

Przekształcenie wskazania analogowego przyrządu pomiarowego na postać cyfrową

Converting the indication of an analog measuring instrument to a digital form

Dariusz Luśtyk
Główny Urząd Miar

W artykule przedstawiono sposób wyodrębnienia obrazu podzielnego analogowego przyrządu pomiarowego uzyskanego z kamery oraz metodę przetwarzania jego wskazania na postać cyfrową z zastosowaniem perceptronu wielowarstwowego. W pracy przedstawiono wyniki skuteczności odczytu wskazań analogowych z wykorzystaniem programu implementującego proponowaną metodę.

The article presents a method of extracting the image of an analog measuring instrument scale obtained from a camera, and the method of its processing into a digital form of an indication using a multilayer perceptron. The paper presents the results of the effectiveness of reading analog indication with the use of a program implementing the proposed method.

Słowa kluczowe: analogowy przyrząd pomiarowy, wskazanie cyfrowe, perceptron wielowarstwowy, operator Sobela

Keywords: analog measuring instrument, digital indication, multilayer perceptron, Sobel operator

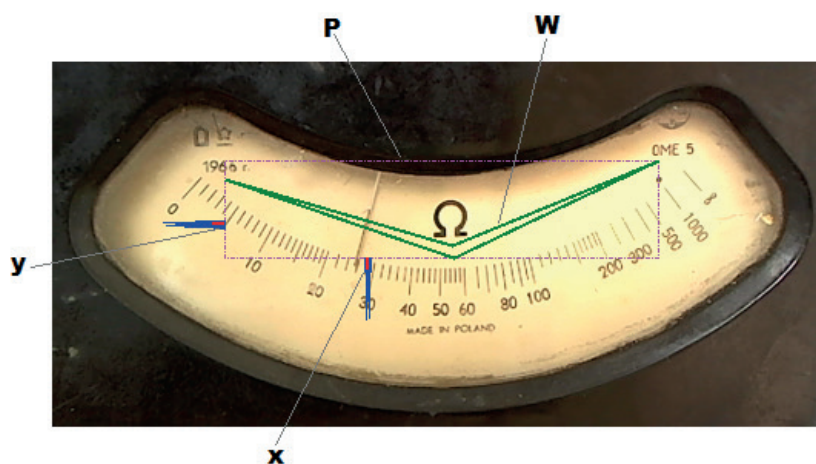
Wprowadzenie

Analogowe przyrządy pomiarowe na ogół nie umożliwiają odczytu wskazania w postaci cyfrowej. Kąt obrotu lub współrzędne wybranego punktu wskazówki przyrządu są nieliniową i nieznaną funkcją, co wynika z charakterystyki czujnika przyrządu, wzajemnego położenia przyrządu i kamery czy zniekształcenia obrazu przez kamerę.

Odczyt wskazań analogowych na stanowisku wyposażonym w kamerę i oprogramowanie możliwy jest po wyodrębnieniu obrazu podzielnego przyrządu, następnie lokalizacji wskazówki i zamianie jej pozycji na postać cyfrową. W rozwiązaniu proponuje się wykorzystanie sieci neuronowej typu *wielowarstwowy perceptron*, uczącej się na ograniczonej liczbie wskazań analogowych.

Wyodrębnienie obrazu podzielnego

Obraz przyrządu, podlegający analizie, ograniczony jest do niezbędnego obszaru podzielnego, obejmującego założony zakres położenia wskazówki. Na rys. 1 przedstawiono obszar analizy graficznej ograniczony do wielokąta *W*.



Rys. 1. Obszar analizy graficznej wyznaczenia położenia wskazówki na obrazie podzielnego

W ogólnym przypadku wielokąt *W* może być nieregularny, niewypukły, z liczbą krawędzi zależną od kształtu podzielnego i występujących na niej elementów graficznych. Istotne jest, aby wewnątrz wielokąta *W* było jednorodne, co do koloru, tło z widoczną wskazówką przyrządu pomiarowego lub jej fragmentem, z pominięciem symboli graficznych występujących na podzielnym.

Początek układu współrzędnych, w którym określa się położenie wskazówki, znajduje się w lewym dolnym rogu prostokąta P , opisanego na wielokącie W .

