

# Wykorzystanie sieci neuronowych w diagnostyce poprawności wykonania płytek drukowanych

Mariusz Sikora, Michał Grochowski

Wydział Elektrotechniki i Automatyki Politechniki Gdańskiej

**Streszczenie:** Artykuł opisuje stanowisko badawcze do diagnostyki optycznej poprawności wykonania płytek drukowanych przesuujących się po taśmie produkcyjnej. Diagnostyka optyczna realizowana jest za pomocą kamery. Obraz z kamery przekazywany jest do komputera PC, gdzie trafia do zaprojektowanego systemu diagnostycznego, zaimplementowanego w środowisku MATLAB. Po wstępnym przetworzeniu obrazu kierowane są do właściwego systemu diagnostycznego wykorzystującego sztuczne sieci neuronowe, który podejmuje ostateczną decyzję o poprawności montażu elementów płytki drukowanej. Cała aplikacja zrealizowana jest w środowisku MATLAB. W artykule zamieszczono wybrane wyniki badań analizujących wpływ aspektów takich, jak rodzaj oświetlenia, sposób obróbki i kompresji obrazu, dobór architektury i parametrów sieci neuronowej na jakość osiąganych wyników.

**Słowa kluczowe:** diagnostyka, przetwarzanie obrazów, sztuczne sieci neuronowe

## 1. Wprowadzenie

Współczesne procesy produkcyjne charakteryzują się tym, iż stale podnoszącej się wydajności musi towarzyszyć jednoczesny wzrost jakości wykonania produktów oraz ciągłe obniżanie kosztów produkcji. Producenci nie mogą pozwolić sobie na wyprodukowanie wadliwej partii produktów, ani na zbyt częste braki lub przestoje, ponieważ powodują one znaczne straty ekonomiczne. Z tego powodu bardzo duży nacisk kładzie się na nadzorowanie oraz monitorowanie produkcji. Często jakość kontroli produktu w przypadku zastosowania konwencjonalnych metod inspekcji jest uzależniona od predyspozycji psychofizycznych operatora, który nie jest odporny na zmęczenie i w przypadku monotonicznych, powtarzających się operacji, jest podatny na chwilowe braki koncentracji. Ponadto kontrola może odbywać się w warunkach niebezpiecznych dla zdrowia. Dlatego w celu wyeliminowania

błędów wywołanych przez czynnik ludzki dąży się do pełnej automatyzacji procesu inspekcji. Tłumaczy to coraz szersze zastosowanie systemów wizyjnych w przemyśle. Automatyczne systemy wizyjne wykorzystuje się powszechnie w procesie kontroli jakości w wielu dziedzinach przemysłu, szczególnie w produkcji wielkoseryjnej, taśmowej (np. w branży motoryzacyjnej czy podzespołów elektronicznych), ale także w przemyśle spożywczym czy farmaceutycznym.


Inspekcja optyczna składa się zasadniczo z czterech podstawowych faz: akwizycja obrazu, przetwarzanie obrazu, analiza obrazu, podjęcie decyzji. Jako dodatkowe etapy procesu najczęściej występują: archiwizacja danych, obróbka statystyczna danych oraz wizualizacja. W systemie takim równorzędne role pełnią sprzęt (wysokoczułe i szybkie kamery przemysłowe, specjalizowane oświetlenie) oraz zastosowane algorytmy przetwarzania i analizy obrazów.

W artykule przedstawiono prototypowe stanowisko badawcze do optycznej kontroli jakości produktów przemysłowych, w tym przypadku poprawności wykonania prostych płytek drukowanych. Na rys. 1 pokazano przykładowe defekty powstające na etapie montażu takiej płytki.

Jako narzędzie decyzyjne w procesie inspekcji zastosowano sztuczne sieci neuronowe. Aplikacja napisana w środowisku MATLAB umożliwia przeprowadzenie całościowego procesu diagnostyki optycznej oraz analizę wpływu wielu elementów w poszczególnych fazach inspekcji na końcową jakość inspekcji. Stanowisko jest efektem pracy inżynierskiej inż. Mariusza Sikory prowadzonej pod nadzorem dr inż. Michała Grochowskiego [3].


