Wydział Transportu Politechniki Śląskiej

Metoda automatycznej oceny żeliwa stosowanego na części maszyn, z wykorzystaniem sieci neuronowych

Rozprawa doktorska - streszczenie

Mgr inż. Rafał Wąsik

Promotor: prof. zw. dr hab. inż. Jan Piecha

Katowice 2010

Wprowadzenie

Żeliwa są materiałem stosowanym do budowy elementów maszyn o różnych właściwościach mechanicznych i użytkowych. Są one również powszechnie stosowane jako materiał na części i elementy maszyn transportowych. W niniejszej pracy przedstawiono nowe podejście do elementów oceny parametrów żeliw z wykorzystaniem metod komputerowego systemu wspomagania wnioskowania.

Do celów diagnozowania wstępnego opracowano elementy oceny regułowej, która wspomaga proces treningu sieci neuronowej wykorzystanej do budowy systemu automatycznego wnioskowania. Na etapie początkowym proces diagnozy wspomagany jest klasyfikatorami szczegółowymi (dla poszczególnych wydzieleń grafitu), aby sieć neuronowa była trenowana prawidłowo sklasyfikowanymi danymi wejściowymi. Na końcu procesu prawidłowego treningu, sieć neuronowa przejmuje proces decyzyjny; samodzielnie sklasyfikuje badaną próbkę żeliwa.

Etap początkowy wnioskowania realizowany jest na podstawie reguł opisujących zbiorem cech geometrycznych obrazu mikroskopowego wydzieleń grafitu. Miary regułowe są elementem niezbędnym do przekazania na wejścia sieci neuronowej właściwej decyzji. Jest to proces treningu sieci pod tzw. nadzorem klasyfikatora (eksperta) regułowego.

Parametry żeliwa można opisać wartościami jego charakterystycznych elementów składowych, zwanych deskryptorami miar graficznych wydzieleń grafitu w żeliwie. Są one elementami miar jakości żeliwa, które można ocenić po dokonaniu ekstrakcji elementów istotnych dla próbek pomiarowych.

Celem badań była ocena możliwości opracowania metod i narzędzi wyodrębniania cech charakterystycznych wydzieleń grafitu w żeliwie. Ważnym elementem tej oceny była również kwestia istnienia miar ilościowych dla tych cech, występujących w obrazie próbki materiału. Te dwa elementy miar są nieodzowne dla opracowania metod automatyzacji procesu nadzorowanego treningu modułu wnioskowania.

Ekstrakcję cech wyłącznych, charakterystycznych dla badanej klasy (próbki), można zrealizować wykorzystując zbiór reguł wyróżniających każdą z tych klas od cech klas innych. Pierwotną ocenę struktury żeliwa przeprowadza ekspert, na podstawie zdjęć mikrostruktury wewnętrznej materiału, analizując istotne elementy próbki. Jego wstępna diagnoza polega na ocenie jakościowej kształtu oraz rozmieszczenia wydzieleń grafitu, w obrazie mikroskopowym badanej próbki. Wiele z żeliw zawiera elementy wspólne, identyczne w każdej z klas. Postawienie ostatecznej diagnozy musi zatem zostać oparte o cechy wyróżniające każdą z nich.

Sieci neuronowe są narzędziem oceny, często stosowanym w różnych dziedzinach nauki, także w inżynierii materiałowej, jako alternatywne rozwiązanie problemów diagnozowania struktury metalograficznej materiału. Wykorzystanie sieci neuronowej pozwala uniknąć poszukiwań

skomplikowanych, często nieznanych zależności modelu matematycznego, umożliwiającego opis elementów charakterystycznych diagnozowanego obiektu.

Wyniki przedstawionych badań miały na celu definicję elementów złożonego procesu wyboru ciągów uczących sieć oraz przeprowadzenia jej treningu. Dobrze wytrenowana sieć neuronowa może określać klasy badanych próbek materiału; w szczególności jej przyporządkowanie do określonego gatunku i pośrednio określenia jego własności mechanicznych.

Opracowane metody mają znacznie ogólniejszy charakter, choć w pracy przedstawiono badania przeprowadzone na przykładowych trzech klasach próbek żeliwa - sferoidalnego, wermikularnego lub szarego. Miary klasyfikacji dotyczą oceny kształtu i rozmieszczenia wydzieleń grafitu na materiale zdjęcia mikroskopowego próbki żeliwa. Zgodnie z definicjami wzorców opisanych Polskimi Normami. Do budowy modułu automatycznej oceny wydzieleń grafitu w żeliwie wykorzystano deskryptory cech geometrycznych wydzieleń grafitu. Ich cechy charakterystyczne określane są za pomocą współczynników kształtu. Na tej podstawie opracowano procedury numerycznej klasyfikacji obiektów oceny.

Metoda automatycznego wnioskowania

Sieci neuronowe są uogólnionym modelem automatu iteracyjnego, który pozwala zamodelować cechy obiektu, trudne lub niemożliwe do bezpośredniego opisu matematycznego, z uwagi na brak formuł matematycznych lub zapis analityczny jest bardzo trudny. Możliwość odwzorowania różnych, także nieliniowych zależności pomiędzy pewnymi sygnałami wejściowymi a wybranymi sygnałami wyjściowymi, równoległe przetwarzanie informacji, zdolność uczenia się oraz filtracja błędów to istotne cechy sieci neuronowych.

Działanie i trening sieci neuronowej

Działanie sieci neuronowej polega na wyznaczaniu wektora sygnałów wyjściowych, na podstawie wektora sygnałów wejściowych. Dla każdej warstwy, począwszy od pierwszej, obliczane są wartości sygnałów wyjściowych części liniowej neuronu, a następnie na ich podstawie wartości wektorów sygnałów wyjściowych, części nieliniowej neuronu, które dalej stają się wejściami dla kolejnej warstwy sieci. W procesie uczenia (treningu) sieci neuronowej następuje modyfikacja jej parametrów (wag).

Podstawową cechą sieci neuronowej jest jej zdolność do uogólniania, tzn. generowania właściwego rozwiązania dla danych, które nie należały do ciągu uczącego sieć.

Ocena przydatności żeliwa do zastosowań w przemyśle motoryzacyjnym, dokonywana jest w oparciu o odpowiednie normy.

W niniejszej pracy zaproponowano wykorzystanie sztucznych sieci neuronowych jako narzędzia automatycznej klasyfikacji cech charakterystycznych badanego obiektu; ocenę przydatności żeliwa na elementy maszyn transportowych. Poniżej sformułowano cel i tezę niniejszej pracy.

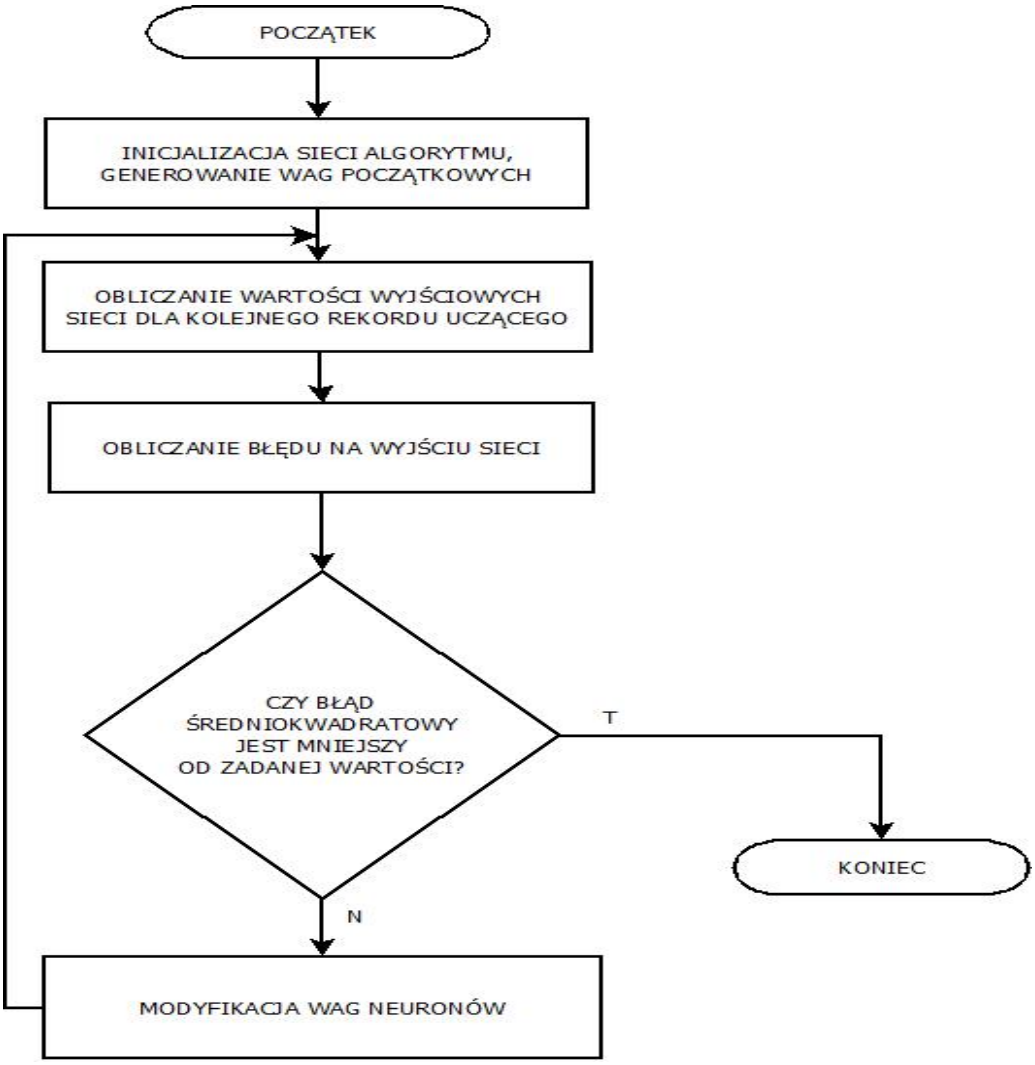

Schemat uczenia sieci neuronowej

Cel pracy

Celem rozprawy jest opracowanie metod ekstrakcji cech charakterystycznych próbek żeliwa, z wydzieleniami grafitu oraz przedstawienie metod skutecznego treningu sieci neuronowej pod nadzorem (dla systemu automatycznego wspomagania diagnozy). Do uczenia sieci neuronowej pod nadzorem, wykorzystane zostaną metody regułowego opisu cech charakterystycznych żeliwa, stosowanego do produkcji elementów maszyn transportowych.

Teza pracy

Automatyzacja procesu oceny jakościowej oraz ilościowej rodzaju wydzieleń grafitu w żeliwie jest możliwa na podstawie decyzji sieci neuronowej, wytrenowanej pod nadzorem regułowych klasyfikatorów cech charakterystycznych wydzieleń grafitu w próbkach żeliw. Opracowanie miar numerycznych dla cech charakterystycznych wydzieleń grafitu w żeliwie,

umożliwi zwielokrotnienie liczby danych wejściowych dla skutecznego wytrenowania sieci neuronowej.

Ocena przydatności opracowanego modułu automatycznego wnioskowania z zastosowaniem sieci neuronowej, została dokonana na podstawie wymagań zdefiniowanych obowiązującymi normami, uzupełnionych zadanymi wymaganiami użytkownika systemu.

