

Csaba Stupák - Rastislav Lukáč - Stanislav Marchevský *

PROCESOR PRE POTLÁČANIE IMPULZOVÉHO ŠUMU V TELEKOMUNIKAČNÝCH KANÁLOCH

PROCESSOR FOR IMPULSIVE NOISE SUPPRESSION IN TELECOMMUNICATION CHANNELS

V ostatnom čase bolo mnoho lineárnych filtrov nahradených nelineárnymi filterami, obzvlášť v prípade poškodenia signálu impulzovým šumom. Trieda kompozičných filtrov, ktorá patrí medzi nelineárne filtre, je zaujímavá kvôli ľahkej hardvérovej realizácii a vlastnosti nakladania. Rozvoj digitálnej HDTV podporil technologický vývoj v tejto oblasti. V mnohých aplikáciách je vhodné použitie veľmi účinných poriadkovo-štatistických filtrov, napr. mediánového alebo vyhľadovacieho LUM filtra. Tieto filtre môžu byť realizované ako kompozičné filtre, ktorými sa zaoberáme v tomto krátkom prehľade.

1. Úvod

Väčšina súčasných komunikačných systémov, systémov riadenia a systémov pre spracovanie signálov, je vyvíjaných so zreteľom na odolnosť voči Gaussovmu šumu [2]. Avšak mnohé prostredia sú vhodnejšie modelované ako impulzové, nie gaussové distribúcie [16-18]. V praxi impulzový šum pochádza z atmosférického rušenia, napr. atmosférické výboje, vyžarovanie v rádiokomunikáciách a šum spínacích relé v telefónnych kanáloch. Okrem týchto prirodzených negaussovských zdrojov, existuje aj veľké množstvo umelých zdrojov ako automatické vzplanutie, neónové svetlá a iné elektronické zariadenia.

Impulzový šum je vysoko závislý od fyzikálneho prostredia a môže sa relatívne zriedkavo vyskytovať vzhľadom na nestacionaritu a nevhodný štatistický popis.

Nie Gaussova podstata predurčuje na potlačenie impulzového šumu nelineárne filtre s vlastnosťou robustnosti. Pre tieto vlastnosti sa široko používajú kompozičné filtre.

Zvyšok tohto článku je organizovaný nasledovne. V prvej časti sú popísané modely impulzového šumu. Základné vlastnosti procesora sú načrtnuté v druhej časti. V ďalších častiach je opísaná dvojrozmerná mediánová filtrácia, vyhľadovacie LUM filtre, podstata kompozičných filtrov a neurónové kompozičné filtre. V závere sú zhrnuté základné myšlienky.

In recent years, many linear filters have been replaced by non-linear filters, especially in case of impulse noise distorting. Stack filters, the class of non-linear filters are very interesting for easy hardware realisation and threshold decomposition property. The development of digital HDTV gives technological push in this area. Various of very efficient order-statistics filters such as median or LUM smoother are useful in many applications. In addition, these filters can be realised as stack filters. This paper gives a short review of the stack filter class.

1. Introduction

The majority of the present systems in communication, control and signal processing are developed under the assumption that the interfering noise is Gaussian [2]. However, many physical environments are more accurately modelled as impulsive non-Gaussian distributions [16-18]. In practice, sources of impulse noise include atmospheric noise, such as lightning spikes and spurious radio emission in radio communication, and relay switching noise in telephone channels. In addition to these natural non-Gaussian noise sources, there is a great variety of man-made sources such as automatic ignition, neon lights, and other electronic devices.

Impulse noise is highly dependent on the physical environment and may be relatively infrequently occurring and non-stationary, which often renders it impossible to obtain an accurate statistical description. The non-Gaussian nature of impulse noise dictates that the suppression filter should be non-linear, and due to the presence of impulses, it must be robust. For these properties, the stack filters are widely used.

The paper is organized as follows. In the first section, impulsive noise types are described. The second section outlines the basic principle of the processor. The following sections describe the two-dimensional median filtering, LUM smoothers, fundamentals of stack filters and neural stack filters. Conclusions are drawn in the last section.

