

Jakub PEKSIŃSKI¹
Grzegorz MIKOŁAJCZAK²

ZASTOSOWANIE SIECI NEURONOWEJ JEDNOWARSTWOWEJ TYPU INSTAR W CYFROWYM PRZETWARZANIU OBRAZÓW


W artykule autorzy przedstawili możliwość wykorzystania sieci neuronowej jednowarstwowej typu INSTAR do poprawy jakości obrazów cyfrowych uzyskanych z różnych urządzeń, których budowa oparta jest na matrycy CCD. Jako kryterium porównawcze została zastosowana miara jakości MSE.

THE USE OF SINGLE-LAYER NEURAL NETWORKS TYPE INSTAR IN DIGITAL IMAGE PROCESSING

The authors put forward the possibility of using a single-layer neural network to improve the quality instar digital images obtained from various devices whose construction is based on the CCD. As a comparator was used measure of the quality of the MSE.

1. WSTĘP

Od samego początku powstania komputerów ludzie starali się przekształcić obrazy analogowe na ich odpowiednik cyfrowy. Do tego celu opracowano wiele urządzeń, których budowa oparta jest na przetwornikach CCD (*Charge Coupled Device*). Matryca CCD jest urządzenie o sprzężeniu ładunkowym. Składa się z siatki światłoczułych elementów, które zamieniają docierające do nich w danym punkcie obrazu światło na impulsy elektryczne o wartości proporcjonalnej do natężenia tego światła. W ten sposób powstaje cyfrowy obraz odzwierciedlający fotografowany obiekt lub skanowany document. Schemat blokowy typowego toru przetwarzania obrazu pokazany jest na rysunku numer.1.



Rys.1 Schemat blokowy toru przetwarzania obrazu

¹Zachodniopomorski Uniwersytet Technologiczny w Szczecinie Wydział Elektryczny, ul. 26 Kwietnia 10, 71-126 Szczecin, tel. +48 91 4495139, e-mail: jpeknski@zut.edu.pl

²Zachodniopomorski Uniwersytet Technologiczny w Szczecinie Wydział Elektryczny, ul. 26 Kwietnia 10, 71-126 Szczecin, tel. +48 91 4495139, e-mail: gregorm@zut.edu.pl

Podstawowym zadaniem takiego toru jest takie przekształcenie obrazu analogowego aby jego postać cyfrowa była jak najbardziej wierna oryginałowi. Jak widać tor ten składa się z następujących elementów:

- Źródła obrazu (Obiekt);
- Urządzenia służące do przetworzenia obrazu analogowego do postaci cyfrowej i przesłania go do komputera w celu dalszego przetwarzania. Takim uprzedzeniem mogą być urządzenia których budowa oparta jest na strukturze *CCD* (skaner, aparat, kamera itp.), w przeprowadzonym eksperymencie użyto skaner niskiej i wysokiej jakości;
- Komputer do zadań którego należy przetworzenie cyfrowego obrazu;
- Monitor do wizualizacji obrazu cyfrowego;
- Odbiorcy oceniającego jakość obrazu.

Można powiedzieć, obraz cyfrowy jest tylko mniej lub bardziej wiernym odwzorowaniem obrazu analogowego [1]. Na jakość odwzorowania istotny wpływ ma zastosowanie urządzenia do przetwarzania obrazu analogowego do postaci cyfrowej. Obecnie powszechnymi urządzeniami stosowanymi do tego celu są urządzenia których budowa oparta jest na strukturze *CCD*. Pozyskiwanie danych przy pomocy tego rodzaju urządzeń związane jest z występowaniem różnych zakłóceń oraz błędów wpływających na jakość pozyskanego obrazu cyfrowego. Typowe błędy występujące w torze przetwarzania obrazów można podzielić na następujące grupy:

- Grupa 1. Błędy podstawowe - zalicza się do nich błędy powstające w torze transmisyjnym, oraz błędy związane z obróbką i interpretacją danych;
- Grupa 2. Błędy przetwornika obrazu - są to błędy zależne od jakości zastosowanej matrycy *CCD* (rozdzielczości, jakości wykonania)
- Grupa 3. Błędy wynikające z oświetlenia matrycy *CCD* - są to błędy powstałe w wyniku szumów termicznych, transferu, ładunku).

Wszystkie w/w błędy powodują znaczne pogorszenie jakości otrzymanego obrazu cyfrowego. Oczywiście aby uzyskać lepszy obraz należy zastosować w torze przetwarzania obrazu urządzenie o lepszych parametrach. Jednak takie rozwiązanie wiąże się z wysokimi kosztami zakupu. Alternatywą jest zastosowanie *filtracji liniowej* [2] opartej na operacji splotu opisanego wzorem numer 1.

$$Y(n, m) = \sum_{i, j \in k} X(n - i, y - j)w(i, j) \quad (1)$$

Gdzie: k – otoczenie piksela;

$w(i, j)$ – wagi otoczenia k piksela (n, m) ;

$X(n, m)$ – obraz wejściowy;