Lokalizacja wskazówki przyrządu

Wskazanie reprezentuje położenie wskazówki, która kontrastuje na tle wyodrębnionego obrazu podzielnicy. Analiza oparta jest na badaniu gradientów luminacji w otoczeniu wszystkich pikseli zawartych w wielokącie W . Umożliwia identyfikację tych, które rejestrują największe zmiany luminacji, a na wyodrębnionym obrazie powinny dotyczyć krawędzi wskazówki. W implementacji programowej do wykrywania krawędzi wykorzystano operator Sobela.

W celu określenia pozycji wskazówki w układzie X - Y istotne są przyrosty luminacji wewnątrz wielokąta W . W związku z tym składowe tablice gradientów luminacji są zerowane dla pikseli, które znajdują się poza obszarem W . Sprawdzenie przynależności każdego piksela, występującego w prostokącie P , do wnętrza wielokąta W realizuje odrębna funkcja, która bada liczbę punktów wspólnych półprostej, zaczynającej się w pikselu i poprowadzonej w dowolnym kierunku, z bokami wielokąta W . Nieparzysta liczba punktów wspólnych świadczy o przynależności piksela do wnętrza W .


Pozycja wskazówki obliczana jest na podstawie sumy gradientów luminacji (SGL) pikseli zawartych wewnątrz wielokąta W na kierunkach prostopadłych do osi X i Y . Współrzędne występowania maksimum SGL na osiach X , Y określają pozycję wskazówki. Charakterystyki SGL, przedstawione na rys. 1 w kolorze niebieskim, osiągają największą wartość na odciętej i rzędnej w miejscach oznaczonych czerwonymi kreskami. W przyrządzie, którego wskazówka zmienia swoją pozycję w pionie, istotna jest SGL w kierunku osi rzędnych.

W obrazach występuje niepożądany efekt powstania niezerowego gradientu luminacji wewnątrz wielokąta W , poza krawędziami wskazówki, spowodowany zmiennym natężeniem i kątem padania światła na podzielnicy przez przezroczysty wizjer. W związku z tym, wielokąt W powinien być tak usytuowany i ukształtowany, aby obejmował założony zakres zmian pozycji wskazówki i jednocześnie względnie małą liczbę pikseli w wielokącie W . W implementacji programowej algorytm SGL uwzględnia piksele, które reprezentują przyrost luminacji na poziomie wyższym od określonej wartości granicznej.

Współrzędne pozycji wskazówki są średnią arytmetyczną kilku ostatnich pozycji maksimum SGL na osiach X i Y , obliczanych z częstotliwością kilkunastu na sekundę.

Przetwarzanie pozycji wskazówki na postać cyfrową

Pozycja wskazówki przyrządu jest argumentem nieliniowej i nieznannej funkcji. W celu określenia postaci tej funkcji, na podstawie ograniczonego zbioru wskazań analogowych, wykorzystano sieć neuronową typu wielowarstwowy perceptron, schematycznie przedstawioną na rys. 2.



Rys. 2. Wielowarstwowy perceptron

Na potrzeby aproksymacji wskazania analogowego, zależnego od położenia wskazówki, zbudowano dwuwarstwowy perceptron, w którym pierwsza warstwa zawiera kilkanaście neuronów, a druga tylko jeden. Do sieci dochodzą dwa sygnały x i y , a wychodzi jeden z .

Sygnały wyjściowe neuronów warstwy poprzedniej są sygnałami wejściowymi wszystkich neuronów warstwy następnej. Położenie wskazówki określają współrzędne x , y występowania maksimum SGL – są to sygnały wejściowe sieci. Jeśli podczas pomiaru kąt obrotu wskazówki nie przekracza 180° , wystarczy jeden sygnał wejściowy sieci x lub y .


Każdy neuron realizuje przetwarzanie oparte na sigmoidalnej unipolarnej funkcji aktywacji $s(u)$, której argumentem u jest iloczyn skalarny wag synaptycznych i sygnałów wejściowych, pomnożony przez współczynnik kształtu funkcji:

$$s(u) = \frac{1}{1 + e^{-u}} \quad (1)$$

$$u = \beta \left[\left(\sum_{i=1}^N w_i x_i \right) + w_0 \right] \quad (2)$$

gdzie: β – współczynnik kształtu funkcji, w_i – i -ta waga synaptyczna neuronu, N – liczba sygnałów wejściowych neuronu, x_i – i ty sygnał wejściowy neuronu, w_0 – waga synaptyczna dodatkowego sygnału wejściowego o wartości 1.