* Csaba Stupák, Rastislav Lukáč, Stanislav Marchevský

Technical University of Košice, Faculty of Electronics and Informatics, Department of Electronics and Multimedia Communications,
Park Komenského 13, SK-04120 Košice, Slovak Republic, Tel.: +42-95-6333458, 6024108, Fax.: +42-95-633 0115,
E-mail: stupak@tuke.sk, lukacr@tuke.sk, marchs@tuke.sk

2. Šumové modely

Rozoznávame dva druhy impulzového šumu. V prípade 8 bitového kvantovania impulzový šum s premenlivou hodnotou, jednoducho nazvaný impulzový šum, znehodnotí vzorku signálu náhodnou hodnotou s rovnomerným rozložením z intervalu $\langle 0, 255 \rangle$. Tento proces je možné vyjadriť v tvare

$$y_i = \begin{cases} x_i & 1 - p_{rnd} \\ rnd & p_{rnd} \end{cases} \quad (1)$$

kde y je znehodnotený signál, x je pôvodný nezašumený signál, rnd náhodná hodnota, p_{rnd} je pravdepodobnosť výskytu impulzu a i je pozícia vzorky signálu.

$$y_i = \begin{cases} x_i & 1 - (p_0 + p_{255}) \\ 255 & p_{255} \\ 0 & p_0 \end{cases} \quad (2)$$

Druhým šumovým modelom je impulzový šum s pevnou hodnotou, tzv. čiernobiely šum, ktorý znehodnotí signál mimoležiacimi prvkami. Pravdepodobnosti p_0 a p_{255} sú pravdepodobnosti výskytu impulzov s jasovými úrovňami „0“ a „255“.

3. Procesor

Z modelu impulzového šumu vyplýva, že len niektoré časti signálu budú znehodnotené (zvyčajne do 30 %). Z tohto dôvodu by mali byť spracovávané len znehodnotené prvky, zatiaľ čo zvyšné nezašumené vzorky by mali byť ponechané bez zmeny. Avšak podstatná časť súčasných filtračných postupov spracováva každý signálový prvok a to bez ohľadu, či je tento prvok znehodnotený alebo nie. Spomínaný procesor pozostáva z dvoch častí (obr. 1).

Samotný princíp je jednoduchý [7,8,10-12,14]. V prvej časti detektora sú vyhodnotené vstupné dáta y_i . V prípade detekcie neznehodnoteného prvku, výstup filtra je rovný hodnote spracovávaného prvku. Výkon detektora ovplyvňuje množstvo falošných detekcií. V prípade detekcie znehodnoteného signálového prvku sa tento privádza na vstup estimátora, v ktorom sa koriguje odchýlka od pôvodnej vzorky.

Tento článok je zameraný na nelineárne estimátory. V nasledujúcich častiach budú popísané typy estimátorov patriacich do triedy kompozičných filtrov.

4. Mediánový filter

Mediánový filter je najjednoduchším filtrom patriacim do triedy kompozičných filtrov [1]. Tento filter je často používaný kvôli svojim vlastnostiam ako výborné potlačanie impulzového šumu so súčasným zachovaním hrán. Navyše, tento filter je vysoko robustný.

2. Noise model

Two impulse noise models are usually used. The first one is the variable valued impulse noise, simply called impulse noise, where some of the signal elements are replaced by random value with uniform distribution from interval $\langle 0, 255 \rangle$ in case of 8bit quantized signal. It is defined as follows:

$$y_i = \begin{cases} x_i & 1 - p_{rnd} \\ rnd & p_{rnd} \end{cases} \quad (1)$$

where y is the distorted signal, x is the original, noise-free signal, rnd random value, p_{rnd} probability of impulse occurrence and i is position of the signal elements.

$$y_i = \begin{cases} x_i & 1 - (p_0 + p_{255}) \\ 255 & p_{255} \\ 0 & p_0 \end{cases} \quad (2)$$

The second noise model (2) is the fixed value impulse noise, or so-called salt and pepper noise, which distorts the signal by outlier. The p_0 and p_{255} are the probabilities of “0” and “255” impulses, respectively.

