




Wydawnictwo  
Naukowe  
AKAPIT



## WSPOMAGANIE WYKRYWANIA PRZYCZYN POWSTAWANIA WAD WYROBÓW

ANDRZEJ KOCHAŃSKI

### COMPUTER AIDED DETECTION OF SOURCES OF PRODUCT DEFECTS

#### Abstract

*Manufacturing of products without defects is potentially possible in two ways: severe selection of faulted final products or improvement of the manufacturing technology. The paper deals with the problem of detection of defects of metallic casts. The main objective of the work is elaboration of the methodology, based on the artificial neural network approach, of classification of the industrial data and prediction of parameters initiating defects in casts. The presented method can be treated as an advisory system for foundry engineers.*

### 1. WSTĘP

Wyprodukowanie wyrobu potencjalnie pozbawionego wad może być realizowane w dwojaki sposób: na drodze eliminacji wyrobów wadliwych (finalna kontrola gotowych wyrobów i odrzucenie wadliwych) lub przez poprawę procesu produkcyjnego, mającą na celu obniżenie wadliwości.

Pierwsza metoda jest nieskuteczna, bowiem nawet 100% kontrola nie powoduje wychwycenia wszystkich wadliwych wyrobów. Doświadczenie i teoria mówią, że im więcej wadliwych wyrobów zostanie wykonanych, tym więcej dostanie się ich do odbiorcy (Theory of Escaping Defects) (Maciaszczyk, 2003). Nierzadkie są również przypadki, w których pełna kontrola jest wręcz niemożliwa do realizacji.

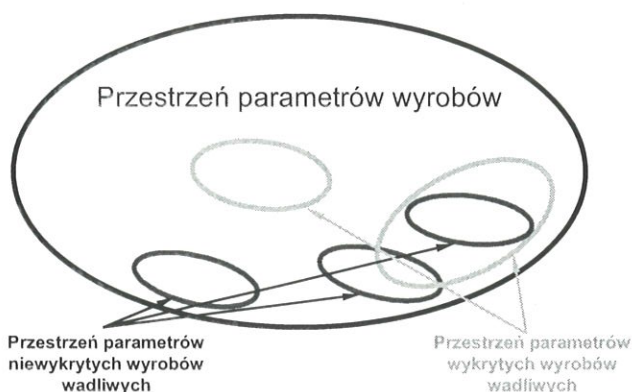
Druga metoda oznacza konieczność określenia parametrów procesu mających wpływ na powstanie wady, a w dalszej kolejności także określenie wartości tych parametrów, aby ograniczyć lub wyeliminować możliwość powstawania wad.

Określenie wartości parametrów procesu mających wpływ na powstawanie wady jest możliwe bardzo często tylko wtedy, gdy wada została wykryta bezpośrednio po wyprodukowaniu wyrobu. Wykrycie jej na późniejszym etapie, czyli np. u użytkownika lub odbiorcy, może uniemożliwić określenie tych parametrów. Dzieje się tak, dlatego że na wyprodukowanym wyrobie brak cechy identyfikującej. Z taką sytuacją mamy do czynienia np. w odlewnictwie, kiedy nie ma zgody odbiorcy na umieszczenie dodatkowych oznaczeń, z których odbiorca nie korzysta albo też rzadziej,

w przypadku gdy część lub wszystkie znaki identyfikujące zostały usunięte w wyniku obróbki skrawaniem.

W odlewnictwie wykrywanie braków odbywa się w wielu etapach. Pierwsza eliminacja odlewów wadliwych jest dokonywana zaraz po ich wybicciu (wyjęciu) z formy. Wówczas oddzielane są od pozostałych odlewy np. z wyraźnymi wadami powierzchni: przestawienie, obciążenie, wypchnięcie, strup, obrwanie, itp. Drugim etapem selekcji jest kontrola przeprowadzana w trakcie czyszczenia odlewów: usuwania układów wlewowych, nadlewów, zalewek. Wtedy odrzucane są odlewy, w których np. wykryto jamy skurczowe sięgające poza nadlew. Trzecim etapem jest kontrola prowadzona po obróbce skrawaniem. Obróbka ta może być jedno- lub dwuetapowa: wstępna i całkowita. Wstępna obróbka skrawaniem jest wykonywana w odlewni i ma na celu m. in. obniżenie kosztów transportu odlewów do odbiorcy przez wykrycie wadliwych wyrobów i usunięcie ich przed transportem. Całkowita obróbka może być wykonywana zarówno w odlewni, jak i u odbiorcy.