$Y(n, m)$ – obraz wyjściowy

Jednak metoda filtracji liniowej była skuteczna konieczne jest znajomość odpowiedniej maski filtru $w(i,j)$. W przeciwnym wypadku gdy zastosuje się źle dobrany filtry możemy doprowadzić do pogorszenia obrazu w stosunku do oryginału. W artykule tym autorzy postawili sobie za cel przekształcenie obrazu pozyskanego skanerem niskiej klasy taka by jego jakość była porównywalna z obrazem cyfrowym pozyskanym skanerem klasy wysokiej. W tym celu obraz zostanie poddany filtracji liniowej. W pracy zaproponowano wykorzystanie sieci neuronowej do generowania odpowiedzi impulsowej w postaci filtru FIR. Projektowanie i optymalizacja filtrów FIR w oparciu o sieć neuronową [3] posiada duży potencjał w cyfrowym przetwarzaniu obrazów. Wyniki eksperymentów potwierdziły, że w wyniku uczenia sieci neuronowej można uzyskać maskę filtru, którego użycie umożliwia poprawę jakości obrazu.

2. PORÓWNANIE OBRAZÓW PRZY UŻYCIU KRYTERIUM MSE

W celu pokazania różnicy w jakości obrazów cyfrowych pozyskiwanych przy pomocy dwóch różnych skanerów wykonano doświadczenie praktyczne. W doświadczeniu zostały wykorzystane dwa skanery:

- Skaner niskiej klasy;
- Skaner wysokiej klasy.

Za pomocą tych skanerów pozyskano obrazy cyfrowe opisane w następujący sposób:

- Literą a) oznaczona obrazy pozyskane przy pomocy skanera niskiej klasy;
- Literą b) obrazy uzyskane za pomocą skanera wysokiej klasy.

Rysunek nr. 2 przedstawiono przykładowe obrazy biorące udział w eksperymencie pozyskane przy pomocy wyżej wymienionych skanerów. W celu eliminacji jak największej ilości błędów powstających w procesie skanowania oraz ujednoczenia wyników wykonano następujące czynności:

- Firmowe oprogramowanie skanerów zostało zastąpione oprogramowaniem *VueScan 8.5.xxx* firmy *Hamrick Software*, pozwoliło to wyeliminowanie błędów powstających w wyniku przetwarzania danych;
- Każdy ze skanerów rozgrzewany był przez 10 minut przed wykonaniem skanu obrazu biorącego udział w eksperymencie. Po otrzymaniu obrazu, skaner był wyłączany na 20 minut;
- Obrazy zapisywano do formatu *.bmp.



Rys.2 Przykładowe obrazy pozyskane z dwóch różnych skanerów

Tak otrzymane obrazy cyfrowe poddano ocenie:

- Subiektywnej wykonanej przez grupę 30 studentów mający w skali od 1 do 10 (gdzie 10 oznacza identyczność obrazów) podobieństwo obrazów. Wyniki liczono według wzoru nr 2:

$$S = \frac{s_1 + s_2 + \dots + s_{30}}{30} \quad (2)$$

Gdzie: s_1, s_2, \dots, s_{30} – oceny cząstkowe;

- Obiektywnej, w której wykorzystano dwie miary jakości *Mean Square Error* (MSE) wzór nr 2 [4],

$$MSE = \frac{1}{MN} \sum_{x=1}^M \sum_{y=1}^N [f_{in}(x, y) - f_{out}(x, y)]^2 \quad (3)$$

Gdzie: f_{in} - obraz uzyskany ze skanera wysokiej klasy;
 f_{out} - obraz uzyskany skanem niskiej klasy

W tabeli numer 1 przedstawiono wyniki porównań obrazów uzyskanych z dwóch skanerów .

Tab. 1 Wyniki wskazań kryteriów

Pary obrazów		MSE	S
1	obraz 1a	52.381	9.721
	obraz 1b		
2	obraz 2a	57.293	9.843
	obraz 2b		
3	obraz 3a	57.511	9.684
	obraz 3b		
4	obraz 4a	50.022	9.748
	obraz 4b		
5	obraz 5a	54.135	9.698
	obraz 5b		
6	obraz 6a	56.772	9.809
	obraz 6b		

Analizując wyniki przedstawione w tabeli numer 1, można stwierdzić, że między obrazami występują pewne niewielkie różnice. Spowodowane jest to błędami opisanymi w punkcie 1 artykułu. Oznacza to, że pozyskano dwa różne obrazy cyfrowe, odbiegające od siebie jakością. Obrazy otrzymane ze skanera niskiej klasy można uzdatnić do jakości obrazów otrzymanych skanerem wysokiej klasy stosując operacje *cyfrowego przetwarzania obrazów*. Do najczęściej używanych metod poprawy jakości obrazów cyfrowych zalicza cyfrową filtrację obrazu. Operacja ta pozwala pozbyć się z obrazu pewnych niepożądanych obiektów takich jak zakłócenia lub szumy. Jednak aby operacja ta była skuteczna konieczne jest posiadanie wiedzy na temat występujących w obrazie zakłóceń