Graficzne deskryptory wydzieleń grafitu

Wykorzystanie reprezentacji obrazowej struktury mikroskopowej żeliwa, jako zbioru danych wejściowych modelu automatycznego wnioskowania, nie było dotąd stosowane. Podstawowym problemem implementacyjnym jest duża liczba elementów opisujących obraz żeliwa.

Pełny obraz mikroskopowy próbki zawiera szereg nieistotnych elementów opisowych, bez znaczenia dla prawidłowej diagnozy. Dla uproszczenia zapisu danych pomiarowych oraz ekstrakcji danych istotnych procesu diagnozowania zastosowano wstępne przetwarzanie przesiewowe źródła informacji obrazowej:

- odfiltrowane zostaje tło obrazu, z którego usunięte zostają elementy grafitu o zbyt małym wymiarze, jako nieistotne dla właściwości żeliwa i trudne do klasyfikacji w systemie wnioskowania,
- ocenie podlegają wzorniki (deskryptory) podstawowe według ustalonych miar dla elementów wydzieleń,
- ocenie podlega stopień i równomierność wypełnienia próbki elementami grafitu,
- odrzucone zostają próbki, których dowolne miary wydzieleń przekraczają dopuszczalne normy.

Przekształcenia obrazu struktury wewnętrznej żeliwa

Obraz mikroskopowy klasyfikowanej próbki żeliwa zawiera:

- zbiór charakterystycznych elementów klasyfikacji,
- teksturę.

Analizę cyfrowego widma obiektów przeprowadza się w oparciu o kilka klasycznych metod przetwarzania obrazów, jak:

- filtracja obrazu według założonego poziomu progowego, której celem jest usunięcie zakłóceń obrazu, wyostrzenie krawędzi obiektów, zwiększenie kontrastu obrazu itp.,
- binaryzacja obrazu, czyli zmiana jego atrybutów barw na dwukolorowe zwykle czarno-białe,
- operacje morfologiczne, np. erozja – powodująca wyeliminowanie obiektów o założonym rozmiarze,
- ścienianie lub szkieletyzacja obrazu, które prowadzą do pokazania konturów lub "szkieletów" obiektów.

Po wstępnym przetworzeniu obrazu poddajemy analizuje cechy obiektów pozostałych na obrazie.

Przekształcenia morfologiczne

Przekształcenia morfologiczne to jedne z najistotniejszych operacji w komputerowej analizie obrazu. Odpowiednio kombinowane w zestawy pozwalają na najbardziej złożone operacje, związane z analizą kształtu elementów obrazu, ich wzajemnego położenia oraz umożliwiają złożone procesy symulacji.

Podstawowe przekształcenia morfologiczne są punktem wyjściowym do tworzenia bardziej złożonych operacji, związanych z analizą kształtu obiektów, oraz ich wzajemnego rozmieszczenia.

Przekształcenie morfologiczne polega na:

- Przyłożeniu centralnego punktu kolejno do wszystkich punktów obrazu;
- Sprawdzeniu czy lokalna konfiguracja punktów odpowiada układowi zapisanemu w elemencie strukturalnym (najczęściej na siatce elementów obrazu w postaci kwadratowej ew. heksagonalnej);
- Wykonaniu, w przypadku zgodności konfiguracji punktów, operacji określonej dla danego przekształcenia.
- Przekształcenia morfologiczne ingerują (zmieniają) tylko tę część punktów obrazu, których otoczenie jest zgodne z elementem strukturalnym, co pozwala na szczególnie dokładne planowanie przekształceń.

Wykonywano przekształcenia morfologiczne takie jak m.in.: erozja, dylatacja, otwarcie i zamknięcie, otwarcie i zamknięcie właściwe, ścienianie.

Dobrze wytrenowana sieć neuronowa spełniać może rolę szybkiego automatu wnioskującego o jakości badanych próbek żeliwa. Zdefiniowanie odpowiednich miar deskryptorów pozwala na ich użycie w formie elementów wzorcowych, stosowanych jako filtr do skanowania bieżących rekordów pomiarowych na obecność charakterystycznych danych w rekordzie.

Rekordy danych

Dysponując opisem cech można je również użyć do sztucznego generowania rekordów danych, zgodnych z przyjętymi elementami charakterystycznymi produktu trafionego.

Rekordy sztuczne (wirtualne) winny zawierać elementy o wyodrębnionych cechach występujące w różnych proporcjach i różnej dyslokacji w rekordzie opisu próbki.

Tak wirtualnie uzyskane dane można wykorzystać do:

- empirycznego doboru sieci neuronowej, najlepiej wnioskującej dla badanego rodzaju próbek,
- przeprowadzenia weryfikacji metod treningu sieci, choć uzyskanych sztucznie, jednak o cechach zgodnych z modelem rekordu rzeczywistego.

W procedurach generacji danych wirtualnych można ustawiać:

- udział poszczególnych elementów składowych,
- współczynniki skali wydzieleń.

Uzyskujemy w ten sposób dowolną liczbę kombinacji klas wydzieleń charakterystycznych grafitu. Danymi wejściowymi sieci neuronowej są parametry geometryczne wydzieleń grafitu.

Metoda określania rodzaju wydzieleń grafitu

Dla wyodrębnienia obiektów próbki, będących pojedynczym wydzieleniem grafitu, z pola widzenia mikroskopu, można zastosować jedną z wielu metod rozpoznawania obrazów. Ze względu na wymagany, krótki czas obliczeń, przy występowaniu wielu wydzieleń w badanym obrazie, poszukujemy metod o jak najmniejszej złożoności obliczeniowej. Obraz wejściowy poddawany jest wstępnym przekształceniom, w celu wyeliminowania elementów nieistotnych, zakłóceń wynikających z niedoskonałości przyrządów pomiarowych, itp. Analiza obrazu może być przeprowadzana z zastosowaniem programów implementowanych na standardowych procesorach obliczeń numerycznych (programowo) lub za pomocą dedykowanych procesorów układowych, Obie kategorie rozwiązań cechuje różna szybkość obliczeń a zatem obowiązują inne metody przygotowania materiału wejściowego.

Segmentacja obrazu

Jest to operacja pozwalająca wydzielić z obrazu obszary spełniające wymagania kryterium jednorodności próbki, którymi mogą być m.in. poziom barw, poziom jasności, czy kształt analizowanego obiektu.

Segmentacja służy do odseparowania od siebie obiektów wchodzących w skład obrazu oraz wyodrębnienia tła obrazu. Najbardziej znane techniki tej operacji to segmentacja przez podział obszaru, przez rozrost obszaru, metodą wykrywania krawędzi – granic segmentu oraz segmentacja statyczna.

Ekstrakcja mapy krawędzi

Zaproponowana w pracy metoda wykorzystuje dane uzyskane na podstawie filtracji obrazu, której efektem jest mapa krawędzi obrazu źródłowego (zdjęcia mikroskopowego struktury żeliwa).

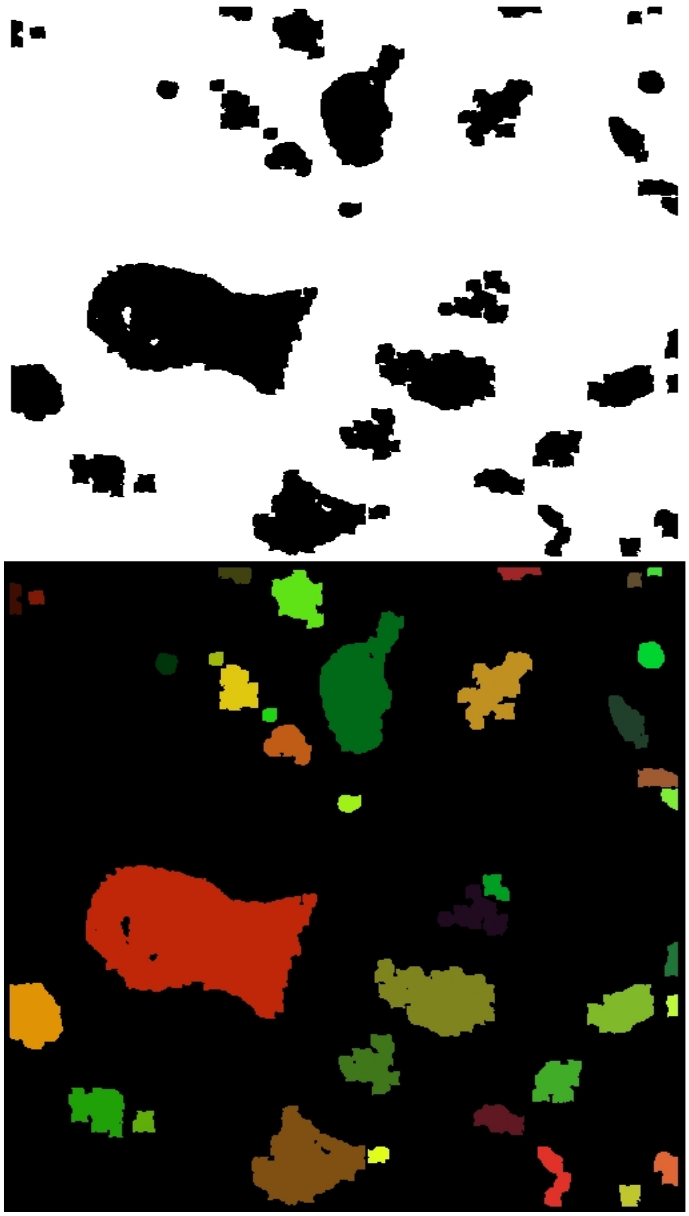

Mapa krawędzi analizowanego obrazu wykonana przy użyciu algorytmu Smitha oraz obraz po segmentacji z barwnie wyróżnionymi segmentami.

Algorytm wypełniania obszaru i identyfikacji obiektu

Dla procedury identyfikacji obiektów, na analizowanym obrazie, wykorzystano algorytm Smitha, wypełniający obszary ograniczone pikselami ich krawędzi. Segmentacja obrazu to skomplikowane czynności wykorzystujące m.in. piksele charakterystyczne obrazu, skanowanie prawo i lewostronne.