W analizowanym problemie założono przypisanie zgromadzonych danych (parametrów procesu i własności wyrobu) do dwóch zbiorów: wyrobów dobrych i wyrobów wadliwych, gdzie zbiór pierwszy jest (a w każdym bądź razie powinien być) znacznie większy od drugiego. Należy przy tym podkreślić fakt, że zbiór wyrobów wadliwych może składać się z kilku lub nawet kilkunastu oddzielnych obszarów (rysunek 1). Dodatkową niedogodnością jest niekompletność danych dotyczących tego zbioru. Wynika to z faktu, że już od pierwszego etapu wymienionego w poprzednim akapicie (usunięcie z formy) część danych, jeśli nie jest prawidłowo rejestrowana, może być tracona. Ostatecznie, po ujawnieniu wady u odbiorcy może dochodzić do sytuacji, w której nie można w żaden sposób związać konkretnego odlewu z warunkami, w jakich powstawał (skład wytopu, temperatura zalewania, własności masy, itp.).



Rysunek 1. Określenie problemu przypisania kategorii wyrobom.  
Figure 1. A characterization of the problem of assigning products to categories.

Model predykcji wystąpienia wad w wyrobie można zbudować na dwa sposoby. W pierwszym przypadku jest to model z nauczycielem, wykorzystujący algorytm z nadzorowanym uczeniem. Przykład zastosowania takiego modelu przedstawiono w pracy Perzyka i Kochańskiego (2004). Drugie rozwiązanie to model z uczeniem bez nadzoru wykorzystywany w sztucznych sieciach neuronowych stosowanych do klasyfikacji.

## 2. ZASTOSOWANIE KLASYFIKACJI DO ANALIZY WYSTĘPOWANIA WAD W PROCESACH ODLEWNICZYCH

Sieć użyta do klasyfikacji dzieli zbiór danych na podzbiory. Dla pogrupowanych – sklasyfikowanych danych można przeprowadzić dwa rodzaje analizy: spójności pojedynczego podzbioru lub też właściwości określających podzbiory. W przypadku pierwszym analizujemy te przykłady zaklasyfikowane do podzbioru, które wyraźnie odstają, wg przyjętych kryteriów, od pozostałych przypadków. W drugim przypadku określamy istotne cechy wyróżniające podzielone podzbiory i na ich podstawie je charakteryzujemy – nazywamy.

W pracy przeprowadzono analizę na przykładzie zbioru obejmującego wyniki blisko 1000 kontrolowanych wytopów żeliwa sferoidalnego.

### 2.1. Analiza wadliwych wytopów z żeliwa sferoidalnego

Dane wykorzystane w pracy zostały zgromadzone przez autora w ciągu kilku lat w jednej z warszawskich odlewni. Fragment tego zbioru przedstawia tabela 1. Zgromadzone dane z wytopów charakteryzują się następującymi wielkościami:

- skład chemiczny żeliwa sferoidalnego:  $3,47 \div 4,00\%C$ ,  $1,90 \div 2,98\%Si$ ,  $0,09 \div 0,42\%Mn$ ,  $0,03 \div 0,08\%P$ ,  $0,005 \div 0,03\%S$ ,  $0,01 \div 0,12\%Cr$ ,  $0,00 \div 0,07\%Ni$ ,  $0,013 \div 0,70\%Cu$ ,  $0,015 \div 0,065\%Mg$ , zawartości aluminium, tytanu, cyny i molibdenu mieszczą się w zakresach  $0,015 \pm 0,005\%$ ,
- parametry procesu: temperatura sferoidyzacji  $1480 \div 1525^{\circ}C$ , temperatura zalewania  $1350 \div 1500^{\circ}C$ , czas sferoidyzacji  $1'20'' \div 3'30''$ .

W wytopach uzyskano żeliwo, którego własności zmieniały się w zakresie: wytrzymałość na rozciąganie  $382 \div 834$  MPa, wydłużenie  $5 \div 29\%$  i twardość  $152 \div 285$  HB. Wszystkie badania własności mechanicznych były wykonane na próbkach oddzielnie lanych typu Y2.

Tak szeroki zakres wartości wynikał z wykonywanej w odlewni produkcji. W zakładzie produkowano



Tabela 1. Przykładowe dane wytopu żeliwa sferoidalnego (Typical data for a ductile cast iron melt).

