADNÍČEK, V.: Teória štatistiky, Praktikum, Bratislava, VŠE 1991.
5. DROZDOVÁ, M.: Teória lineárnych obvodov, Alfa, Bratislava, 1990.
6. MURGAŠ, J. - HEJDA, I.: Adaptívne riadenie technologických procesov, Bratislava, STU 1993.
7. DRÁBEK, O. - MACHÁČEK, J.: Adaptivní řízení, Pardubice, VŠCHT 1992.
8. ZEMANOVIČOVÁ, A. - BAKOŠOVÁ, M. - KARŠAIOVÁ, M. - ZEMANOVIČ, J.: Niektoré aspekty merania a regulácie pH v bioreaktoroch. Bulletin PV, 31(11), 1992, č.2, s.167-173.
9. ZEMANOVIČOVÁ, A.: Patent Automatický dávkovač dvojzložkovej plynnnej zmesi AO 205892, 1980.

Do redakcie došlo 28.8.1995.

Possibilities of filtration of concentration sensors output signals

ANNA VASIČKANINOVÁ - ANNA ZEMANOVIČOVÁ

SUMMARY. The contribution deals with filtration of data from CO₂ analyzer. Several types of filter principles were used (digital, digital with multisampling, empirical, statistical). The best results were obtained by the developed empirical filter algorithm. By using of the developed filter dynamic distortion of the data was very slight.