Przebiegi sigmoidalnej unipolarnej funkcji aktywacji dla wybranych współczynników β przedstawia rys. 3.



Rys. 3. Sigmoidalna unipolarna funkcja dla wybranych współczynników β

Proces uczenia sieci realizuje algorytm propagacji wstecznej błędu (back propagation), szeroko opisywany w literaturze sztucznych sieci neuronowych. Uczenie oznacza sekwencyjną modyfikację wag synaptycznych podczas wielokrotnej prezentacji wszystkich przykładów uczących – danych wejściowych i wyjściowych. W uczeniu zastosowano model z tzw. momentem μ – składową w zakresie wartości od 0 do 1 w formule modyfikacji wag, która ułatwia osiągnięcie najmniejszego błędu sieci o określonej architekturze, funkcji aktywacji i danych uczących. Trening poprzedza inicjalizacja wag neuronów przy użyciu rozkładu Bottou.

Dane treningowe podlegają skalowaniu i translacji, ponieważ funkcje aktywacji, z racji swojego charakteru, nie osiągają wartości maksymalnych. Dla sigmoidalnej unipolarnej funkcji aktywacji, opisanej formułami (1) i (2), można przyjąć, dla sygnału wyjściowego sieci, zakres wartości od 0,1 do 0,9.

Tempo treningu zależy od współczynnika szybkości uczenia η przyjmowanym w zakresie od 0,001 do 0,05, przy czym mniejsze wartości wymagają większej liczby prezentacji przykładów uczących, wydłużając czas uczenia przy wyższym prawdopodobieństwie osiągnięcia minimum błędu.

Trening przeprowadzany jest kilkakrotnie dla ustalonych parametrów sieci. Losowe wartości początkowe wag mogą prowadzić do osiągnięcia różnych błędów sieci. W celu uzyskania minimum błędu sieci dobiera się liczby neuronów i współczynniki β , η , μ , a także parametry skalowania i translacji sygnałów wejściowych i wyjściowych.


Uczenie powtarzane jest tak długo, aż osiągnięty zostanie dostatecznie mały błąd sieci.

W sytuacji, gdy dla różnych parametrów, sieć nie rozpoznaje sygnałów wejściowych z dostatecznie małym błędem, należy rozważyć przygotowanie bardziej reprezentatywnych danych treningowych lub zwiększyć ich liczbę. Trening jest zakończony, gdy średniokwadratowy błąd sieci, uzyskany na różnicach wartości sygnałów wyjściowych osiągniętych i wyjściowych oczekiwanych dla wszystkich przykładów uczących, jest mniejszy lub równy wartości akceptowalnego błędu. Efektem treningu są wyznaczone wagi neuronów.

Nauczona sieć reprezentuje przetwornik pozycji wskazówki przyrządu w układzie X-Y na cyfrową postać wskazania, w zastosowaniu tutaj opisywanym. Wartość wskazania, jako efekt rozpoznawania przez sieć sygnałów wejściowych, otrzymywana jest po skalowaniu i translacji odwrotnej sygnału wyjściowego.

Implementacja metody

Metoda cyfrowego odczytu wskazania analogowego zrealizowana została w programie AnnRiami, którego działanie obrazują diagramy przepływu danych DFD. Rys. 4 przedstawia diagram kontekstu rozwiązania, w którym proces „Przekształcenie wskazania analogowego na postać cyfrową” odpowiedzialny jest za określenie krawędzi wielokąta W , filtra kolorów, parametrów perceptronu, jego trening oraz odczyty i rejestrację w postaci cyfrowej wskazania analogowego.




Rys. 4. Diagram kontekstu rozwiązania

Proces wymienia dane z obiektami:

- „Użytkownik” – osoba sterująca procesem adaptacji perceptronu i inicjująca automatyczne odczyty wskazań,
 - „Kamera” – źródło obrazu podzielnego przyrzędu pomiarowego,
 - „Wskazanie cyfrowe” – postać cyfrowa wskazania.
- W diagramie kontekstu występują przepływy danych:
- „Obraz” – bitmapa obrazu z kamery, sekwencyjnie odświeżana, prezentowana w oknie aplikacji,
 - „Błąd sieci” – średniokwadratowy błąd perceptronu określony różnicą sygnałów wyjściowych otrzymanych i oczekiwanych, obliczony dla wszystkich przykładów treningowych,
 - „Ustawienia” obejmują:

- krawędzie wielokąta W ograniczającego obszar analizy obrazu podzielnego,
- składowe w kanałach: czerwonym, zielonym, niebieskim filtra kolorów obrazu,
- liczby sygnałów wejściowych, warstw i neuronów w warstwach,
- współczynniki: $\beta, \eta, \mu,$
- parametry skalowania i translacji sygnałów wejściowych i wyjściowych sieci,
- przykłady treningowe – jeden przykład zawiera dwie współrzędne pozycji wskazówki i wartość wskazania.