## 2. Stanowisko badawcze

Stanowisko badawcze zostało pokazane na rys. 2, natomiast na rys. 3 przedstawiona została jego struktura funkcjonalna. Konstrukcja została wykonana z profili aluminiowych, jako środek transportu zastosowano sznur z mikrogumy.




**Rys. 1.** Przykłady wadliwego montażu lub lutowania płytki: a) odwrotne umieszczenie układu scalonego, b) odwrotna polaryzacja diody, c) brak elementu, d) rozmazanie pasty lutowniczej


**Fig. 1.** The examples of faulty assembling or soldering of printed circuit-board: a) inverse position of the integrated circuit, b) reverse polarization of the diode, c) lack of the element, d) smearing of the soldering paste



Rys. 2. Stanowisko badawcze do diagnostyki optycznej  
Fig. 2. Optical diagnostics research test stand



Rys. 4. Układ sterowania stanowiska  
Fig. 4. Control unit of the test stand



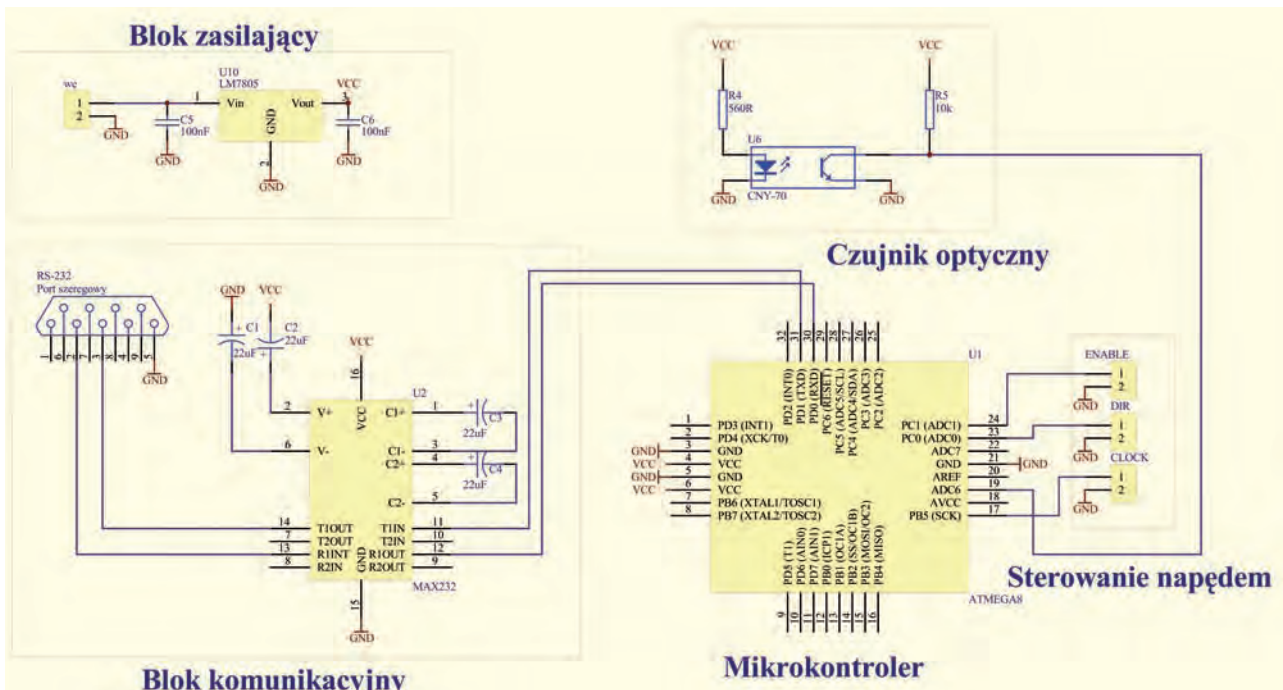
Rys. 3. Struktura funkcjonalna systemu  
Fig. 3. Functional structure of the system

Do wykrywania obecności diagnozowanych elementów wykorzystano czujnik optyczny CNY-70.