3. The proposed processor


From the impulse noise model is clear that only few elements of the signal, usually up to 30%, are distorted. Therefore, only distorted signal elements should be filtered and the rest, noise-free elements should be left without filtering. However, the majority of present filters process every elements of the signal even the not distorted signal elements, too. The proposed processor consists of two parts (Fig. 1).

Its principle is simple [7,8,10-12,14]. The first part of the processor, the detector, investigates the input data y_i . In the case of noise-free detection, the processed sample is sent to the output without change. The amount of false detection influences the detector performance. In the case of impulse detection, the distorted signal element is sent to the estimator that tries to correct this element.

This paper is focused on non-linear estimators. The following sections describe several type of estimators belong to class of stack filters.

4. Median filter

The simplest filter belonging to the class of stack filter is the median filter [1]. This filter is preferred in application because of its performance. The MF well suppresses impulse noise and maintains image edges at same time. Moreover, it is generally the most robust filter.



Obr. 1 Architektúra procesora
Fig. 1 Architecture of the processor

Princíp filtrácie je nasledovný. Operačné okno (OW) sa pohybuje po signále. Rozmer OW je zvyčajne volený v rozmedzí od troch do sedem. Výstup filtra je určený aplikovaním operátora mediána (4) na dáta z OW. Mediánový operátor zoradí dáta v zostupnom poradí podľa veľkosti. Nech x_1, x_2, \dots, x_n sú dáta z operačného okna, potom zoradené vzorky sú

$$x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}. \quad (3)$$

Značením $x_{(i)}$ sa označuje i -tá poriadková štatistika, a maximálne a minimálne prvky z OW sú určené $x_{(n)}$ and $x_{(0)}$. V prípade spracovania obrazov je veľkosť okna nepárna.

$$\text{med}(x) = \begin{cases} \frac{x_{(\frac{N}{2})} + x_{(\frac{N+1}{2})}}{2} & \text{rozmer je nepárny} \\ x_{(\frac{N+1}{2})} & \text{rozmer je párný} \end{cases} \quad (4)$$

Za hlavný nedostatok mediánového filtra je považované rozmazávanie hrán a odstránenie jemných signálových detailov. Z tohto dôvodu bolo vytvorených niekoľko ďalších filtrov založených na poriadkových štatistikách. Tieto filtre eliminujú túto nevýhodu.

5. Vyhľadovací LUM filter

MF však vo veľkom počte aplikácií vnáša priveľa vyhladzovania, čo v praxi znamená rozmazanie hrán a detailov. Rozmazanie obrazu tak môže predstavovať väčšiu odchýlku od originálneho obrazu, než zašumený obraz. Rovnováhou medzi potlačením šumu a ochranou signálových detailov sa vyznačujú vyhladzovacie LUM filtre (Lower Upper Middle) [13,15]. Vyhľadovací LUM filter sa vyznačuje jednoduchou štruktúrou, pričom úroveň vyhladenia je riadená ladiacim parametrom k na vyhladzovanie. Zmenou ladiaceho parametra sa môžu získať rôzne úrovne vyhladenia od identického filtra (pre $k=1$, kde $y=x$) až po maximálne množstvo vyhladenia vykonané MF ($k = (N + 1)/2$).

Vyhľadovacia funkcia LUM filtra je tvorená porovnaním spracovávanej vzorky x_4 s vyššou a nižšou poriadkovou štatistikou. Ak x_4 patrí do rozsahu vymedzenom týmito vzorkami, nie je menený. V opačnom prípade je nahradený vzorkou ležiacou bližšie k mediánu.

Výstup vyhladzovacieho LUM filtra je definovaný

$$y = \text{med} \{x_{(k)}, x_4, x_{(N-k+1)}\} \quad (5)$$

kde $1 \leq k \leq [N + 1]/2$, $x_{(k)}$ a $x_{(N-k+1)}$ vyššia poriadková štatistika zoradené množiny.