Rys. 5 przedstawia dekompozycję DFD procesu „Przekształcenie wskazania analogowego na postać cyfrową”, który realizuje funkcję przetwarzania obrazu, treningu i eksploatacji sieci.



Rys. 5. Diagram dekompozycji procesu „Przekształcenie wskazania analogowego na postać cyfrową”

Proces „Wyznaczanie położenia wskazówki” realizuje filtrowanie kolorów zgodnych z kolorem wskazówki i określa pozycję wskazówki na podstawie obrazu ograniczonego do wielokąta W .

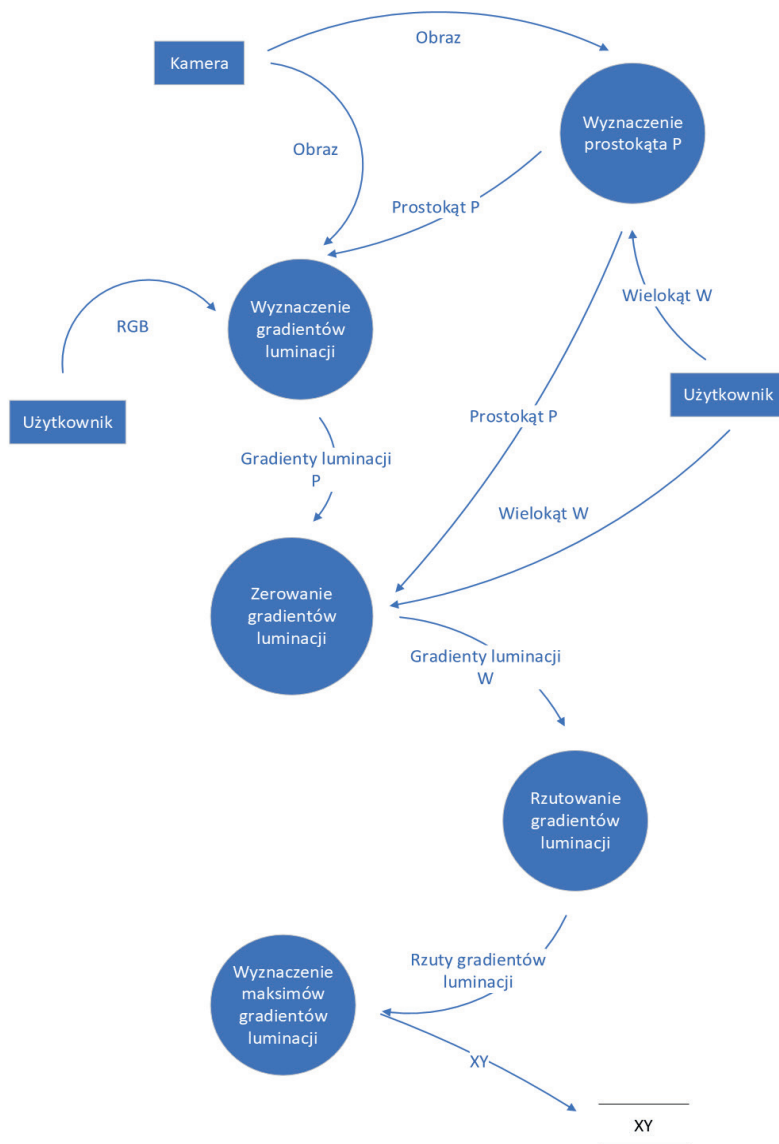
Proces „Skalowanie i Translacja” wykonuje skalowanie i translację sygnałów wejściowych i wyjściowych na potrzeby uczenia w procesie „Trening” oraz skalowanie i translację sygnałów wejściowych w procesie „Rozpoznanie”.