Jako napęd zastosowany został silnik krokowy, sterowany poprzez mikrokontroler ATmega8 firmy ATMEL, za pomocą wzmacniacza mocy zrealizowanego na układzie TA8435H. Mikrokontroler w tym układzie wykonuje trzy podstawowe zadania, tj. steruje pracą silnika krokowego, komunikuje się z komputerem oraz sprawdza, czy płytkę znajduje się w ob-

szarze widzenia kamery. Układ sterowania wraz z zasilaniem przedstawiono na rys. 4, a jego schemat ideowy na rys. 5.

Mikrokontroler na bieżąco sprawdza stan czujnika optycznego CNY-70 wskazującego obecność płytki drukowanej. Pomimo że czujnik wykorzystuje promieniowanie podczerwone, stosowanie diod oświetleniowych LED zakłócało działanie czujnika i konieczne było zastosowanie wbudowanego przetwornika A/C do pomiaru sygnału z czujnika. Do komunikacji z komputerem wybrany został interfejs RS-232 i układ MAX232 dopasowujący poziom napięcia do interfejsu. Aplikacja zainstalowana na komputerze odbiera sygnały o położeniu płytki z mikrokontrolera i steruje sposobem pracy silnika krokowego. Ze względu na moc obliczeniową, jaka potrzebna jest do przetwarzania obrazu i podejmowania decyzji o stanie poprawności wykonania płytki (lub innego elementu), jako jednostkę obliczeniową wykorzystano komputer klasy PC z oprogramowaniem MATLAB. Na kompu-



Rys. 5. Schemat ideowy sterownika stanowiska  
Fig. 5. Schematic diagram of the test stand control unit



terze w środowisku MATLAB/GUI stworzono dwie aplikacje – pierwsza służy do diagnostyki, w której zachodzi proces podejmowania decyzji o poprawności wykonania płytki, druga – do trenowania systemu. Środowisko MATLAB zarządza całością procesu komunikacji, sterowania oraz algorytmami przetwarzania obrazu i podejmowania decyzji. Istotnym elementem konstrukcji jest puszka zapewniająca odizolowanie od zewnętrznego, zmiennego oświetlenia, i zastosowanie sztucznego, pochodzącego z białych, zimnych diod LED. Sztuczne światło umożliwia równomierne oświetlenie całej powierzchni płytki, co ma ogromne znaczenie w procesie akwizycji i późniejszego przetwarzania obrazu. Przykłady błędnego oświetlenia pokazano na rys. 6.



Rys. 6. Przykłady błędnego oświetlenia płytki przy oświetleniu punktowym

Fig. 6. The examples of incorrect illumination of the circuit-board by the spot lighting

### 3. Akwizycja i przetwarzanie obrazu

Poprawna akwizycja i efektywny proces przetwarzania obrazu mają kluczowe znaczenie dla dalszego procesu uczenia oraz podejmowania decyzji przy użyciu sztucznych sieci neuronowych [4]. Na tym etapie najważniejsza jest jak najlepsza ekstrakcja elementów obrazu pozwalających na jego jednoznaczny ocenę przy jednoczesnej dużej kompresji zdjęcia, nie tracąc przy tym istotnych informacji. W opisywanym systemie po akwizycji zdjęcia następuje jego przetwarzanie polegające m.in. na

binaryzacji (RGB oraz jedynie koloru niebieskiego), filtracji, odnajdywaniu poszczególnych elementów, kompresji.