Its principle is following. An operation window (OW) is moved over the signal. Usually, the OW size varies from three up to seven. The data from OW are sent to the median operator (4) that calculates the filter output. The median operator arranges the data of the OW in ascending order of magnitude. Let x_1, x_2, \dots, x_n are the data of the OW, then the arranged data are

$$x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}. \quad (3)$$

The $x_{(i)}$ is called the i -th order statistic, and the maximum and minimum of the OW are denoted by $x_{(n)}$ and $x_{(0)}$, respectively. Usually, in the case of image processing the size of the OW is odd.

$$\text{med}(x) = \begin{cases} \frac{x_{(\frac{N}{2})} + x_{(\frac{N+1}{2})}}{2} & \text{OW size is even} \\ x_{(\frac{N+1}{2})} & \text{OW size is odd} \end{cases} \quad (4)$$

The main drawback of the MF is that it blurs signal edges and removes fine details of the signal. On that account another filters based on order statistic trying to eliminate those disadvantages were developed.

5. LUM smoother


In many applications, the median introduces too much smoothing that in the practice means the blurring of edges and details. The LUM smoother [13,15], a subclass of a lower-upper-middle (LUM) filters, achieves the best balance between noise smoothing and signal-detail preservation. A structure of LUM smoother is based on tuning parameter k for the smoothing. Varying this parameter changes the level of the smoothing from no smoothing (i.e. identity filter for $k=1$, where $y=x$) to the maximum amount of smoothing (i.e. median, $k = (N + 1)/2$).

Thus, the smoothing function is created by a simply comparing of the processed sample to the lower- and upper-order statistics. If x_4 lies in a range formed by these order statistics, it is not modified. If x_4 lies outside this range it is replaced by a sample that lies closer to the median.

The output of LUM smoother is given by

$$y = \text{med} \{x_{(k)}, x_4, x_{(N-k+1)}\} \quad (5)$$

where $1 \leq k \leq [N + 1]/2$, $x_{(k)}$ a $x_{(N-k+1)}$ are lower and upper order statistics of the ordered set.



Obr. 2 LUM filter ako: a) vyhladzovací b) ostriaci c) hybridný filter
Fig. 2 LUM filter: a) smoother b) sharpener c) hybrid filter

Trieda vyhladzovacích LUM filtrov je ekvivalentná so stredne váženými mediánmi (CWM - Center-Weighted Median), ktorých výstup je mediánom modifikovanej množiny mnohonásobnú spracovávanú vzorku. Implementácia CWM podľa (5) požaduje menej operácií, než (6), pretože menej prvkov musí byť triedených.

$$y = \text{med} \left\{ W \cup \underbrace{[x_4, x_4, \dots, x_4]}_{w-1} \right\} \quad (6)$$

V (6) w je váha strednej vzorky, pričom sa uvažuje nepárne kladné celé číslo. Vzájomný vzťah medzi parametrom pri CWM a parametrom k pri LUM filtri je daný

$$w = N - 2k + 2 \quad (7)$$

Proces zoradovania dát je výpočtovo veľmi náročný. V ďalšej časti je popísaný filter ktorý sa vyznačuje rýchlou VLSI implementáciou.

6. Kompozičný filter

Mediánová filtrácia binárnych signálov je relatívne jednoduchá a celkom dobre spracovaná. Výpočet mediána sa dá zjednodušiť na počítanie jednotiek vo vnútri pracovného okna. Ak ich počet je väčší alebo rovný ako $(N+1)/2$, výstup mediánového operátora je jedna, v opačnom prípade je nula. Filtrácia binárnych signálov je atraktívna tak z praktického ako aj z teoretického hľadiska.

Binárny signál sa získa pomocou operátora prahovej dekompozície. Nech x je M úrovňový signál, v prípade 8 bitového signálu $M = 256$: $0 \leq x \leq M-1$ a počet kvantizačných úrovní je $M-1$: $1 \leq j \leq M-1$. Signál x môže byť rozložený do $M-1$ kvantizačných úrovní $x^{(j)}$, pomocou funkcie prahovej dekompozície $I_j(x)$ nasledovne:

$$x^{(j)} = T_j(x) = \begin{cases} 1 & \text{if } x \geq j \\ 0 & \text{if } x < j \end{cases} \quad (8)$$

Takto rozložené binárne signály môžu byť filtrované nezávisle aj pomocou mediánového filtra.

$$y^{(j)} = \text{med}(x_1^{(j)}, x_2^{(j)}, \dots, x_n^{(j)}) \quad (9)$$

Rekonštrukcia výstupu filtra spočíva v sčítaní výstupov mediánových filtrov pre jednotlivé úrovne.

$$y = \sum_{j=1}^{M-1} y^{(j)} \quad (10)$$

Architektúra kompozičného filtra je znázornená na obr. 3.