Proces „Trening” realizuje uczenie wielowarstwowego perceptronu metodą propagacji wstecznej błędów, z zastosowaniem współczynnika μ w formule modyfikacji wag synaptycznych neuronów. Po każdej prezentacji wszystkich przykładów uczących obliczany jest i prezentowany na wykresie średniokwadratowy błąd sieci.

„Sygnał rozpoznany” jest aproksymacją funkcji zadanej w postaci przykładów uczących podczas treningu sieci, podlega przetworzeniu w procesie „Skalowanie i translacja odwrotna” na „Wskazanie cyfrowe” – wartość odczytu analogowego przedstawionego cyfrowo.

Wymiana danych następuje w przepływach wcześniej zdefiniowanych i niżej wymienionych:

- „Wielokąt, RGB” – współrzędne wielokąta W oraz trzy składowe filtra koloru wskazówki, każdy w zakresie wartości od 0 do 255 w kanałach: czerwonym, zielonym, niebieskim,
- „XY” – położenie wskazówki przyrządu w układzie X-Y z początkiem w lewej dolnej krawędzi prostokąta P ,
- „Skala, translacja, XYZ” – minimalne i maksymalne wartości sygnałów wejściowych i wyjściowych sieci,



Rys. 6. Diagram wyznaczenia położenia wskazówki

uwzględniające cechy funkcji aktywacji neuronów oraz zakres pomiaru,

- „XYZt” – dane treningowe (sygnały wejściowe i wyjściowy sieci) po skalowaniu i translacji,
- „Wagi synaptyczne” – wagi synaptyczne neuronów sieci,
- „XYs” – sygnał wejściowy sieci po skalowaniu i translacji,
- „Skala, translacja Z” – minimalne i maksymalne wartości sygnałów wyjściowych sieci,
- „Sygnał rozpoznany” – wartość rozpoznana przez sieć.

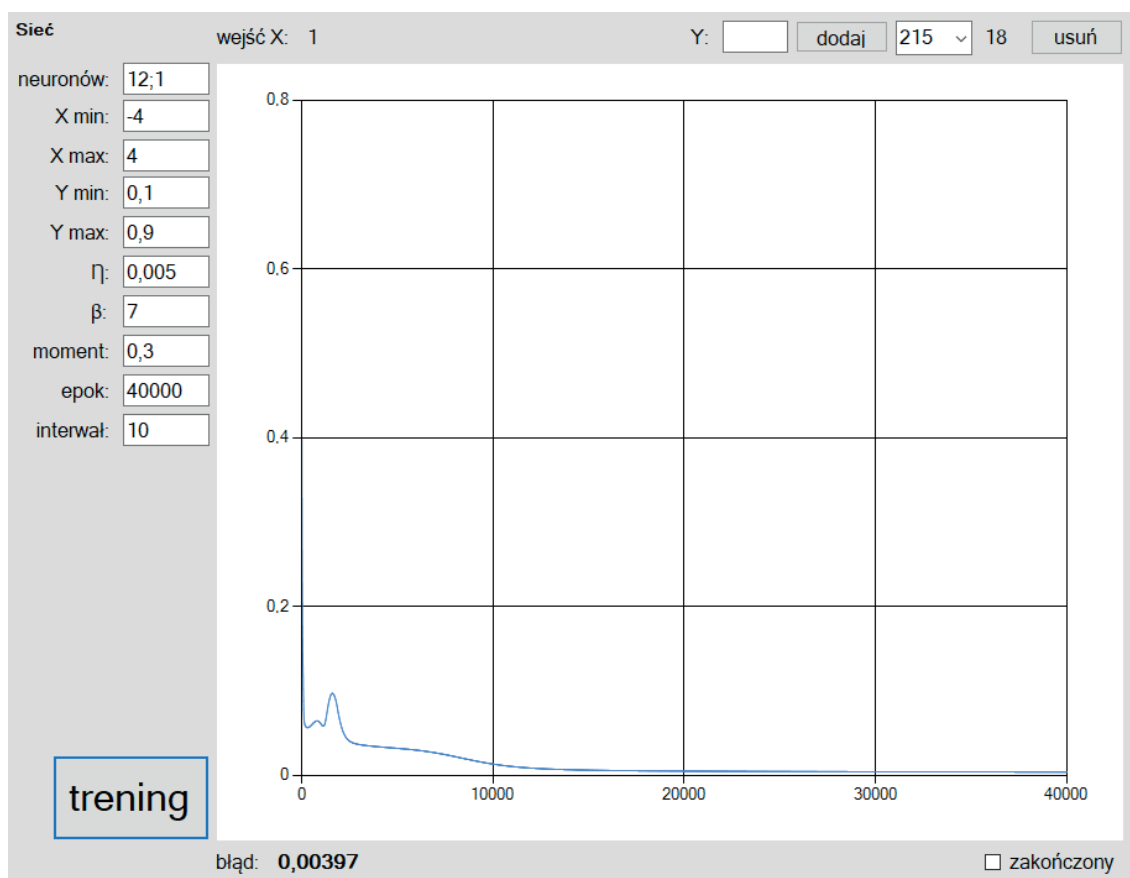
Proces „Wyznaczenie położenia wskazówki” dekomponuje się na procesy przedstawione w diagramie na rys. 6.