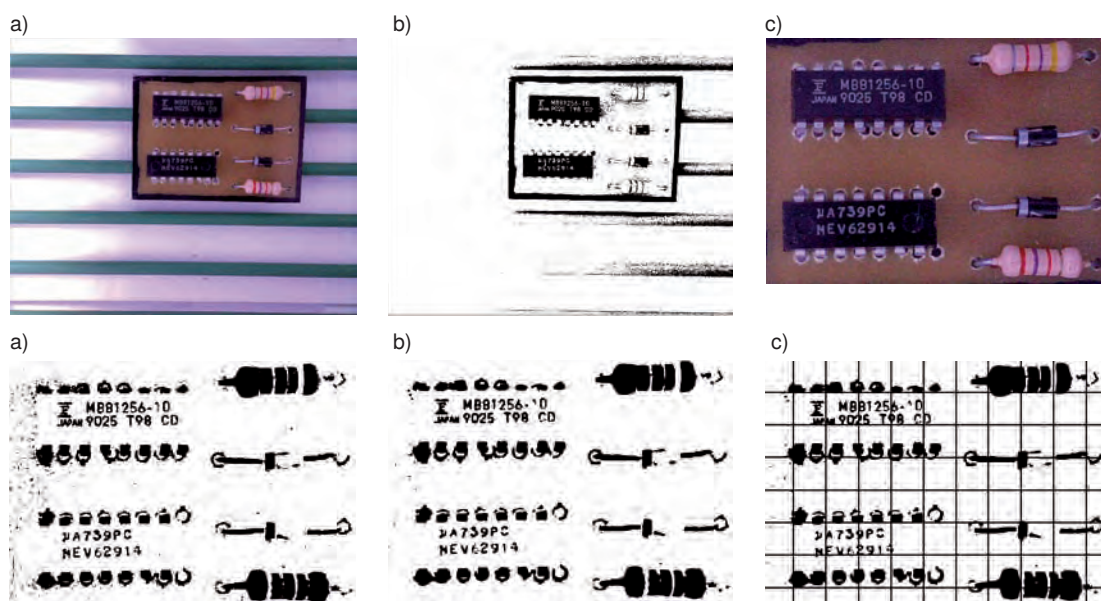
Pierwszą operacją jest odnalezienie na zdjęciu płytki drukowanej. Zdjęcie kolorowe poddane jest procesowi wstępnej binaryzacji przy progu o wartości pozwalającej na efektywne odróżnienie płytki drukowanej od tła. Znając kształt i rozmiar analizowanej płytki, możliwe jest jej precyzyjne odnalezienie. W następnym etapie obraz poddawany jest kolejnej binaryzacji, tym razem z tak dobranym progiem, aby możliwe było zachowanie jak największej ilości informacji o elementach płytki. Wyróżnić tutaj można dwie metody binaryzacji: operacja na zdjęciu kolorowym oraz jedynie na niebieskim odcieniu tego zdjęcia. Zastosowane diody LED pomimo tego, że są białe, mają zimną barwę, która jest zbliżona do koloru niebieskiego, dlatego operacja na niebieskim odcieniu daje ciekawe efekty, jak eliminacja drobnych odbłasków. Odblaski powstają głównie na elementach błyszczących, które w przypadku binaryzacji zdjęcia kolorowego powodują tworzenie się białej plamy w miejscu odbłasku (rys. 7), natomiast binaryzacja niebieskiego koloru potrafi je usunąć.



Rys. 7. Odblask światła na zdjęciu kolorowym (a); binaryzacja RGB (b); binaryzacja koloru niebieskiego (c)

Fig. 7. Reflection of the illumination on colour image (a); binarization RGB (b); binarization of the blue colour

W celu usunięcia szumu powstającego w procesie binaryzacji objawiającego się pojedynczymi lub zgrupowanymi pikselami, zastosowano filtr medianowy. Ostatnim etapem procesu przetwarzania obrazu jest zastosowanie siatki redukującej rozmiar zdjęcia. Jest to stratny proces redukcji po-




Rys. 8. Kolejne etapy procesu przetwarzania obrazu. Na górze: a) zdjęcie z kamery; b) wstępna binaryzacja; c) wyodrębnione zdjęcie. Na dole: a) binaryzacja koloru niebieskiego; b) filtr medianowy; c) nałożenie siatki redukcyjnej