Prahová dekompozícia má teoretický aj praktický význam v oblasti mediánovej filtrácie. Používa sa na popísanie štatistických rozdelení výstupu a na nájdenie koreňov mediánového

This definition is equivalent to the centre-weighted median that is given by the median over a modified set of observations containing multiple processed samples. However, the implementation of the LUM smoother as shown in (5) requires fewer operations than that of (6), since fewer elements must be sorted.

$$y = \text{med} \left\{ W \cup \underbrace{[x_4, x_4, \dots, x_4]}_{w-1} \right\} \quad (6)$$

In (6) w is the weight of the central sample and is assumed to be an odd positive integer. The relationship between the parameter in the centre-weighted median and the parameter k in the LUM smoother is

$$w = N - 2k + 2 \quad (7)$$

The process of arranging the data needs high computational demand. The next section describes a filter whose VLSI implementation is fast.

6. Stack filter

Median filtering of binary signals is relatively easy and fairly well understood. Its computation can be reduced to counting the 1's inside the OW. If their number is greater than or equal to $(N+1)/2$, the output of the median is 1, otherwise is 0. The filtering of the binary signal is attractive from both practical and theoretical point of view.

The binary signal can be obtained by the operator of *threshold decomposition*. Let x be an M -valued signal, in case of 8bit quantized signal $M = 256$: $0 \leq x \leq M-1$ and consider the $M-1$ thresholds: $1 \leq j \leq M-1$. The signal x can be decomposed to $M-1$ binary valued signals $x^{(j)}$, by using a threshold decomposition function $I_j(x)$ as follows:

$$x^{(j)} = T_j(x) = \begin{cases} 1 & \text{if } x \geq j \\ 0 & \text{if } x < j \end{cases} \quad (8)$$

These $M-1$ binary valued signals can be filtered independently for example by MF.


$$y^{(j)} = \text{med}(x_1^{(j)}, x_2^{(j)}, \dots, x_n^{(j)}) \quad (9)$$

The output of the whole filter can be reconstructed by summing the binary output signals.

$$y = \sum_{j=1}^{M-1} y^{(j)} \quad (10)$$

The architecture of stack filter is shown in Fig. 3.

The threshold decomposition has both theoretical and practical significance for median filtering. It has been used to find the statistical distribution of the output of the median filter and of the roots of the



Obr. 3 Kompozičný filter
Fig. 3 The stack filter

filtra. Prahová dekompozícia je taktiež použitá pri vývoji architektúr na rýchlu mediánovú filtráciu.

Binárny mediánový filter môže byť nahradený Boolovou funkciou na každej kvantizačnej úrovni. Výstupy týchto binárnych filtrov majú vlastnosť nakladania, ak výstup $y^{(j)}$ $1 \leq j \leq k-1$ v čase i sa skladá zo stĺpca jednotiek, na ktorých sa nachádzajú len nuly. Filtre, ktoré majú vlastnosť nakladania, sa nazývajú kompozičné filtre [1,5]. Výstup kompozičných filtrov je daný:

$$y = S_j(x) = \sum_{j=1}^{M-1} y^{(j)} = S_j \left(\sum_{j=1}^{M-1} T_j(x) \right) \quad (11)$$

Do triedy kompozičných filtrov platia aj také nelineárne filtre ako mediánový filter alebo LUM filter. VLSI implementácia mediánových filtrov založených na prahovej dekompozícii sa veľmi zjednoduší náhradou mediánového filtra Boolovými funkciami.

Trieda kompozičných filtrov je veľmi široká. Ak veľkosť pracovného okna je n , počet kompozičných filtrov je viac ako $2^{2^{n/2}}$. Problém nájdenia vhodných kompozičných filtrov sa redukuje na problém nájdenia Boolových funkcií, ktoré spĺňajú vlastnosť nakladania. Také funkcie sú tzv. pozitívne Boolové funkcie. Boolová funkcia je vtedy a len vtedy pozitívna, ak na vstupné hodnoty nebol aplikovaný operátor inverzie.