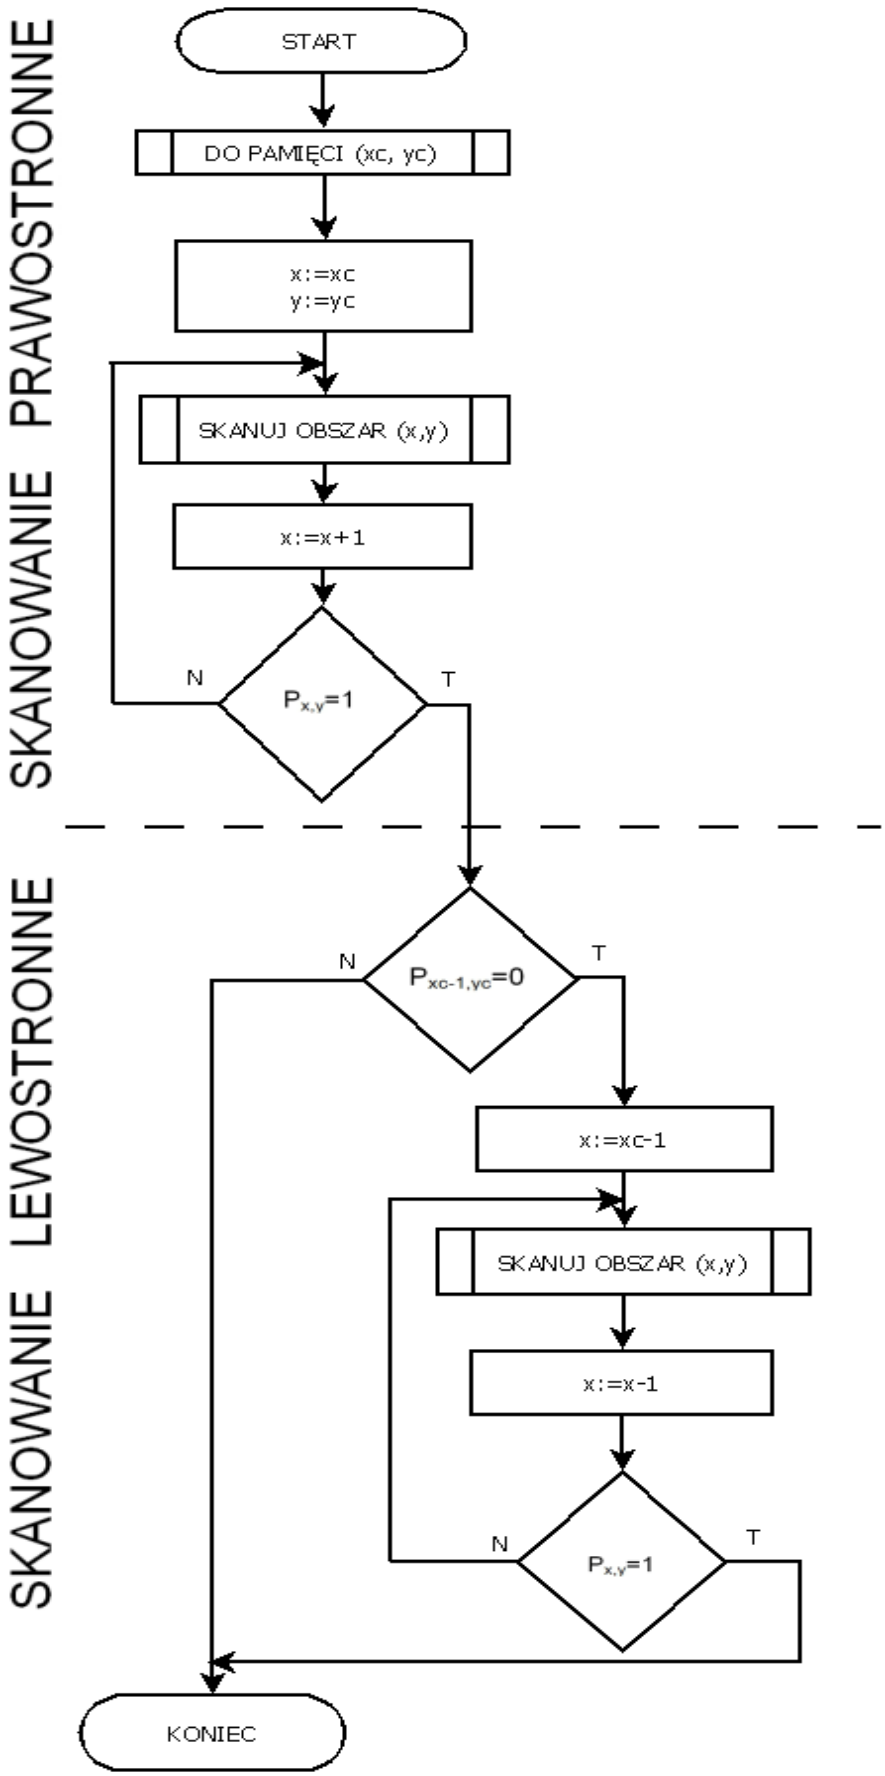

Schemat blokowy procedury skanowania obrazu.

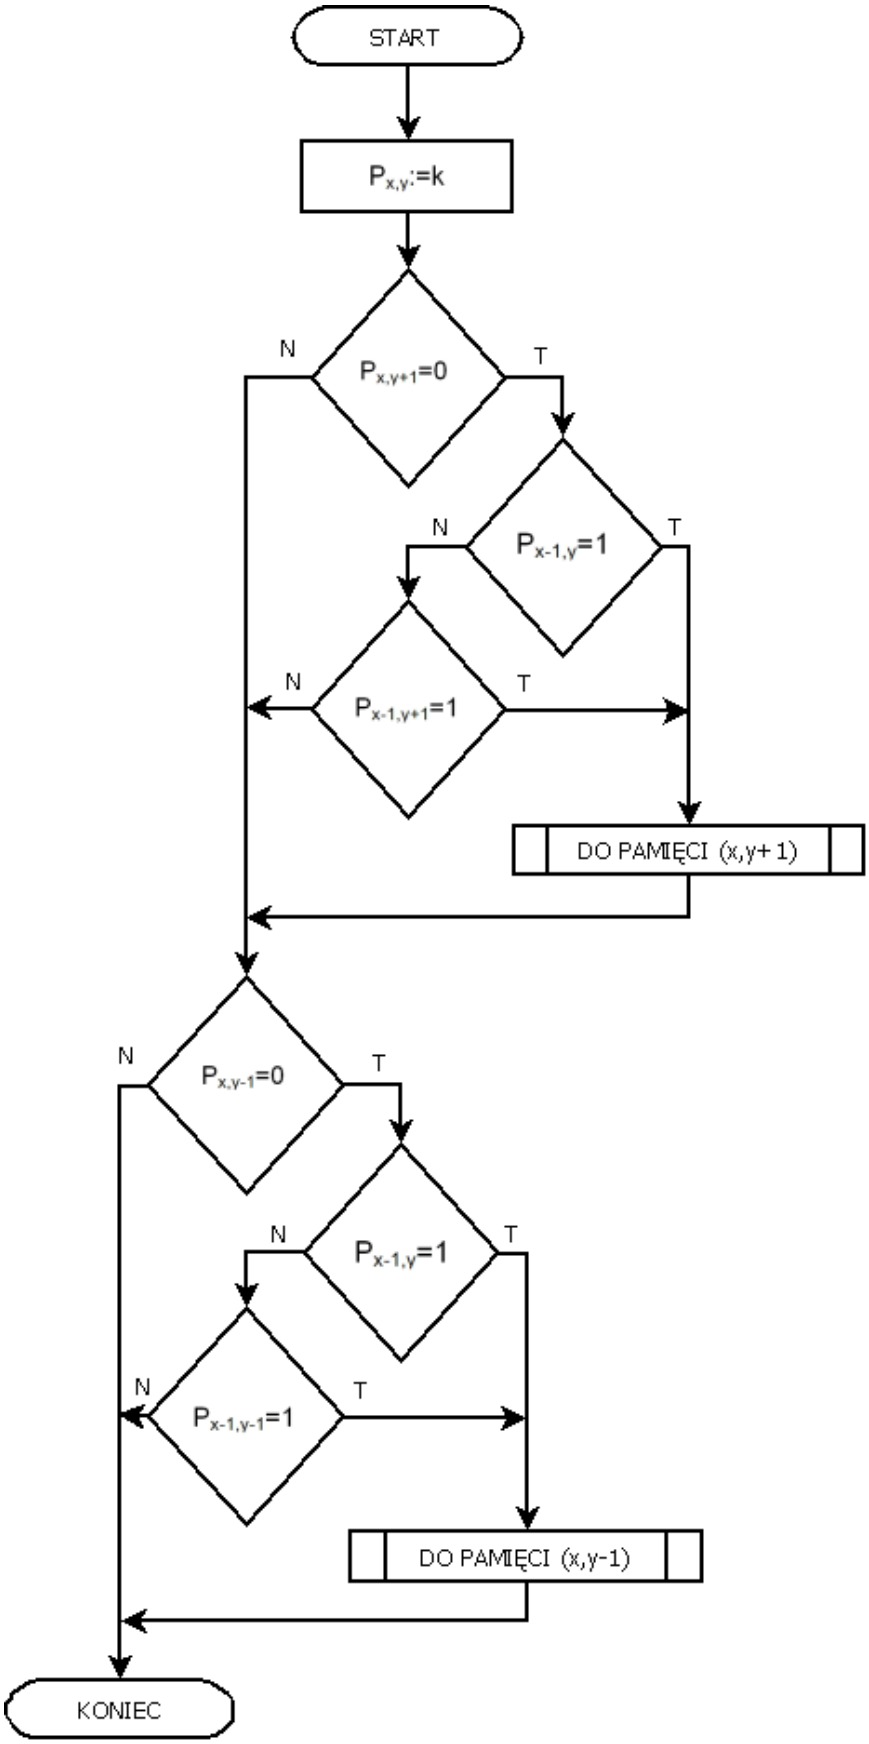

Schemat blokowy procedury skanowania obszaru.

Cechy charakterystyczne i parametryzacja obiektów

Procedura parametryzacji badanego obrazu polega na obliczeniu wartości cech charakterystycznych obiektów obrazu. Na podstawie zwymiarowanych elementów opisowych, otrzymujemy parametry klasyfikacji rodzajów obiektów wyodrębnionych w analizowanym obrazie. Procedura parametryzacji opisuje dwie grupy wielkości charakterystycznych obiektów: parametry lokalne segmentu oraz parametry globalne segmentu. Zadaniem algorytmu parametryzacji segmentu jest wyodrębnienie cech, które wymiernie definiują jego kształt. Prawidłowy dobór cech charakterystycznych warunkuje skuteczne działanie procedur klasyfikacji obiektów obrazu.

Współczynniki kształtu obiektów, cechy charakteryzujące kształt wydzielenia grafitu

Średnice Fereta (D_v, D_h) to parametry opisujące liniowy rozmiar segmentów obrazu; miary segmentu w pionie v i poziomie h. Wyznaczane są na podstawie różnicy pomiędzy maksymalną i minimalną poziomą (pionową) współrzędną pikseli $P_{i,j}$ segmentu k:

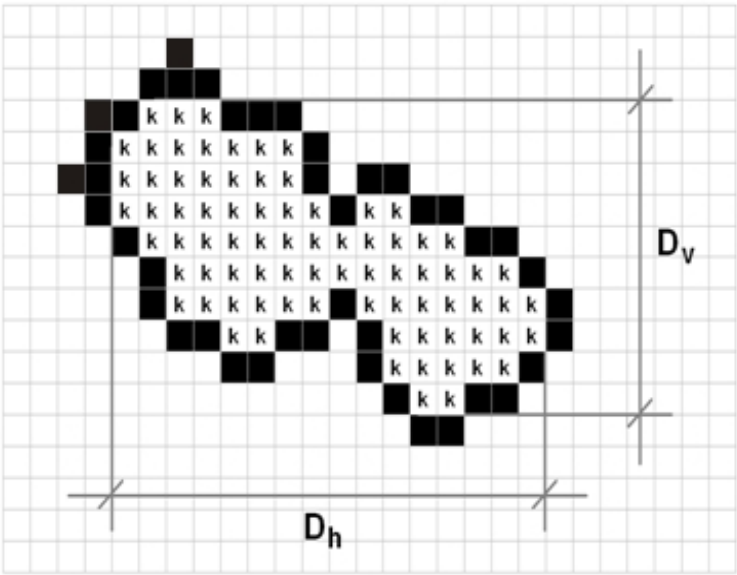

Przykład graficzny opisu segmentu k średnicami Fereta.