Fig. 8. Consecutive stages of image processing. Top: a) camera image; b) preliminary binarization; c) isolation of the image. Bottom: a) binarization of the blue colour; b) median filter; c) reduction grid

legający na nałożeniu na zdjęcie siatki o określonej wielkości oczka, a następnie zsumowanie wszystkich wartości pikseli znajdujących się w tym oczku. W wyniku otrzymuje się macierz o wymiarach równych liczbie oczek siatki nałożonych na zdjęcie. Dla przykładu, zdjęcie wykonane przez kamerę ma rozdzielczość  $1280 \times 1024$ , co w efekcie daje ponad 1,3 mln pikseli. Wraz ze wzrostem rozmiaru oczka zwiększa się stopień redukcji, ale z drugiej strony zwiększa się liczba traconych informacji. Jak zostanie to pokazane w dalszej części artykułu, w tym konkretnym przypadku rozmiar obrazu można zmniejszyć nawet do ok. 400 elementów (tab. 1). Zastosowanie siatki o zbyt dużym oczku uniemożliwia efektywną diagnostykę. Analiza poprawności montażu układów scalonych wymaga większej precyzji. W pierwszej kolejności następuje ich odnalezienie na zdjęciu, następnie dla każdego z układów z osobna stosowana jest odpowiednia siatka. Na rys. 8 przedstawiono przykładowe efekty wybranych etapów przetwarzania obrazu. Tak przygotowany obraz trafia na wejście sztucznych sieci neuronowych.

### 4. Sztuczne sieci neuronowe

Sztuczne sieci neuronowe [1, 2] wykorzystują wiedzę o działaniu systemu nerwowego istot żywych. Podstawowym elementem sztucznych sieci neuronowych jest neuron (rys. 9).




Rys. 9. Model pojedynczego neuronu  
Fig. 9. Model of the neuron

Pojedynczy neuron ma  $n$  wejść, a każde z nich ma wagę  $w$ . Najczęściej występuje dodatkowe wejście zwane progiem. Przemnożone przez wagi sygnały wejściowe „schodzą się” do tzw. funkcji pobudzenia, gdzie najczęściej są sumowane, a następnie trafiają na blok aktywacji, w którym to podawane są kolejnej operacji matematycznej w zależności od zastosowanej funkcji aktywacji. Funkcja aktywacji może być ciągła lub przekąźnikowa, liniowa bądź nieliniowa. Rezultatem tych operacji jest sygnał wyjściowy z neuronu, opisany matematycznie jako

$$y = f\left(\sum_{i=1}^n x_i w_i + b\right) \tag{1}$$

przy czym  $f$  jest funkcją aktywacji,  $x_i$  są kolejnymi elementami wektora informacji wejściowej,  $w_i$  są wagami, natomiast  $b$  jest progiem. Każdy neuron ma jedno wyjście. Neurony połączone równolegle tworzą warstwę sieci neuronowej, natomiast szeregowo (w najprostszym przypadku) połączone ze sobą warstwy sieci tworzą sieć neuronową. Na rys. 10 przedstawiono schemat dwuwarstwowej sieci neuronowej jednokierunkowej.



Rys. 10. Sieć jednokierunkowa wielowarstwowa  
Fig. 10. Multilayer feed forward neural network

Wyjście z takiej sieci można opisać następującym równaniem:

$$y = F_2 \left( \sum_{i=1}^n F_1 \left( \sum_{i=1}^l x_i W_{1i} + B_1 \right) W_{2i} + B_2 \right) \tag{2}$$


przy czym  $F_1, F_2, B_1, B_2, W_{1i}, W_{2i}$  są wektorami zawierającymi odpowiednio: funkcje aktywacji, progi oraz wagi pierwszej i drugiej warstwy neuronów.