Na podstawie obrazu z kamery użytkownik określa liczbę i współrzędne węzłów wielokąta W , które w procesie „Wyznaczenie prostokąta P ” służą do określenia pozycji i rozmiarów prostokąta P opisanego na W . W procesie „Wyznaczenie gradientów luminacji” następuje generacja tablicy „Gradienty luminacji P ” w obszarze prostokąta P z użyciem operatora Sobela na obrazie

poddanym filtracji kolorów, zgodnym z kolorem wskazówki i zdefiniowanym przepływem „RGB”. Proces „Zerowanie gradientów luminacji”, na podstawie współrzędnych krawędzi prostokąta P i wielokąta W , przeprowadza zerowanie składowych tablicy „Gradienty luminacji P ” odpowiadających pikselom, które nie zawierają się w wielokącie W . W efekcie powstaje tablica „Gradienty luminacji W ”.

Proces „Rzutowanie gradientów luminacji” z wykorzystaniem tablicy „Gradienty luminacji W ” wykonuje obliczenia charakterystyk SGL na kierunkach X i Y , przy czym uwzględniane są tylko te piksele, które występują w wielokącie W i reprezentują przyrost luminacji większy od założonej granicznej wartości. Położenie wskazówki w układzie współrzędnych określają maksima charakterystyk SGL, określonych w procesie „Wyznaczenie maksimów gradientów luminacji”. W diagramie występują przepływy danych:

- „Wielokąt W ” – współrzędne krawędzi wielokąta W ,
- „Prostokąt P ” – współrzędne krawędzi prostokąta P ,



■ Rys. 7. Przebieg błędu sieci w funkcji prezentacji przykładów uczących

- „RGB” – trzy składowe koloru w zakresie wartości od 0 do 255 w kanałach: czerwonym, zielonym, niebieskim,
- „Gradienty luminacji P” – tablica dwuwymiarowa, odpowiadająca rozmiarem liczbom pikseli w pionie i poziomie prostokąta P ,
- „Gradienty luminacji W” – tablica dwuwymiarowa, odpowiadająca rozmiarem liczbom pikseli w pionie i poziomie prostokąta P , zawierająca niezerowe gradienty luminacji tylko tych pikseli, które zawarte są wewnątrz wielokąta W ,
- „Rzuty gradientów luminacji” – dwie tablice wartości, reprezentujące charakterystyki rzutów gradientów luminacji na osie X i Y ,
- „XY” – współrzędne x i y występowania maksymalnych wartości charakterystyk rzutów gradientów luminacji, stanowiących pozycję wskazówki przyrządu.

Skuteczność odczytów analogowych

W ramach oceny możliwości wykorzystania metody cyfrowego odczytu wskazań analogowych przeprowadzono porównanie wyników wskazań, uzyskanych analogowym omomierzem Mera (podzielnia na rys. 1) o klasie dokładności 1,5, z wynikami wskazań omomierza cyfrowego Vellman DVM892 o klasie dokładności 1,2. Program implementujący metodę współpracował z kamerą internetową Logitech HD 1080p.