Miarą kształtu wydzielenia grafitu jest współczynnik relacji jego obwodu do pola powierzchni, wyznaczaną na podstawie bezwymiarowego współczynnika kształtu:

$$R_S = \frac{L^2}{4\pi \cdot S}$$

gdzie:

L – obwód obiektu, wyznaczanym liczbą pikseli na jego krawędzi,

S – pole powierzchni obiektu.

Miarą wydłużenia wydzielenia grafitu, nazwano relacje wymiarów geometrycznych wzdłuż jego osi podłużnej oraz poprzecznej, zgodnie ze współczynnikiem Fereta:

$$R_F = \frac{L_h}{L_v}$$

gdzie:

L_h – jest maksymalną średnicą obiektu w poziomie

L_v – jest maksymalna średnica (czy wymiar) obiektu w pionie

Miarą cyrkularności wydzielenia grafitu nazwano relację jego obwodu do pola powierzchni wydzielenia. Wyliczaną na podstawie współczynników:

$$R_{C1} = 2 \cdot \sqrt{\frac{S}{\pi}}$$

$$R_{C2} = \frac{L}{\pi}$$

gdzie:

L – całkowity obwód obiektu, mierzony liczbą pikseli po jego krawędziach zewnętrznych,

S – pole powierzchni obiektu liczone liczbą pikseli wewnątrz obrysu

Miarą Blaira-Blissa, kształtu wydzielenia grafitu nazywamy współczynnik wyznaczany ze wzoru:

$$R_B = \frac{S}{\sqrt{2\pi \cdot \sum_i r_i^2}}$$

gdzie:

S – pole powierzchni obiektu, liczone w pikselach obrazu,

r_i – odległość bieżącego piksela wydzielenia od jego środka ciężkości,

i – bieżący numer piksela obiektu.

Miarą Malinowskiej dla wydzielenia grafitu nazywamy relacje obwodu do jego powierzchni, wyliczana na podstawie współczynnika Malinowskiej:

$$R_M = \frac{L}{2 \cdot \sqrt{\pi \cdot S}} - 1$$

gdzie:

L – obwód obiektu

S – pole powierzchni obiektu

Miarą Danielssona dla kształtu wydzielenia grafitu nazywamy współczynnik smukłości kształtu wyliczany ze wzoru:

$$R_D = \frac{S^3}{\left[\sum_i l_i\right]^2}$$

gdzie:

S – pole powierzchni obiektu

l_i – minimalna odległość bieżącego piksela obrazu wydzielenia grafitu od konturu obiektu,

i – bieżący numer piksela obiektu.

Miarą Haralicka środka ciężkości wydzielenia grafitu nazywamy współczynnik obliczany na podstawie wyrażenia:

$$R_H = \sqrt{\frac{\left(\sum_i d_i\right)^2}{n \cdot \sum_i d_i^2 - 1}}$$

gdzie:

d_i – odległość pikseli konturu od środka ciężkości wydzielenia,

n – liczba pikseli konturu wydzielenia,

i – numer bieżącego piksela wydzielenia.

Miarą wypełnienia wydzieleń grafitu nazywamy iloraz pola powierzchni wydzielenia i pola powierzchni prostokąta w który ten obiekt został wpisany:

$$w_{wyp} = \frac{p_{pow}}{p_{prost}} [/]$$

gdzie:

w_{wyp} – jest współczynnikiem wypełnienia wydzielenia,

p_{pow} – jest powierzchnią obiektu,

p_{prost} – jest powierzchnią prostokąta pola odniesienia wydzielenia.

Implementacja algorytmu parametryzacji obiektu

Algorytm Smith'a zastosowany do wypełnienia obszarów, w procedurach segmentacji obrazu, pozwala na uproszczenie procesu parametryzacji. Podczas segmentacji obrazu możliwa jest parametryzacja obiektu w trakcie realizacji procesu wypełniania segmentu k.

Operacje uzupełniające:

- wyznaczanie liczby pikseli należących do segmentu - wyznaczanie pola powierzchni obiektu,
- identyfikacja i zliczanie elementów krawędzi segmentu - wyznaczanie obwodu segmentu,
- identyfikacja minimalnych i maksymalnych miar dla współrzędnych i, j pikseli wypełnianego obszaru (miary średnic Fereta),
- sumowanie współrzędnych i, j pikseli wypełnianego obszaru (wyznaczanie elementów miar dla momentów bezwładności obiektów).

Użycie wzorów odpowiednich dla zsumowanych współrzędnych i, j obrazu, identyfikuje współrzędne środka ciężkości badanego segmentu. Ostatni etap parametryzacji to wyznaczanie współczynników kształtu.

Selekcja obiektów

W celu wyeliminowania badania obiektów nieistotnych, zaproponowano metody filtracji, które nie podlegają analizie. Podczas wstępnej analizy odrzucane są obiekty, które nie należą do istotnych elementów obrazu lub opisanych w niewystarczającym stopniu dla ich identyfikacji.

Zastosowano metodę progowania miar kształtu obiektów, ich rozmiarów oraz położenia, jak:

- pole powierzchni,
- współczynnik zwartości,
- środek ciężkości inne.

Pierwszy etap selekcji odrzuca obiekty o zbyt małych rozmiarach. W drugim kroku filtracji klasyfikowane są tylko te obiekty, których pole powierzchni S jest większe od zadanej wartości progowej S_p

Wyselekcjonowane obiekty muszą posiadać odpowiednią zwartość. Aby obiekt był klasyfikowany, wartość współczynnika zwartości R_z dla tego obiektu musi być niższa od zadanej wartości progowej R_{z_pr}. Zastosowana metoda selekcji segmentów umożliwia pominięcie (w procedurze analizy obrazu) elementów tła, zmniejszenie liczby danych przechowywanych w pamięci, ograniczenie liczby wykonywanych obliczeń podczas realizacji procedur analizy obrazu.

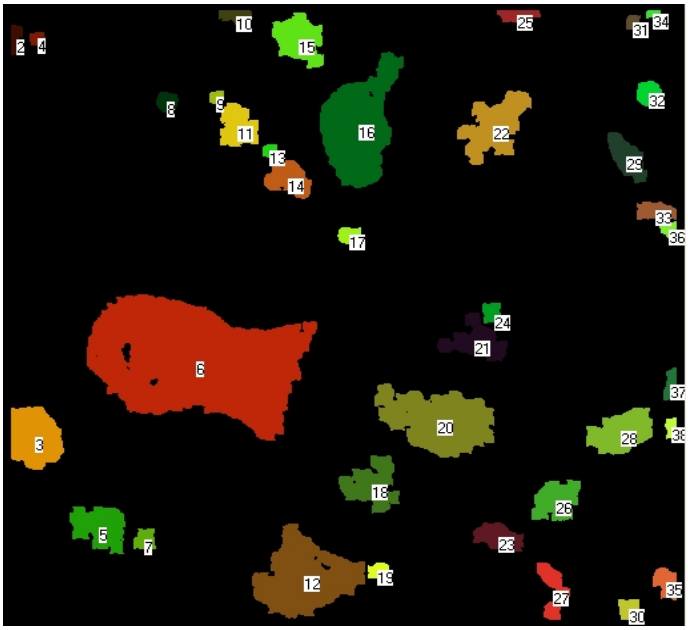

Ilustracja obiektów po przeprowadzeniu procedury selekcji.

Aplikacje wykorzystane w badaniach

Aplikacja „Generator-cięcie” służy do przygotowywania danych wejściowych z obrazów uzyskanych ze zdjęć (mikroskopu) w postaci obrazów o określonych rozmiarach wyrażonych w pikselach będących z kolei plikami wejściowymi dla aplikacji dokonującej wydzielania (segmentacji) obiektów. Istnieje możliwość:

- określenia rozmiaru przygotowywanych plików graficznych będących wycinkami obrazu wejściowego,
- zadania liczby obrazów, które zostaną wygenerowane,
- podania wartości „kroku” czyli położenia (przesunięcia) kolejnych obrazów wyjściowych na obrazie wejściowym,
- skalowania obrazu wejściowego, jeśli obraz ten został zarejestrowany z powiększeniem innym niż obrazy referencyjne i powiększenia określane przez Polską Normę PN-EN ISO 945-1. Istnieje możliwość przeskalowania pierwotnego obrazu wejściowego w zakresie 50-150% rozmiaru wejściowego.

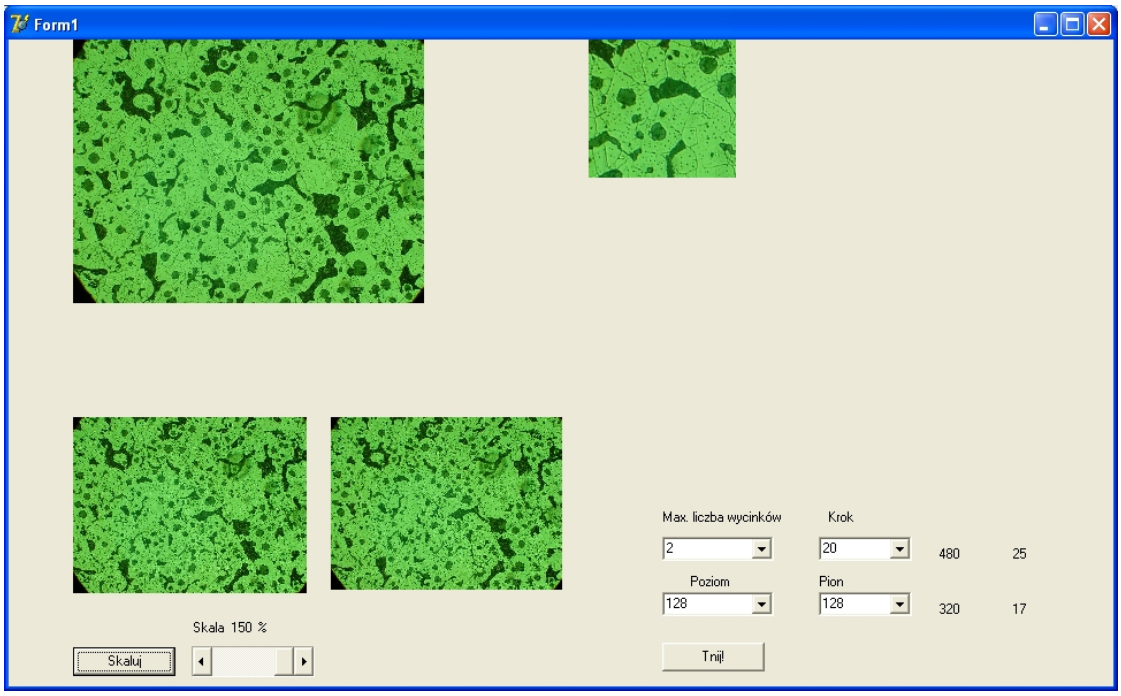

Okno programu „Generator-Cięcie”

Aplikacja dokonuje kopiowania z obrazu wejściowego fragmentów o zadanych rozmiarach, z których współrzędne początkowego (lewego górnego narożnika) kolejnego fragmentu są przesunięte w stosunku do poprzedniego o wartość zadanego kroku. Otrzymuje się zestaw obrazów, które służą do dokładnego zbadania próbki – unika się w ten sposób przypadkowego doboru jednego, nie zawsze reprezentacyjnego miejsca badanego zdjęcia a także umożliwia zbadanie przez kolejne aplikacje zdjęć o wyższej niż akceptowalna przez aplikacje rozmiarze plików wejściowych (512 x 512 pikseli). Otrzymane pliki graficzne stanowią dane wejściowe do aplikacji „Segmentacja”.