Hlavnou úlohou návrhárov je nájsť vhodnú pozitívnu Boolovú funkciu, ktorá dobre potláča impulzový šum a súčasne zachováva hrany a jemné detaily signálu. Počet pozitívnych Boolových funkcií je veľmi vysoký. V prípade, ak veľkosť pracovného okna je päť, potom počet funkcií je 7581, ak veľkosť okna je sedem, počet funkcií narastá na neskutočne veľkú hodnotu $> 2.4 \cdot 10^{12}$. Z toho dôvodu je potrebné nájsť metódu, ktorá za krátky čas nájde vhodnú funkciu z tej veľkej množiny funkcií.

7. Neurónové kompozičné filtre

Neurónové siete podstatne zjednodušili návrh kompozičných filtrov. V tomto prípade binárne mediánové filtre na každej kvantizačnej úrovni sú nahradené neurónovou sieťou. Podobne ako v predchádzajúcom prípade kompozičný filter, môže byť homogénny, ak na všetkých kvantizačných úrovniach sú umiestnené filtre s rovnakými parametrami, alebo nehomogénny, ak na jednotlivých úrovniach parametre filtrov môžu byť rôzne. V skutočnosti však homogénny filter už dosahuje uspokojujúce výsledky.

Štruktúra kompozičného filtra je obzvlášť vhodná pre neurónové siete, nakoľko vstupné údaje sú $\{0,1\}$, a preto nie je potrebné normalizovať vstupné hodnoty do neurónovej siete. Výstup neurónovej siete mal by byť podobne ako vstup 0 alebo 1. Takýto výstup je možné dosiahnuť len zavedením prahu na výstup siete, alebo pomocou prahovej aktivačnej funkcie.

$$y = f_{act}(x) = \begin{cases} 1 & \text{if } x \geq 0.5 \\ 0 & \text{if } x < 0.5 \end{cases} \quad (12)$$

kde x je vstup neurónovej siete a y je výstup siete.

Taká aktivačná funkcia by mala byť na výstupe neurónovej siete. Neurónová sieť sa môže nachádzať v dvoch stavoch. Prvý je stav učenia, keď parametre siete sú nastavované, a druhý stav, keď

MF. It has also been used to develop architectures for fast median filtering.

The binary median filters at each level can be replaced by Boolean functions. The outputs of these binary filters possess what is referred to as the stacking property if the binary output signals $y^{(j)}$ $1 \leq j \leq k-1$, are piled and the pile of y at time i consists of a column of 1's having a column of 0's on top. The filters that support the stacking property are called stack filters [1,5]. The output of a stack filter is given by:

$$y = S_j(x) = \sum_{j=1}^{M-1} y^{(j)} = S_j \left(\sum_{j=1}^{M-1} T_j(x) \right) \quad (11)$$

Stack filters constitute a broad class of non-linear filters having median filters and LUM filters as special cases. The replacement of MF by Boolean function greatly facilitates the VLSI implementation of the MF based on threshold decomposition.

The class of stack filters is very large. Their number, when the filter window is n , grows faster than $2^{2^{n/2}}$. The problem of finding them reduces to the problem of finding stackable Boolean functions, or so-called positive Boolean functions (PBF). It has been established that a Boolean function is stackable if and only if it contains no complements of the input variables.

The main task of designers is to find a suitable PBF functions that well suppress the impulsive noise and concurrently well preserves signal edges and fine details. However, the amount of PBF functions is very high. In case of OW of size five, there are 7581 functions and in case of size seven, the number of PBF is tremendously high $> 2.4 \cdot 10^{12}$. Therefore, it is necessary to find methods that find the optimal PBF from such great set.

7. Neural stack filters

Neural networks (NN) [9] greatly simplified the design of the stack filters. In this case, the binary median filters at each level are replaced by neural networks. Similarly as in previous case the stack filter can be homogenous, at each level are identical filters with identical parameters, or non-homogenous, at each level the parameters of the filters can vary. Usually, it a sufficient result can be obtained by the homogenous representation.