Sztuczna sieć neuronowa jest modelem typu black-box. Model ten stroi się w trakcie procesu uczenia, w wyniku czego dobierane są optymalne (najczęściej pod względem kryterium minimalizacji błędu średniokwadratowego odpowiedzi sieci) parametry sieci, czyli wagi i progi.

$$E = \frac{1}{2} \sum_{k=1}^p \sum_{j=1}^n (y_j(k) - d_j(k))^2 \tag{3}$$

gdzie:  $y(k)$  – odpowiedź neuronu,  $d(k)$  – pożądane wyjście neuronu,  $p$  – liczba elementów uczących,  $n$  – liczba neuronów w warstwie wyjściowej.

Pozostałymi dobraćymi elementami są funkcje aktywacji, liczba warstw sieci oraz liczba neuronów w każdej z warstw. Rys. 11 przedstawia ogólny schemat działania systemu diagnostycznego zastosowanego w stanowisku badawczym.



Rys. 11. Schemat działania modułu diagnostycznego  
Fig. 11. The scheme of diagnostic module functioning


Poszczególne piksele zdjęcia płytki drukowanej stają się wejściami sieci neuronowej. Przy przyjętej rozdzielczości zdjęcia ( $1280 \times 1024$ ) daje to liczbę 1 310 720 sygnałów. Oczywiście liczba taka uniemożliwia osiągnięcie jakichkolwiek rozsądnych wyników działania sieci (czas i dokładność obliczeń). W celu redukcji liczby wejść na zdjęcie nałożono siatkę (opisywaną wcześniej), w wyniku czego wejściami

sieci neuronowej stają się wartości wyliczone w poszczególnych polach siatki. Wagi i progi sieci dobierane są w procesie uczenia. Podczas fotografowania płytek zawsze uzyskiwano informację, czy dana płytka jest wykonana poprawnie czy też zawiera błędy. W przypadku błędnie wykonanej płytki operator procesu wskazywał miejsce i rodzaj defektu. W ten sposób nauczona sieć neuronowa, ma umiejętność generalizacji swojej wiedzy na przypadki podobne, lecz takie, które nie należały do zbioru uczącego. Zdolność uczenia oraz późniejszego uogólniania zdobytej wiedzy jest najważniejszą cechą sieci neuronowych.

## 5. Badania symulacyjne

### 5.1. Opis przeprowadzonych badań

W opisywanym systemie można wyróżnić trzy rodzaje sieci neuronowej. Pierwsza sieć służy do wstępnego rozróżniania rodzaju diagnozowanej płytki, druga do precyzyjnej analizy poprawności usytuowania układu scalonego na płytce, i w końcu trzecia sieć neuronowa do całościowej analizy płytki. Płytką uznawaną jest za pozbawioną wad w przypadku zgodnej decyzji drugiej i trzeciej sieci neuronowej, co oznacza, że wszystkie elementy płytki są wlutowane, mają odpowiednią polaryzację, zamontowany jest odpowiedni układ scalony (w odpowiedniej orientacji), brak jest widocznych uszkodzeń lutu. Wszelkie algorytmy oraz komunikację z urządzeniami zrealizowano w programie MATLAB. Na rys. 12 przedstawiono zrzut jednego z ekranów aplikacji.



Rys. 12. Przykładowy ekran programu diagnostycznego  
Fig. 12. The example screen of the diagnostics software

W ramach badań przeprowadzono analizę wpływu różnych metod i parametrów związanych z przetwarzaniem obrazu oraz strukturą i parametrami sieci neuronowych. Do estów wykonano i zastosowano bazę 1000 zdjęć płytek drukowanych, z czego 60 % zdjęć użyto do nauczania sieci neuronowej, natomiast całość bazy wykorzystano do walidacji. Analizie pod względem wpływu na jakość podejmowanych przez sieć decyzji poddano: metody binaryzacji, wielkość siatki redukcyjnej, struktury sieci (liczba warstw, liczba neuronów w poszczególnych warstwach, rodzaj funkcji aktywacji) oraz metody uczenia sieci. Dyskusję nad wybranymi rezultatami badań przedstawiono w kolejnej sekcji. Na potrzeby przedstawienia ujednoczonych wyników został wprowadzony wskaźnik jakości (4):

$$J = \frac{(U - 50\%) \cdot 2 + T}{2} \quad (4)$$

gdzie:  $U$  – ilość pozytywnie rozpoznanych obrazów uczących [%],  $T$  – ilość pozytywnie rozpoznanych obrazów testowych [%].