Oznaczenie wytopu <sup>1</sup>	R <sub>m</sub>	A <sub>5</sub>	HB	C	Mn	Si	P	S	Cr	Ni	Cu	Mg
[54,1]	516	12,1	187	3,65	0,23	2,58	0,07	0,01	0,05	0,02	0,20	0,040
[55,1]	459	11,4	179	3,76	0,25	2,60	0,06	0,01	0,05	0,02	0,22	0,030
[56,1]	491	10,0	183	3,65	0,26	2,49	0,07	0,01	0,04	0,02	0,20	0,035
[57,1]	400	6,4	183	3,72	0,28	2,50	0,06	0,01	0,05	0,02	0,21	0,035
[58,1]	497	11,4	183	3,66	0,28	2,66	0,07	0,01	0,04	0,02	0,22	0,035
[59,1]	535	7,1	229	3,83	0,21	2,35	0,07	0,01	0,03	0,01	0,36	0,040
[60,1]	526	8,6	197	3,90	0,21	2,35	0,07	0,01	0,03	0,01	0,36	0,039
[61,1]	573	7,1	229	3,83	0,19	2,21	0,07	0,01	0,03	0,01	0,33	0,032
[62,1]	414	5,7	197	3,85	0,20	2,35	0,07	0,01	0,03	0,02	0,36	0,039
[63,1]	598	7,9	217	3,90	0,20	2,27	0,07	0,01	0,03	0,01	0,33	0,050
[111,1]	455	18,6	167	3,69	0,11	2,35	0,07	0,01	0,02	0,01	0,09	0,033
[112,1]	465	17,9	167	3,73	0,11	2,32	0,07	0,01	0,02	0,01	0,09	0,031
[113,1]	478	20,7	167	3,68	0,11	2,57	0,07	0,01	0,02	0,01	0,09	0,035
[114,1]	459	20,7	163	3,71	0,12	2,43	0,07	0,01	0,02	0,01	0,11	0,036
[115,1]	465	21,4	167	3,66	0,11	2,52	0,07	0,01	0,02	0,01	0,05	0,043

<sup>1</sup> w nawiasach kwadratowych [] podano numer kontrolowanego wytopu

odlewy z żeliw sferoidalnych klasy: 400/18, 500/07 i 500/07 o podwyższonej twardości (wymóg postawiony przez odbiorcę odlewów). Na rysunku 2 przedstawiony został rozkład wydłużenia w funkcji wytrzymałości wszystkich kontrolowanych wytopów. Wskazane na wykresie obszary i oznaczone cyframi od 1 do 3 odpowiadają odpowiednio wykonywanym klasom żeliwa. Obszary 4 i 5 odpowiadają wytopom nietrafionym. W obszarze 4 lokują się wytopy o ponadnormatywnych własnościach (zarówno wytopy żeliwa klasy 400 o wytrzymałości przekraczającej 500 MPa, jak i wytopy klasy 500 o wydłużeniu przewyższającym 15%), a w obszarze 5 nie spełniające wymaganych normami minimów.

## 2.2. Metodyka


Zgodnie z przyjętym w odlewni profilem produkcji dokonano podziału zgromadzonych danych sztuczną siecią neuronową narzucając podział zbioru na trzy podzbiory (rysunek 3). Wykorzystano do tego oprogramowanie NeuroXL Classifier pracujące z danymi zapisanymi w formacie arkuszy kalkulacyjnych MSEXcel. Program do obliczeń wykorzystuje algorytm LVQ (Linear Vector Quantizer).

Do modelowania wykorzystano zbiory uczące za-


wierające dane z 930 kontrolowanych wytopów. Sygnałami wejściowymi były składy chemiczne wytopów określone procentowymi zawartościami pierwiastków: węgla, manganu, krzemu, fosforu, siarki, chromu, niklu, miedzi i magnezu. Odpowiedzią sieci było przyporządkowanie rekordu wejścia wartości 1, 2 lub 3 odpowiadającej przynależności do jednej z trzech klas żeliwa sferoidalnego: 400/18, 500/07 i 500/07 o podwyższonej wartości.

## 2.3. Przykładowa analiza spójności podzbioru

Rysunek 4 przedstawia rozkład wydłużenia w funkcji wytrzymałości danych z jednego z podzbiorów



Rysunek 2. Rozkład wydłużenia w funkcji wytrzymałości kontrolowanych wytopów.  
Figure 2. Elongation related to tensile strenght for recorded melts.