The stack filter structure is useful in case of NN, because the input data are $\{0,1\}$ so it is not necessary to normalize the input for the NN. The output of the NN should be also 0 or 1. Such output can be obtained only by a hard limiter, or also called threshold activation function.

$$y = f_{act}(x) = \begin{cases} 1 & \text{if } x \geq 0.5 \\ 0 & \text{if } x < 0.5 \end{cases} \quad (12)$$


where x is the input of the neuron and y is the neuron output.

Such activation function should be used at output layer of the NN. There are two modes of the NN. The first one is the training mode, where the weights of the NN are set up and the second one,

neurónová sieť spracováva vstupné dáta. V tomto stave váhy siete sú konštantné. Avšak v procese učenia nemôže byť použitá prahová aktivačná funkcia. Z toho dôvodu pri učení sa používa tzv. sigmoidálna aktivačná funkcia.

$$y = f_{act}(x) = \frac{1}{1 + \exp(-x)} \quad (13)$$

Bolo ukázané, že neurónová sieť s jedným neurónom dáva dobré výsledky [3,4]. Architektúra siete je na obr. 4. Výstup siete je získaný váhovaným súčtom vstupov, pričom výsledok je privedený do vhodnej aktivačnej funkcie. Takáto jednoduchá štruktúra môže výrazne zlepšiť vlastnosti kompozičného filtra. Navyše neurónová sieť môže byť učená pre rôzne úlohy, filtrácia impulzov, zvýraznenie hrán atď. Jediná nevýhoda je VLSI realizácia siete, ktorá je zložitejšia ako realizácia Boolových funkcií.



Obr. 4 Neurónová sieť s jedným neurónom

Fig. 4 Neural network with one neuron

where the NN processes the input data. In this case the NN weights are fixed. However, the activation function of the neurons cannot be hard limiter in training mode. Therefore, it must be changed to sigmoidal function, also called the soft limiter.

$$y = f_{act}(x) = \frac{1}{1 + \exp(-x)} \quad (13)$$

It was shown [3,4] that the NN with only one neuron gives sufficient results. The architecture of the NN is shown in Fig. 4.

The output of the NN is obtained by weighted summing the input data and applying the appropriate activation function on result. Such a simple structure can greatly improve the performance of the stack filter. Moreover, the neural filter can be trained for an arbitrary task, impulse noise suppression, edge enhancement, etc. However, the VLSI realization of the NN is

more difficult than the realization of the Boolean functions.

8. Záver

V tomto článku bol ukázaný krátky prehľad triedy kompozičných filtrov. Jednoduchosť hardvérovej realizácie a vlastnosť potlačania impulzového šumu je dôvodom rozšírenia tejto triedy filtrov. Dobré známy mediánový filter a jeho vylepšenie vyhladzovací LUM filter môže byť tiež realizovaný kompozičnými filtermi. Návrh kompozičných filtrov s optimálnymi Boolovými funkciami je časovo náročná úloha. Iný spôsob návrhu ponúkajú neurónové kompozičné filtre. Vlastnosti neurónových kompozičných filtrov sú veľmi zaujímavé najmä kvôli jednoduchšej architektúre siete. Na druhej strane však VLSI implementácia je zložitejšia ako v prípade Boolových funkcií. Z tohto dôvodu výskum by sa mal zamerať na zrýchlenie hľadania vhodných Boolových funkcií. Permutačná teória a genetické algoritmy sú jedným z možných riešení ako zrýchliť vyhľadávanie [6].

9. Poďakovanie

Práca prezentovaná v tomto príspevku bola podporovaná grantom ministerstva školstva a Slovenskou akadémiou vied VEGA pod číslom 1/5241/98.

Recenzenti: V. Moucha, L. Schwartz

8. Conclusion

This paper gave a short review of the class of stack filters. The simplicity of hardware realisation and the performance of impulse noise suppression make this class widely useful in many applications. The well-known median filter and its improvement the LUM smoother can be realised as the stack filters. The design of stack filters with optimal Boolean function is very computation demanding. An alternative way of design, the neural stack filters were shown. The performance of the neural stack filters is very interesting because of simple architecture of neural network. However the VLSI implementation is more complicated than the implementation of the PBF. Therefore, the future research should be oriented to accelerate the search of suitable PBF. Permutation theory gives one way of solving the problem and another way, the genetics algorithm [6].