3. ZASTOSOWANIE SIECI NEURONOWEJ DO GENEROWANIA FILTRU POPRAWIAJĄCEGO JAKOŚĆ OBRAZÓW ZE SKANERA NISKIEJ KLASY

Do celów wygenerowania maski filtru *FIR* o rozmiarach 5×5 , autorzy zastosowali sieć neuronową typu *INSTAR* [5]. Sieć tego typu dopasowuje wagi punktu sumacyjnego neuronu do swoich sygnałów wejściowych. Neuron tego typu pokazany jest na rysunku numer 3. Sygnały wejściowe x_i podawane są za pośrednictwem wag $w_{i,j}$ na wejście *i-tego* instara a następnie sumowane zgodnie ze wzorem numer 4.

$$u_i = \sum_{j=1}^N w_{i,j} x_j \quad (4)$$


W zależności od zastosowanej funkcji aktywacji na wyjściu neuronu wytwarzany jest sygnał wyjściowy opisany wzorem numer 5.

$$y_i = f(u_i) \quad (5)$$

Dobór wag odbywa się tutaj według reguły *Grossberga* wzór numer 6.

$$w_{ij}(t + 1) = w_{ij}(t) + ny_i[x_j - w_{ij}(t)] \quad (6)$$

Gdzie: n - stała uczenia




Rys. 3 Schemat połączeń INSTARA

W wyniku uczenia sieci neuronowej otrzymano maskę filtru *FIR* o postaci pokazanej na rysunku numer 4. Rysunek numer 5 przedstawia charakterystykę amplitudową otrzymanego filtru.

0.0082	0.0098	0.0231	0.0073	0.0036
0.0110	0.0094	0.1588	0.0047	0.0008
0.0270	0.1084	0.4435	0.1087	0.0244
0.0012	0.0058	0.1558	0.0098	0.0103
0.0064	0.0059	0.0230	0.0074	0.0076

Rys.4. Maska filtru *FIR*



Rys.5. Ch-ka amplitudowa filtru *FIR*

Tak otrzymanym filtrem stosując wzór numer 1 poddano filtracji obrazy uzyskane przy pomocy skanera niskiej klasy. Otrzymano w ten sposób nowe obrazy, które porównano przy pomocy kryteriów opisanych wzorami numer 2 i 3 z obrazami otrzymanymi ze skanera wysokiej klasy. Przykładowe wyniki obliczeń pokazano w tabeli numer 2.

Tab. 2. Przykładowe wyniki obliczeń

		MSE before filtering	MSE after filtering	S before filtering	S after filtering
1	Obraz 1a po filtracji	52.381	23.311	9.721	9.824
2	Obraz 2a po filtracji	57.293	30.764	9.843	9.811
3	Obraz 3a po filtracji	57.511	32.349	9.684	9.732
4	Obraz 4a po filtracji	50.022	21.576	9.748	9.844
5	Obraz 5a po filtracji	54.135	26.023	9.698	9.521
6	Obraz 6a po filtracji	56.772	29.351	9.809	9.745

4. WNIOSKI

Analizując wyniki umieszczone w tabeli 2 widać, że w wyniku operacji filtracji filtrem wygenerowanym przy pomocy sieci neuronowej następuje poprawa jakości obrazów w stosunku do ich oryginału. Filtr otrzymany w procesie uczenia sieci neuronowej ze względu na charakter dolnoprzepustowy dobrze radzą sobie z większością zakłóceń obrazu otrzymanego ze skanera niskiej klasy. Dysponując obrazem referencyjnym ze skanera wysokiej jakości o znanych parametrach i obrazem ze skanera gorszej jakości oraz programem realizującym proces uczenia sieci neuronowej otrzymujemy maskę filtru którą możemy użyć bezpośrednio w popularnych programach graficznych. W zależności od wymaganej jakości możemy korzystać z filtru FIR dobranego do konkretnego poprawianego obrazu lub otrzymanego w wyniku uśrednienia. Zaproponowany w pracy proces uczenia sieci neuronowej gwarantuje otrzymanie filtru FIR dającego poprawę jakości obrazu uzyskanego ze skanera niskiej klasy do jakości zbliżonej do jakości obrazu uzyskanego ze skanera wysokiej klasy.

5. BIBLIOGRAFIA

- [1] W.K. Pratt „*Digital Image Processing*”, PIKS Inside, Willey, 2001;
- [2] E. Kornatowski, J. Kowalski, G. Mikołajczak, J. Pęksiński “*Filtracja liniowa i nieliniowa obrazów dyskretnych*”, Wydawnictwo Hogben, Szczecin 2005.
- [3] R. Cierniak “*A neural network optimization-based method of image reconstruction from projections*”, Intelligent Information and Data Base System, LNAI 5990, str. 241-250, Springer-Verlag 2010;
- [4] Z. Wang, Alan C. Bovik “*Mean Squared Error: Love it or Leave it?*”, IEEE Signal Processing Magazine, 2009;
- [5] S. Osowski “*Sieci neuronowe do przetwarzania informacji*”, Oficyna wydawnicza Politechniki Warszawskiej, Warszawa 2000;