Dane treningowe sieci, w których każdy przykład stanowił dwie wartości: sygnał wejściowy x , otrzymany z przekształcenia obrazu wskazań omomierza analogowego i dla tej samej rezystancji oraz sygnał wyjściowy z , jako wskazanie omomierza cyfrowego. W zakresie od 3Ω do 217Ω wykonano kilkanaście odczytów wskazań różnych rezystancji, stanowiących dane treningowe sieci zbudowanej z dwóch warstw neuronów. Pierwsza warstwa zawierała 12 neuronów, druga 1 neuron. Sygnały wejściowe podlegały skalowaniu i translacji w zakresie od $-4,0$ do $4,0$, a wyjściowe w zakresie od $0,1$ do $0,9$ (współczynniki: $\eta = 0,005$, $\beta = 7$, $\mu = 0,3$). Trening przeprowadzono kilka razy, każdorazowo użyto 40 000 prezentacji przykładów uczących, uzyskując najmniejszy błąd przetwarzania sieci o wartości 0,004. Przebieg błędu sieci w funkcji prezentacji przykładów uczących przedstawia rys. 7.

Po treningu przeprowadzono serię odczytów rezystancji omomierzem cyfrowym i analogowym z wykorzystaniem programu AnnRiami. W tab. 1. w kolumnie R_c zamieszczono wskazanie przyrządu cyfrowego, w kolumnie R_p wskazanie odczytane przez program, a w ostatniej kolumnie ich różnicę.

Tab. 1. Odczyt rezystancji omomierzem cyfrowym i przy użyciu programu AnnRiami

L.p.	R_c	R_p	$R_c - R_p$
1	3	4	-1
2	5	6	-1
3	13	12	1
4	14	13	1
5	18	19	-1
6	23	23	0
7	25	25	0
8	28	29	0
9	31	30	1
10	40	39	1
11	43	42	1
12	48	48	0
13	52	52	0
14	58	57	1
15	66	66	0
16	74	74	0
17	83	83	0
18	96	95	1
19	102	102	0
20	114	113	1
21	146	144	2
22	169	166	3
23	200	196	4
24	217	211	6

Średnia kwadratowa różnic wartości uzyskanych w odczycie omomierzem cyfrowym i przy użyciu programu wynosi 1,57. Największe wartości $R_c - R_p$ występują w pobliżu górnej granicy zakresu pomiaru, gdzie określona zmiana kąta położenia wskazówki wskazuje znaczące przyrosty wartości względem zmian kąta położenia wskazówki w pobliżu dolnej granicy zakresu.

Podsumowanie

Przekształcenie wskazań analogowych na cyfrową postać może przyczynić się do automatyzacji stanowisk pomiarowych, ponieważ redukuje czas odczytu, eliminuje wpływ człowieka na jego błąd i umożliwia automatyczne rejestrowanie wartości zmierzonych lub udostępnianie ich innym procesom.

Zaproponowana metoda odwołuje się do techniki przetwarzania opartej na zastosowaniu sztucznej sieci neuronowej. Można rozważać wykorzystanie rozwiązań sztucznej inteligencji w sterowaniu procesami na stanowiskach laboratoryjnych, gdzie istotna jest informacja o położeniu, kształcie, kolorze czy teksturze na obrazie.



Dariusz Luśtyk

Pracuje w Głównym Urzędzie Miar, w Laboratorium Wsparcia Przemysłu, w Pracowni Wsparcia Nowych Technologii. Ukończył jako mgr inż. Politechnikę Warszawską, Wydział Mechaniczny Energetyki i Lotnictwa, ze specjalnością lotnictwo. W Głównym Urzędzie Miar od 2012 r. realizuje zadania związane z tworzeniem oprogramowania i projektowaniem elementów konstrukcji stanowisk laboratoryjnych.

Bibliografia

- [1] Tadeusiewicz R., Sieci neuronowe, Akademicka Oficyna Wydaw. RM, 1993.
- [2] Timoty Masters, Sieci neuronowe w praktyce, WNT Warszawa 1996.
- [3] Strona internetowa (<http://home.agh.edu.pl/~horzyk/lectures/biocyb/BIOCYBSieciNeuronowe.pdf>)
- [4] Strona internetowa (https://www.cri.agh.edu.pl/uczelnia/tad/inteligencja_obliczeniowa/08%20-%20Uczenie%20-%20pogl%c4%85dowe.pdf)
- [5] Strona internetowa (http://wmii.uwm.edu.pl/~mario/jsmallfib_top/upload/wdgm/zestaw10.pdf)
- [6] Strona internetowa (<http://books.icse.us.edu.pl/runestone/static/ai/SztuczneSieciNeuronowe/PodstawoweModeleSieciNeuronowych.html>)
- [7] Strona internetowa (<http://users.pja.edu.pl/~denisjuk/pko/wyklady/07-segmentation.pdf>)