Aplikacja „Segmentacja”

Program wykonuje operacje na obrazie: są to m.in. progowanie, przekształcenia morfologiczne i inne. W efekcie tych działań otrzymuje się matematyczny opis obiektów obrazu w postaci współczynników opisanych kształtu określających cechy charakterystyczne oraz parametryzujące poszczególne obiekty obrazu.

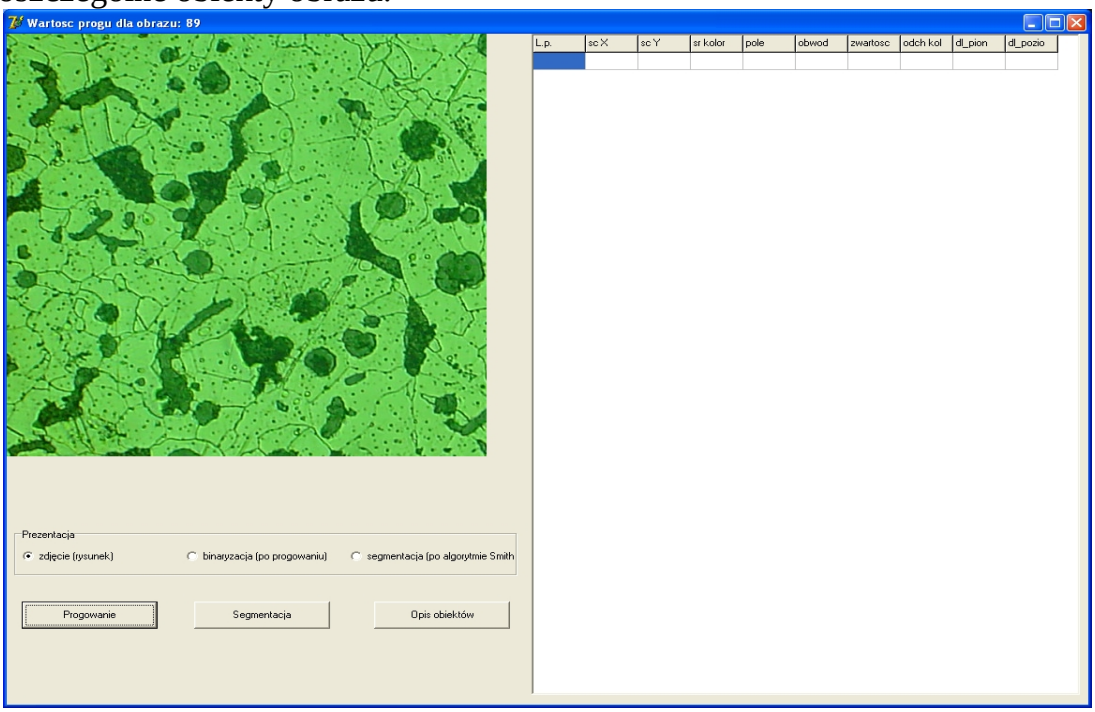

Aplikacja „Segmentacja” – progowanie obrazu wejściowego.

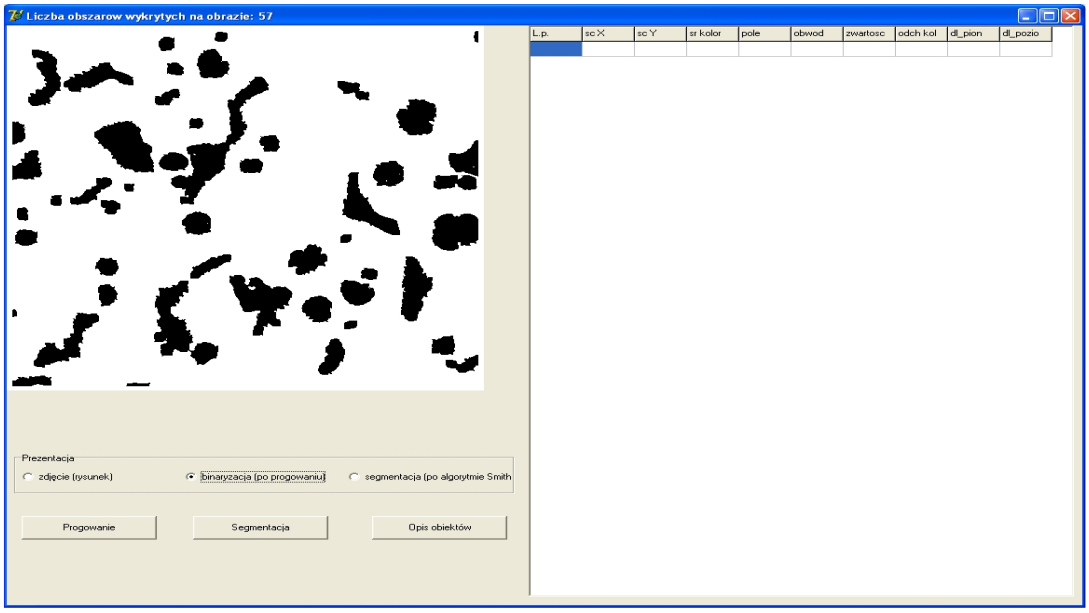

Aplikacja „Segmentacja” – segmentacja obrazu wejściowego.

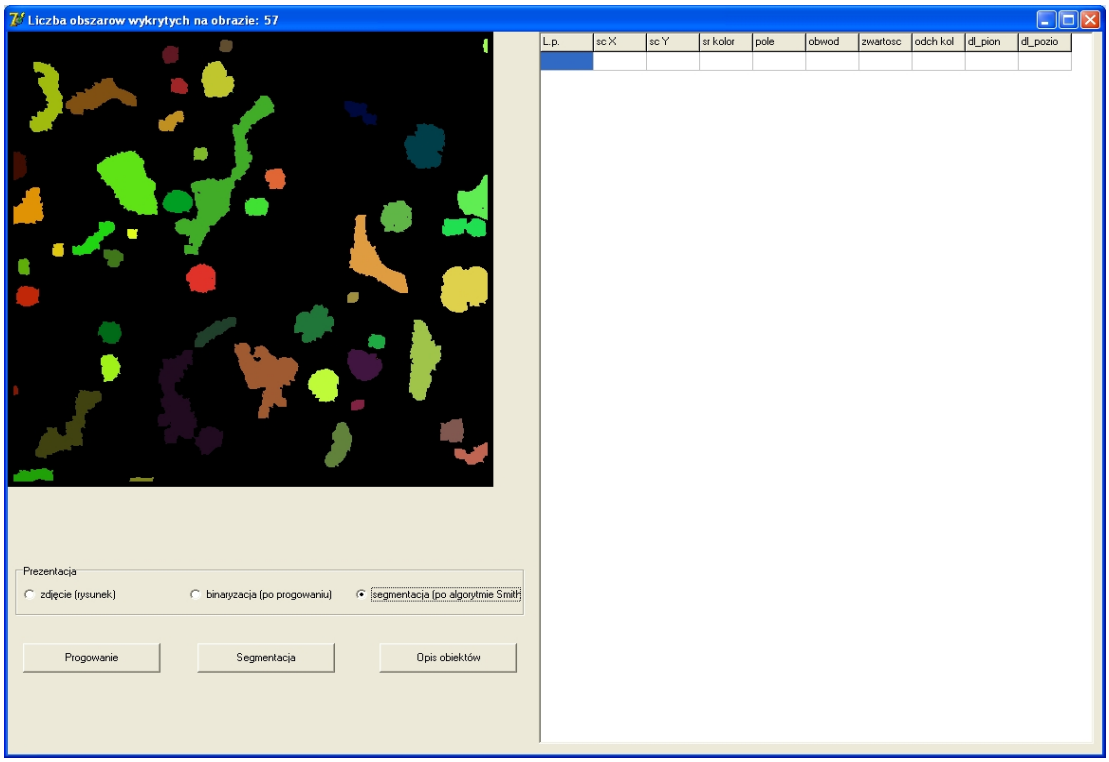

Segmentacja obiektów obrazu wejściowego.