### 5.2. Dyskusja wyników

Na podstawie przeprowadzonych badań można stwierdzić, iż każdy z opisywanych procesów ma znaczący wpływ na osiągnięte wyniki. Poprawnie dobrane parametry przetwarzania obrazu oraz sieci neuronowej pozwalają na uzyskanie dokładności bliskiej 100 %. Z racji ograniczonej objętości artykułu skupiono się na kilku aspektach. Bardzo ważny jest rozmiar oczka siatki nakładanej na obraz w celu redukcji jego rozmiarów. W tab. 1 przedstawiono zależność między rozmiarem oczka siatki a wynikową liczbą wejść sieci neuronowej.

Tab. 1. Zależność pomiędzy rozmiarem oczka siatki, a liczbą wejść sieci neuronowej

Tab. 1. Relationship between the size of the grid and the number of neural network inputs

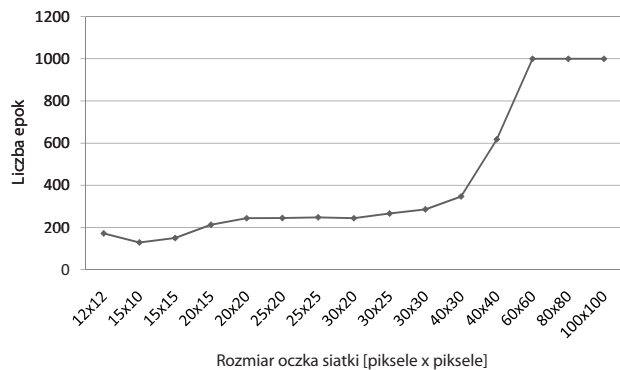
oczko siatki [px × px]	liczba wejść sieci neuronowej
12 × 12	3500
15 × 15	2240
20 × 20	1260
25 × 25	816
30 × 30	560
40 × 30	420
40 × 40	315
60 × 60	140
80 × 80	70
100 × 100	48

Po przeanalizowaniu wpływu siatki na jakość osiągniętych wyników stwierdzić można, że do rozmiaru 40 × 30 nie zaobserwowano pogorszenia się wskaźnika jakości rozpoznawania błędów, natomiast większe oczko siatki powodowało już pogarszanie się wyników. Również przy podobnym rozmiarze siatki lawinowo rośnie liczba epok trenowania potrzebnych do poprawnego nauczania sieci neuronowej. Ma to związek z utratą pewnej części istotnych informacji w procesie kompresji obrazu (rys. 13). W tym badaniu wykorzystano sieć jednowarstwową przekątnikową.

Najbardziej czuła na zmianę rozmiarów siatki okazała się jednowarstwowa sieć z liniowymi funkcjami aktywacji, natomiast najmniej czuła – sieć dwuwarstwowa (rys. 14). Wyniki przedstawiono dla sieci z 41 neuronami w pierwszej warstwie, 1 neuronie w warstwie drugiej oraz sigmoidalnymi funkcjami aktywacji (sieć dwuwarstwowa) uczoną metodą trainoss (nazwa metody w Neural Network Toolbox).