9. Acknowledgements

The work presented in this paper was supported by the Grant Agency of the Ministry of Education and Academy of Science of the Slovak Republic VEGA under Grant No. 1/5241/98.

Reviewed by: V. Moucha, L. Schwartz

10. Literatúra - References

- [1] PITAS, I., VENETSANOPOULOS, A.N.: Order statistics in digital image processing. Proceedings of the IEEE, Vol.80, No.12, December 1992, pp.1893-1916
- [2] KIM, S.R., EFRON, A.: Adaptive robust impulse noise filtering. IEEE Transactions on signal processing, Vol.43, No.8, August 1995, pp.1855-1866

- [3] DRUTAROVSKÝ, M.: Neural weighted order statistics filters based on threshold decomposition. Thesis. Košice, June 1995, (in Slovak)
- [4] DRUTAROVSKÝ, M., MARCHEVSKÝ, S.: The Methods of Design and Implementation of Stack Filters for Image Processing. Radioengineering, Vol.4, No.1, April 1995, pp.13-17
- [5] GABBOUJ, M., COYE, E.J., GALLAGHER, N.C.: An Overview of Median and Stack Filtering. Circuit Systems Signal Process, Vol.11, No.1, 1992, pp.7-45
- [6] HARVEY, N.R., MARSHALL, S.: Optimum Genetic Algorithms for the Design of Stack-Filters. IEEE Transactions on Signal Processing, Vol.42, No.4, April 1994, pp.832-835
- [7] MARCHEVSKÝ, S., DRUTAROVSKÝ, M., CHOMAT, O.: Iterative Filtering of Noisy Images by Adaptive Neural Network Filter. New Trends in Signal Processing I, Liptovský Mikuláš, May 1996, pp.118-121
- [8] STUPÁK, CS.: Digital Image Filtration Based on Local Statistics. 3rd International Scientific Conference Elektro '99, Žilina, May 25-26 1999, pp.106-111
- [9] STUPÁK, CS., MARCHEVSKÝ, S., DRUTAROVSKÝ, M.: Searching the Optimal Training Set for Neural Network Training. Journal of Electrical Engineering, No.5-6, Vol.50, 1999, pp.143-147
- [10] STUPÁK, CS., LUKÁČ, R.: Impulse Detection in Grayscale Images. Digital Signal Processing '99, Herľany, September 29-30, 1999, pp.96-99
- [11] LUKÁČ, R., STUPÁK, CS.: A Class of Impulse Detectors Controlled by a Threshold. Proceedings of the 3rd International Scientific Conference INFORMATICS AND ALGORITHMS '99, Faculty of Production Technologies at the Technical University of Košice with residence in Prešov, Slovakia, Sept. 9-10 1999, pp.178-181
- [12] LUKÁČ, R., MARCHEVSKÝ, S.: Threshold Impulse Detector Based on LUM Smoother (LUMsm detector). Journal of Electrical Engineering, submitted
- [13] LUKÁČ, R.: An Adaptive Control of LUM Smoother. Radioengineering, Vol.9, No.1, April 2000, pp.9-12.
- [14] LUKÁČ, R.: Impulse Detection by Entropy Detector (H - Detector). Journal of Electrical Engineering, No.9-10 Vol.50, 1999, pp.310-312.
- [15] LUKÁČ, R., MARCHEVSKÝ, S.: A Neural LUM Smoother. Radioengineering, submitted.
- [16] STUCK, B., KLEINER, B.: A statistical analysis of telephone noise. Bell Syst. Tech. J., Vol.53, Sept. 1974, pp.1263-1320
- [17] SHINDE, M., GUPTA, S.: A model of hf impulsive atmospheric noise. IEEE Trans. Electromag. Compat., Vol. EMC-16, May 1974, pp.71-75
- [18] MIDDLETON, D.: Man-made noise in urban environments and transportation systems. IEEE Trans. Commun., Vol. COM-21, Nov. 1973, pp.1232-1241