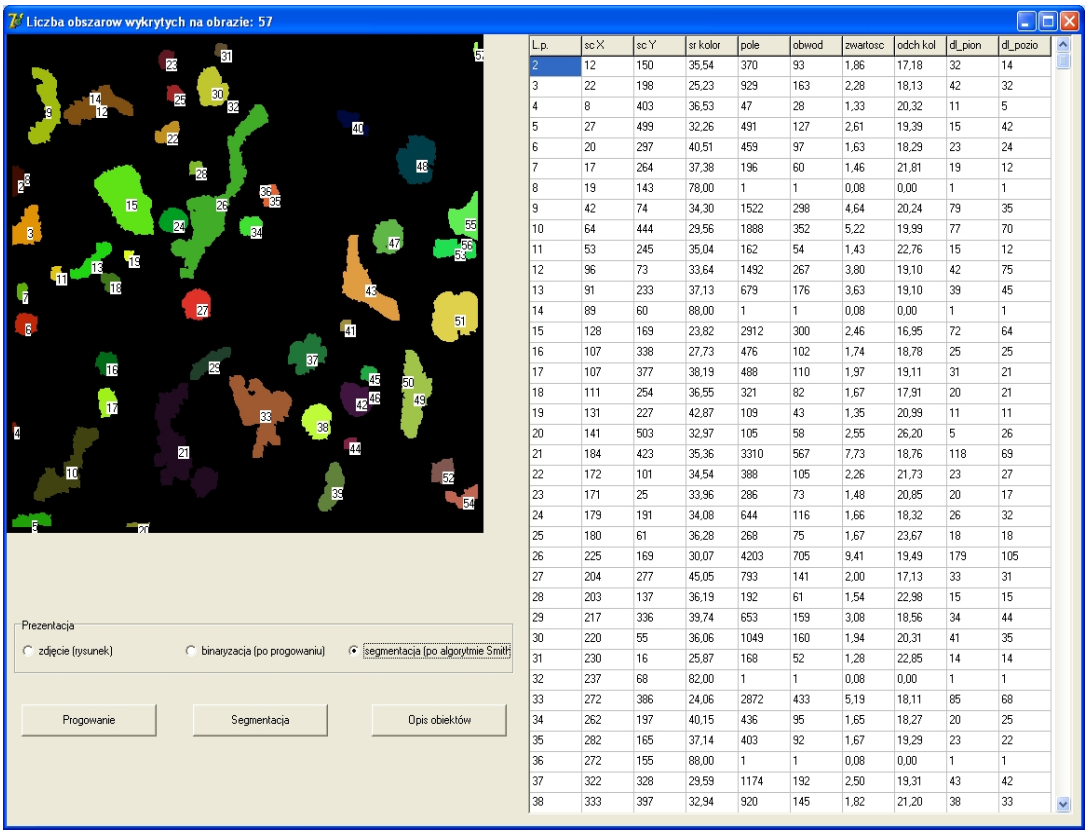

L.p.	sc X	sc Y	sr kolor	pole	obwod	zwartosc	odch kol	dl_pion	dl_pozio
2	12	150	35,54	370	93	1,86	17,18	32	14
3	22	198	25,23	929	163	2,28	18,13	42	32
4	8	403	36,53	47	28	1,33	20,32	11	5
5	27	499	32,26	491	127	2,61	19,39	15	42
6	20	297	40,51	459	97	1,63	18,29	23	24
7	17	264	37,38	196	60	1,46	21,81	19	12
8	19	143	78,00	1	1	0,08	0,00	1	1
9	42	74	34,30	1522	298	4,64	20,24	79	35
10	64	444	29,56	1888	352	5,22	19,99	77	70
11	53	245	35,04	162	54	1,43	22,76	15	12
12	96	73	33,64	1492	267	3,80	19,10	42	75
13	91	233	37,13	679	176	3,63	19,10	39	45
14	89	60	88,00	1	1	0,08	0,00	1	1
15	128	169	23,82	2912	300	2,46	16,95	72	64
16	107	338	27,73	476	102	1,74	18,78	25	25
17	107	377	38,19	488	110	1,97	19,11	31	21
18	111	254	36,55	321	82	1,67	17,91	20	21
19	131	227	42,87	109	43	1,35	20,99	11	11
20	141	503	32,97	105	58	2,55	26,20	5	26
21	184	423	35,36	3310	567	7,73	18,76	118	69
22	172	101	34,54	388	105	2,26	21,73	23	27
23	171	25	33,96	286	73	1,48	20,85	20	17
24	179	191	34,08	644	116	1,66	18,32	26	32
25	180	61	36,28	268	75	1,67	23,67	18	18
26	225	169	30,07	4203	705	9,41	19,49	179	105
27	204	277	45,05	793	141	2,00	17,13	33	31
28	203	137	36,19	192	61	1,54	22,98	15	15
29	217	336	39,74	653	159	3,08	18,56	34	44
30	220	55	36,06	1049	160	1,94	20,31	41	35
31	230	16	25,87	168	52	1,28	22,85	14	14
32	237	68	82,00	1	1	0,08	0,00	1	1
33	272	386	24,06	2872	433	5,19	18,11	85	68
34	262	197	40,15	436	95	1,65	18,27	20	25
35	282	165	37,14	403	92	1,67	19,29	23	22
36	272	155	88,00	1	1	0,08	0,00	1	1
37	322	328	29,59	1174	192	2,50	19,31	43	42
38	333	397	32,94	920	145	1,82	21,20	38	33

Obliczenie parametrów – wartości cech obiektów na obrazie wejściowym.

Na ich podstawie określana jest przynależność danego wytrącenia do jednej z klas wzorcowych. W taki sam sposób generowane są również wartości

współczynników wzorcowych – dla referencyjnych wytrąceń grafitu podanych w PN-EN ISO 945-1.

Modele – wzorce elementów wytrąceń grafitu

Wzorce wydzieleń grafitu według normy PN-EN ISO 945-1 przedstawiono w tabeli:

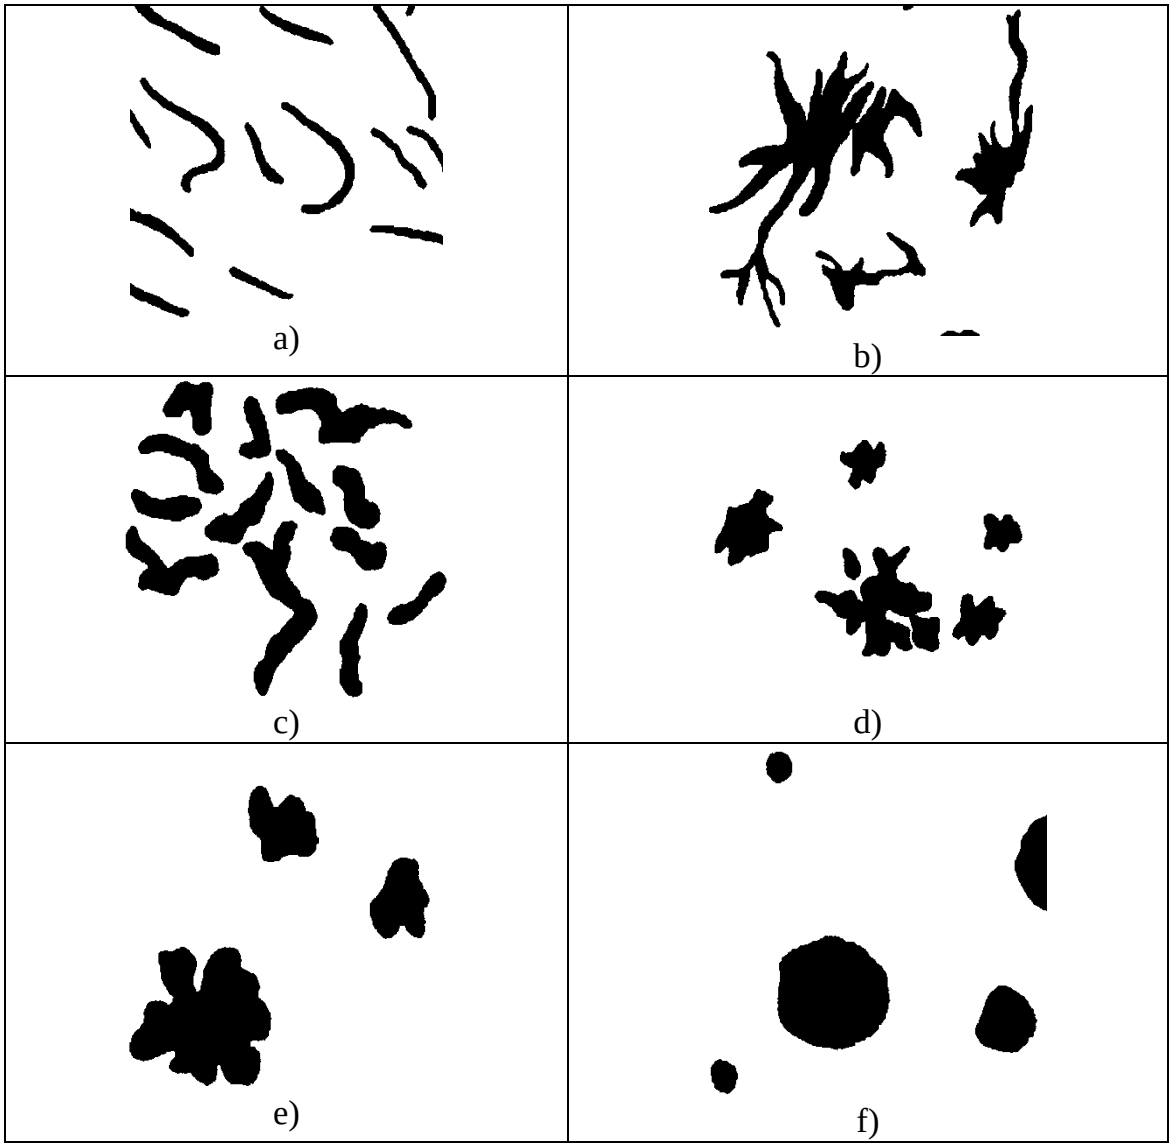

Na podstawie tych wzorców obliczane są cechy charakterystyczne, których wartości stanowią rekordy wejściowe do uczenia sieci neuronowej.

Aplikacja „Generator rekordów uczących”

Program „Generator rekordów uczących” służy do zwielokrotnienia liczby zestawów wejściowych dla uczenia i weryfikacji metod treningu sieci. Na podstawie zestawów danych z programu „Segmentacja”, obliczonych na podstawie wzorcowych wydzieleń grafitu z normy PN-EN ISO 945-1, tworzone są sztuczne rekordy danych. Dysponując opisem cech można je użyć do sztucznego generowania rekordów danych, zgodnych z przyjętymi elementami

charakterystycznymi. Rekordy sztuczne (wirtualne) zawierają wartości cech zmieniających się losowo, występujących jednak w zakresach ściśle określanych przez użytkownika aplikacji – eksperta. Uzyskane w taki sposób rekordy danych wykorzystuje się do przeprowadzenia treningu sieci neuronowej.

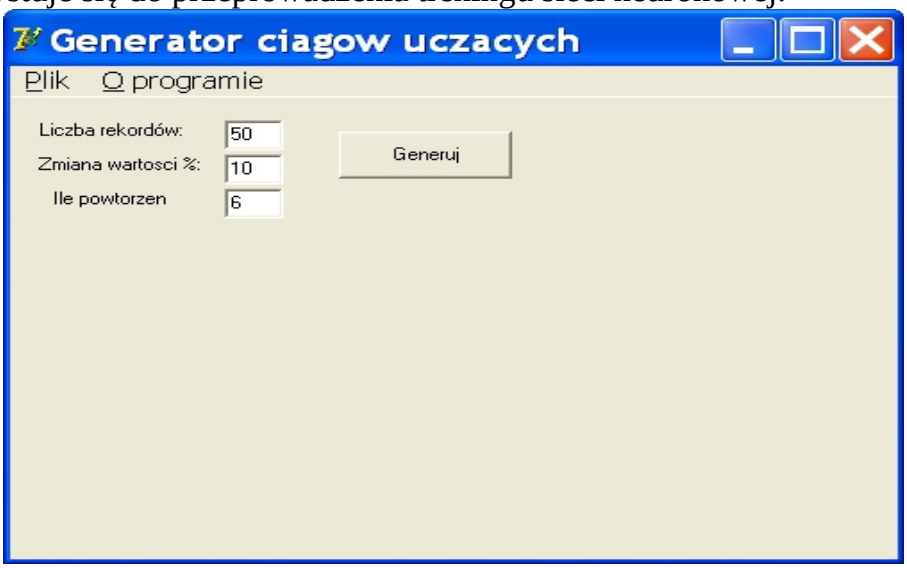

Okno aplikacji „Generator rekordów uczących”

Neuronowa klasyfikacja wydzieleń grafitu

Do uczenia sieci używane są zestawy współczynników cech charakterystycznych obiektów – wydzieleń grafitu wygenerowane aplikacją „Generator rekordów uczących” opisaną w poprzednim rozdziale. Wykorzystano modele sieci zaimplementowane w programie MATLAB.