Rys. 15 pokazuje efektywność metod uczenia zaimplementowanych w Neural Network Toolbox środowiska MATLAB (dla oczka siatki 100 × 100 pikseli i funkcji aktywacji logsig w obu warstwach). Te i pozostałe badania wskazują, że najbardziej efektywną strukturą okazała się sieć dwuwarstwowa z około 40 neuronami w warstwie ukrytej z sigmoidalnymi






Rys. 13. Zależność między rozmiarem oczka siatki redukcyjnej a liczbą epok potrzebną do nauczenia sieci

Fig. 13. Relationship between the size of the grid and the number of epochs needed to teach the neural network



Rys. 14. Porównanie jakości działania sieci w zależności od architektury sieci

Fig. 14. The efficiency of neural networks versus the network architecture



Rys. 15. Porównanie jakości działania sieci w zależności, od metody uczenia dla różnej liczby neuronów w warstwie ukrytej

Fig. 15. The efficiency of neural networks versus training method for different number of neurons in hidden layer

funkcjami aktywacji. Proces uczenia przy próbie 1000 zdjęć trwał kilkanaście sekund (procesor i5, 4 GB RAM), a liczba epok nie przekraczała 100.

## 6. Podsumowanie

Opisywane stanowisko jest jedynie prototypem służącym do badań, jednak przedstawione wyniki potwierdzają słuszność zastosowanych metod i skuteczność użytych algorytmów. Rozwój stanowiska powinien polegać głównie na zastosowaniu profesjonalnej kamery przemysłowej oraz szczelnego pomieszczenia z oświetleniem gwarantującym jego równo-

mierność. Jeśli chodzi o sam proces przetwarzania obrazów, warto zaimplementować algorytmy redukcji wymiaru oraz filtracji oparte o analizę składników głównych, metody wektorów nośnych i/lub metody kernelowe. Aplikacja pozwala na diagnozowanie lub rozpoznawanie także innych elementów niż płytki drukowane. Środowisko MATLAB umożliwia bardzo szybkie prototypowanie analizowanych rozwiązań, jednak ogranicza powstałe produkty do zastosowań badawczych/edukacyjnych. W związku z tym wstępnie przetestowane aplikacje powinny zostać napisane w otwartych językach programowania (np. przy wykorzystaniu bibliotek C++ OpenCV, Fast Artificial Neural Network Library), a następnie zaimplementowane np. w procesorze sygnałowym.

## Bibliografia

1. Korbicz J., Obuchowicz A., Uciński D.: Sztuczne Sieci Neuronowe Podstawy i Zastosowania. PLJ, Warszawa 1994.
2. Osowski S.: Sieci neuronowe w ujęciu algorytmicznym. WNT, Warszawa 1996.
3. Sikora M.: Wykorzystanie sztucznych sieci neuronowych do diagnostyki optycznej poprawności produkcji płytek drukowanych. Praca inżynierska wykonana na Wydziale Elektrotechniki i Automatyki Politechniki Gdańskiej.
4. Sing-Tze Bow: Pattern Recognition and Image Processing. Marcel Dekker AG, Switzerland 2002. ■

### Utilization of neural networks in process of diagnosis of correctness of assembling the printed circuit-boards

Abstract: The paper describes research test stand that is used for optical diagnostics of correctness of assembling of printed circuit-board that moves on a tape. Optical diagnostics is carried out by camera, the images are transferred to computer PC and then to designed diagnostic system implemented in Matlab. After processing of the images they are analyzed by neural networks and the decisions about the correctness of assembling the elements on printed circuit-board are made. The whole application is designed in Matlab environment. The paper presents selected results describing researches carried out in the field of: illumination, image processing techniques, structures and parameters of neural networks and their influence on efficiency of the described system.

Keywords: diagnostics, image processing, neural networks

#### inż. Mariusz Sikora

W 2011 r. uzyskał tytuł inżyniera na Wydziale Elektrotechniki i Automatyki Politechniki Gdańskiej. Jego zainteresowania naukowe obejmują metody sztucznej inteligencji i przetwarzania sygnałów.



#### dr inż. Michał Grochowski

Adiunkt w Katedrze Inżynierii Systemów Sterowania na Wydziale Elektrotechniki i Automatyki Politechniki Gdańskiej. Jego zainteresowania naukowe obejmują metody detekcji i lokalizacji uszkodzeń, diagnostyki procesów, sterowania optymalizującego oraz inteligencji obliczeniowej.