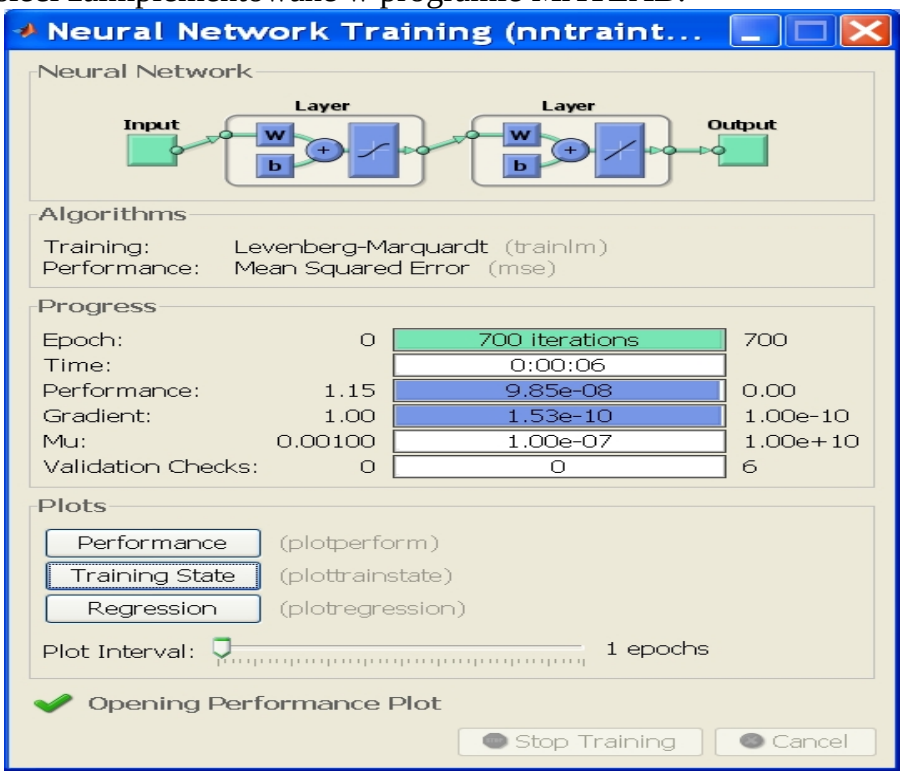

Implementacja sieci neuronowych w programie MATLAB

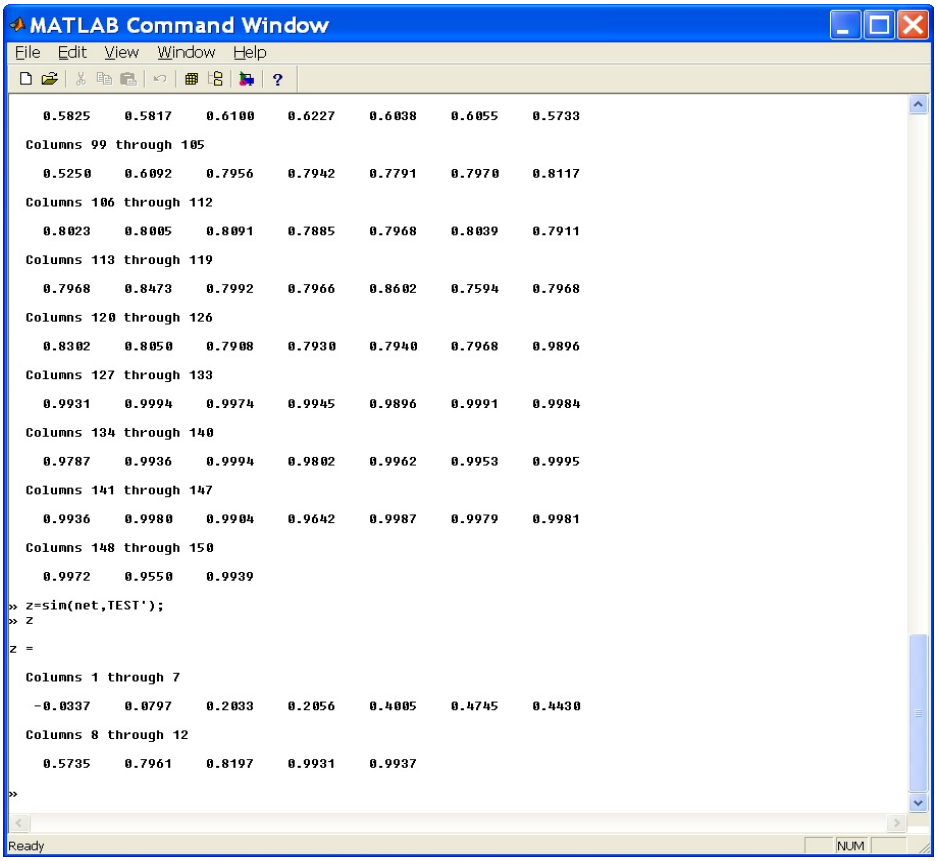

Implementacja sieci neuronowych w programie MATLAB

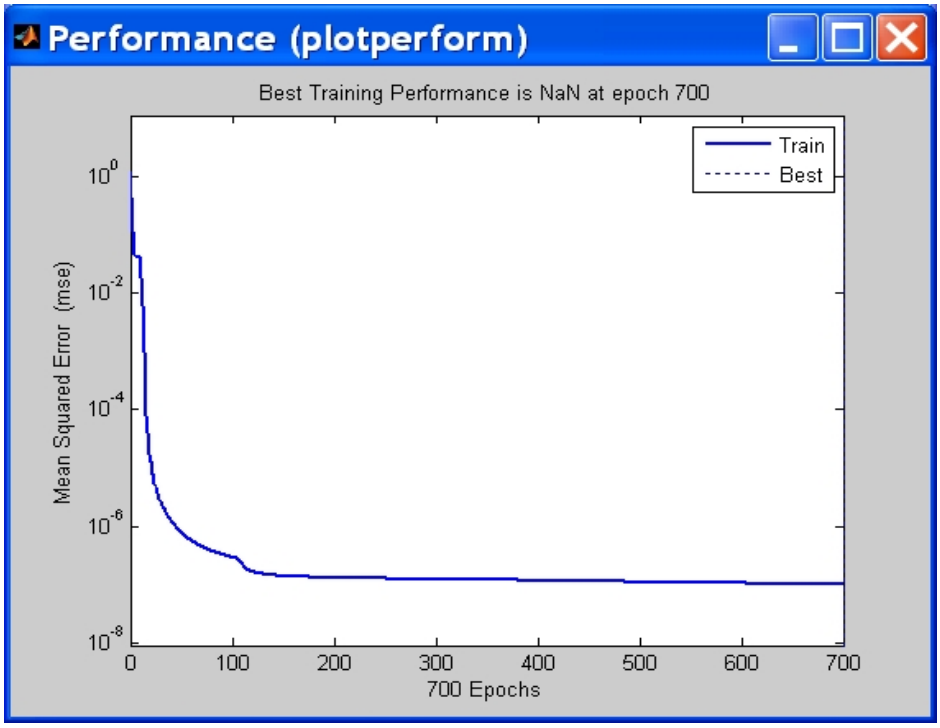

Sieć neuronowa – wyniki uczenia (1)

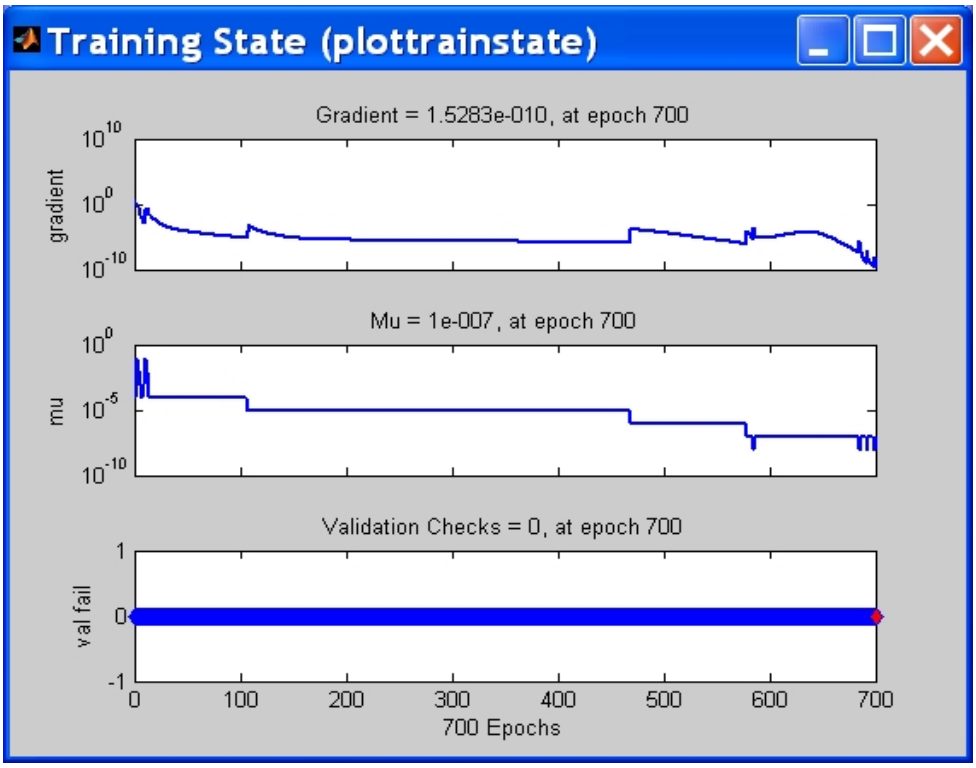

Sieć neuronowa – wyniki uczenia (2)

Weryfikacja procedur klasyfikacji i ocena wyników.

Weryfikację działania wytrenowanej sieci dla rozpoznawania rodzaju wytrącenia grafitu przeprowadzono przez badanie odpowiedzi wytrenowanych różnych rodzajów sieci neuronowych na zestawy współczynników kształtu obliczonych dla wzorcowych wydzieleń grafitu określonych normą PN-EN ISO 945-1. W zależności od rodzaju sieci, jej rozmiaru, liczby warstw, metody uczenia, liczby i rodzaju rekordów uczących, długości cyklu uczenia (liczby epok) itd. rozpoznawalność wzorcowych wytrąceń dochodzi do dziewięćdziesięciu kilku procent. Na rys. poniżej przedstawiono przykładowe wyniki działania wytrenowanej sieci 10-10-1, uczonej metodą backpropagation w czasie 2500 epok. Sieć rozpoznaje prawidłowo 11 z 12 ciągów testowych – prawidłowa kwalifikacja wydzielenia zaznaczona kolorem zielonym.

Wartość wzorcowych odpowiedzi sieci		Wartość rzeczywistej odpowiedzi wytrenowanej sieci	Błąd względny	Kwalifikacja wydzielenia
Wydzielenie typu I	0,00	-0,0337	-17%	0,00
		0,0797	40%	0,00
Wydzielenie typu II	0,20	0,2033	2%	0,20
		0,2056	3%	0,20
Wydzielenie typu III	0,40	0,4005	0%	0,40
		0,4745	37%	0,40
Wydzielenie typu IV	0,60	0,4430	-79%	0,40
		0,5735	-13%	0,60
Wydzielenie typu V	0,80	0,7961	-2%	0,80
		0,8197	10%	0,80
Wydzielenie typu VI	1,00	0,9931	-3%	1,00
		0,9937	-3%	1,00

Przykładowe wyniki działania wytrenowanej sieci.

W celu ostatecznej i całościowej oceny próbki należy wykonać jeszcze (zgodnie z Polskimi Normami):

- analizę rozmieszczenia poszczególnych wydzieleń w analizowanym oknie – zdjęciu przez obliczenie średnich odległości między środkami ciężkości wydzielonych obiektów. Współrzędne środków ciężkości są generowane przez aplikację „Segmentacja”,
- analizę statystyczną proporcji wydzieleń poszczególnych typów, zawartości poszczególnych rodzajów wydzieleń grafitu w żeliwie poszczególnych rodzajów. Proporcje (dopuszczalne zawartości) poszczególnych rodzajów wytrąceń określa ekspert na podstawie właściwych norm.

Podsumowanie i wnioski

Ocena gatunku żeliwa dla zastosowań w przemyśle jest dokonywana w oparciu o polskie normy, w których określono miary oraz wzorce struktur żeliw. Jakość oceny (klasyfikacji) materiału, czy produktu z którego jest wykonany, zależy od skuteczności metod i narzędzi oceny mierzonych parametrów materiału.

W pracy przedstawiono nowe podejście do procesu oceny parametrów żeliwa, metodami wykorzystującymi najnowsze osiągnięcia komputerowych technik analizy obrazów oraz metody automatycznego wspomagania diagnozy.

W systemie automatycznego wnioskowania wykorzystano sztuczne sieci neuronowe, przystosowanie do wspomagania procesów diagnozowania, jako wynik ich treningu, z wykorzystaniem regułowych klasyfikatorów diagnozowanych obiektów.

Opracowano klasyfikatory cech charakterystycznych, które umożliwiły zrealizowanie wspomagania procesu treningu sieci neuronowych, pod nadzorem eksperta. W pierwszej fazie wnioskowania wspomaganego komputerem, wykorzystane są klasyfikatory cech charakterystycznych próbek żeliw. Są one odnoszone do wydzieleń grafitu w obrazie mikroskopowym próbki. Drugi moduł systemu klasyfikacji, decyduje o przydzieleniu badanej próbki do określonego

gatunku żeliwa. Fizyczne właściwości żeliw są ściśle zależne od ich wewnętrznej struktury (rodzaju), liczby oraz proporcji wydzieleń grafitu w próbce materiału.

Pierwszy etap wnioskowania odnosi się do badania reguł wydzieleń (wydzieleń) grafitu i charakterystycznych, dla nich współczynników geometrycznych; opisujących rozkład i kształt wydzieleń. Wszystkie elementy analizowanych reguł, w jednoznaczny sposób diagnozują badaną próbkę. Proces treningu sieci neuronowej odbywa się pod nadzorem eksperta. Ekstrakcja cech wyłącznych, charakteryzujących daną klasę materiału odbywa się z wykorzystaniem zbioru reguł, wyróżniających tę klasę próbki od innych. Wiele cech charakterystycznych jest wspólnych, dla różnych klas materiału. Występują one niemal w każdej klasie żeliwa choć w zasadniczo różnych (trudno policzalnych) proporcjach. Ta istotna właściwość znacznie utrudnienia proces analizy próbek materiału.

Zastosowanie technik informatycznych w procesach klasyfikacji materiału, pozwala prawidłowo wyodrębnić elementy, wyróżniające klasy spośród materiałów o znacznym stopniu podobieństwa. To kluczowy element poprawnego działania systemu klasyfikacji. Zastosowanie metod numerycznych w procesie oceny materiału uwarunkowane jest istnieniem metody formalnego opisu obiektu.

Proces diagnozowania odnosi się do analizy obrazów struktury materiału. Aby możliwy był zapis numeryczny tych struktur przeprowadzono badania metod analizy obrazowej, na których podstawie zbudowane zostały wzorce numeryczne filtrów skanujących próbki żeliw. Dla uogólnienia opisu podobieństwa cech charakterystycznych (różnych rozmiarach) zastosowano sztuczne sieci neuronowe, które grupują podobne obrazy tych cech. Tak uzyskane elementy, skanujące obraz próbki, wykorzystano do wstępnej klasyfikacji badanego materiału. Sieć neuronowa poddana została uczeniu rozpoznawania kompozycji elementów składowych (w odpowiednich proporcjach) tych cech charakterystycznych, dla każdej z klas materiałów.

Sztuczne sieci neuronowe, są powszechnie stosowane jako element sztucznej inteligencji systemów wnioskowania. Jest to alternatywna, skuteczna metoda diagnozowania, pod warunkiem prawidłowego przeprowadzenia procesu uczenia sieci. Zastosowanie neuronowego modułu wnioskowania, daje możliwość zdefiniowania „przez trening”, funkcji opisu obiektów diagnozowania.

W pracy przedstawiono opis metod i przeprowadzonych analiz wydzieleń grafitu, na przykładzie trzech rodzajów żeliw: sferoidalnego wermikularnego i szarego. Dla żeliwa wermikularnego, wzorce są zgodnie z normą PN-EN ISO 945:1999, dla żeliwa szarego – według normy PN-EN 1561:2000, a sferoidalnego, według normy PN-EN 1563:2000.

Opracowane w pracy metody ekstrakcji danych oraz nadzorowanego treningu sieci neuronowej, stanowią podstawę dla rozwoju innego (dowolnego) systemu automatycznego wnioskowania.

Na podstawie powyższej dyskusji można postawić wniosek: *Sieci neuronowe mogą być wykorzystane do zdefiniowania modelu automatu*

iteracyjnego, w którym zapisano cechy obiektu, trudne lub niemożliwe do bezpośredniego opisu matematycznego.

Jest to istotny walor metody dla przypadków w których brak formuł matematycznych lub których zapis analityczny jest bardzo trudny. Duże efektywności i szybkości nadzorowanego uczenia sieci neuronowych, uzyskano przez zastosowanie algorytmów optymalizacji, z których najbardziej skuteczne okazały się algorytmy gradientowe. Do aktualizowania wektora wag w tych metodach, wykorzystano dane o gradiencie funkcji błędu, wskazującej kierunek najszybszego wzrostu funkcji wnioskowania.

Po odpowiednim przygotowaniu metalograficznych danych wejściowych, w postaci obrazów mikroskopowych struktury wewnętrznej próbek żeliwa, uzyskano ciągi danych wejściowych uczących sieć. Po jej wytrenowaniu uzyskano automatyczny klasyfikator wydzielenia grafitu w żeliwie.

Dodatkowe dane wykorzystano dla przeprowadzenia lepszego wytrenowania sieci neuronowej i weryfikacji opracowanych metod analizy obrazowej.

Zrealizowano cele pracy, polegające na:

1. *Opracowaniu metod ekstrakcji cech charakterystycznych próbek żeliwa, z wydzieleniami grafitu*
2. *Opracowaniu metody skutecznego treningu sieci neuronowej pod nadzorem.*

Potwierdzono również tezy pracy:

1. *Automatyzacja procesu oceny jakościowej oraz ilościowej rodzaju wydzieleń grafitu w żeliwie jest możliwa na podstawie decyzji sieci neuronowej, wytrenowanej pod nadzorem regułowych klasyfikatorów cech charakterystycznych wydzieleń grafitu w próbkach żeliw.*
2. *Opracowano miary numeryczne cech charakterystycznych wydzieleń grafitu w żeliwie, które umożliwiły zwielokrotnienie danych wejściowych dla skutecznego wytrenowania sieci neuronowej.*

W celu wykonania założonych zadań pracy przeprowadzono szereg niezbędnych elementów obróbki wstępnej materiału pomiarowego. Dla ekstrakcji istotnych dla procesu diagnozowania danych, zastosowano wstępne przetwarzanie przesiewowe źródła informacji obrazowej, polegające miedzy innymi na odfiltrowaniu tła obrazu z usunięciem elementów o zbyt małym wymiarze jako nieistotnych dla właściwości mechanicznych żeliwa. Są one trudne do sklasyfikowania przez system oceny. Odrzucone zostają próbki z wydzieleniami przekraczającymi określony rozmiar (obszar) oraz takie, których skupienie wydzieleń grafitu świadczy o wadliwej próbce materiału. Oprócz filtracji obrazu zastosowano jego binaryzację oraz różne obróbki morfologiczne (erozja, dylatacja) a także inne jego przekształcenia, prowadząc do pokazania konturów obiektów graficznych. Cechy wydzieleń wyznaczano za pomocą wzorów analitycznych.

Dla opisu bardzo dużego obrazu próbki, wraz z powtarzającymi się obiektami oceny (diagnozowania) kształtu wydzieleń grafitu w próbce, zastosowano procedury fragmentacji obrazu mikroskopowego. Jest to procedura

pozwalająca wykonać (zakończyć) obliczenia na skończonym zbiorze danych. Zanim podjęty zostaje proces treningu sieci neuronowej – sedno pracy, niezbędne są działania wstępne – kompleks procedur z dziedziny przetwarzania obrazów, jak: segmentacja obrazu, czyli operacje wydzielenia z obrazu obszarów spełniających kryteria jednorodności próbki.

W efekcie procesu segmentacji obrazu wybrany piksel pola obserwacji mikroskopu – obrazu, zostaje przypisywany do jednego ze zbiorów przynależności. Z uwagi na szczególny rodzaj (charakterystykę) badanych obrazów zastosowano skuteczny algorytm segmentacji, metodą wykrywania krawędzi granic segmentów. Oprócz segmentacji obrazu mikroskopowego, zastosowano ekstrakcję mapy krawędzi. Metoda ta wykorzystuje dane uzyskane na podstawie filtracji obrazu, której efektem jest mapa krawędzi obrazu źródłowego (zdjęcia mikroskopowego struktury żeliwa). Zastosowany algorytm, zastępuje kolejno gradienty elementów obrazu w dwóch prostopadłych kierunkach, a następnie dokonuje nieliniowej ich kombinacji – połączenia wyników, uzyskując obraz krawędzi w poziomach szarości, o mocno podkreślonych konturach, uzależnionych od kierunku przebiegu gradientów.

Dla tak wyznaczonych obiektów przeprowadzono procedury parametryzacji cech charakterystycznych obiektów. Procedura parametryzacji opisuje dwie grupy wielkości charakterystycznych wydzieleń: parametry lokalne segmentu oraz parametry globalne segmentu. Zadaniem algorytmów parametryzacji segmentu jest wyodrębnienie cech, które wymiernie definiują jego kształt.

Prawidłowy dobór cech charakterystycznych warunkuje skuteczne działanie procedur klasyfikacji obiektów obrazu.

Wśród wyznaczanych cech/współczynników charakterystycznych, znalazły się m.in.: bezwymiarowy współczynnik kształtu oraz współczynniki, takie jak: średnice Fereta, miara cyrkularności, miara Blaira-Blissa, miara Malinowskiej, miara Danielssona, miara Haralicka oraz miara wypełnienia.

Dzięki integracji tych wszystkich elementów obróbki numerycznej diagnozowanego obrazu możliwe jest zdefiniowanie zestawów wartości współczynników, opisujących cechy charakterystyczne wydzieleń w strukturze wewnętrznej żeliw. Są one podstawą przyporządkowania (klasyfikacji) wydzieleń grafitu do jednej z klas wzorcowych.

Tendencje zastosowań metod komputerowych do sterowania jakością produkcji, muszą mieć na uwadze konieczność sięgania do bardzo zawansowanych metod numerycznej obróbki danych, dla przypadków, w których opis analityczny nie istnieje. Ów stopień złożoności implementacyjnej metody automatycznego wnioskowania, autor starał się zaprezentować w niniejszej pracy.