Rysunek 3. Rozkład wydłużenia w funkcji wytrzymałości wszystkich danych z podziałem na trzy podzbiory.  
Figure 3. Elongation related to tensile strength for all data divided into 3 subsets.

(podzbiór 1 na rysunku 3). Odpowiadają one wytopom żeliwa 400/18 (obszar 1 na rysunku 2). Zdecydowana większość wyselekcjonowanych wytopów mieści się w obszarze ograniczonym liniami: wydłużenie w przedziale 15÷25% i wytrzymałość w przedziale 400÷500 MPa. Kilkanaście wytopów, zaklasyfikowanych jako żeliwo klasy 400/18, w badaniach wykazało wartości lokujące je w obszarach 3, 4 i 5 (rysunek 2). Skrajne przypadki, wyraźnie odstające od pozostałych, to oznaczone na rysunku 4 wytopy: 2036.1, 2039.1 i 1279.1. Dane dotyczące tych wytopów zawierające własności mechaniczne i skład chemiczny znajdują się w tabeli 2.

Dla celów porównawczych, w tabeli 2 uwzględniono również wybrane dane dotyczące wytopów sklasyfikowanych, na podstawie składu chemicznego, jako


żeliwo 400/18. Wiersz oznaczony symbolem [średni] zawiera wyliczone średnie wartości ze wszystkich 435 wytopów przypisanych do tej klasy. Kolejne 5 rekordów w przedstawia dane z wytopów najbliższych wartości średniej. Jak widać trzy wybrane wytopy o skrajnie odległych od średnich wartości własnościach mechanicznych nie różnią się rażąco swymi składami chemicznymi od wytopów charakterystycznych dla tej klasy. Na rysunku 4 znalazły się 394 wytopy spełniające wymagania stawiane żeliwu klasy 400/18 oraz 41 wytopów sklasyfikowanych jako żeliwo klasy 400/18, ale o własnościach nie spełniających wymagań stawianym żeliwu tej klasy. Ostatnie dwa wiersze tabeli 2 zawierają minimalne i maksymalne wartości, jakie przyjmują sklasyfikowane wytopy spełniające wymagania dla żeliwa 400/18. Składy chemiczne wadliwych wytopów doskonale mieszczą się w granicach określonych dla wytopów poprawnych. Wytopy wadliwe nie poszerzają zakresu wartości składu chemicznego, lecz lokują się w okolicach wartości średnich.

Tabela 2. Dane wytopów dla punktów charakterystycznych z wykresu na rysunku 4 (Data for characteristic points from the chart in fig. 4).

Oznaczenie wytopu <sup>1</sup>	R <sub>m</sub>	A <sub>5</sub>	HB	C	Mn	Si	P	S	Cr	Ni	Cu	Mg
[1279,1]	747	11,4	248	3,84	0,17	2,50	0,050	0,010	0,04	0,02	0,06	0,036
[2039,1]	382	7,1	156	3,82	0,09	2,50	0,057	0,008	0,02	0,00	0,03	0,037
[2036,1]	490	29,0	159	3,76	0,11	2,54	0,057	0,011	0,03	0,00	0,04	0,040
[średni]	461	20,4	164	3,78	0,15	2,53	0,050	0,010	0,03	0,01	0,06	0,036
[114,1]	459	20,7	163	3,71	0,12	2,43	0,070	0,010	0,02	0,01	0,11	0,036
[1063,1]	459	20,7	156	3,87	0,14	2,54	0,050	0,010	0,02	0,01	0,04	0,035
[1063,2]	459	20,7	156	3,86	0,12	2,49	0,050	0,010	0,02	0,01	0,04	0,039
[1232,1]	459	20,7	156	3,76	0,18	2,55	0,040	0,010	0,04	0,02	0,17	0,032
[1232,2]	459	20,7	156	3,79	0,18	2,56	0,040	0,010	0,04	0,02	0,17	0,034
[min]	414	15,0	152	3,57	0,09	2,15	0,010	0,005	0,01	0,00	0,03	0,024
[max]	497	29,0	179	3,94	0,26	2,98	0,070	0,021	0,06	0,06	0,17	0,057

<sup>1</sup> w nawiasach kwadratowych [] podano numer kontrolowanego wytopu, [średni], [min], [max] to oznaczenie średnich, minimalnych i maksymalnych wartości wyliczonych dla całego analizowanego podzbioru





Rysunek 4 Rozkład wydłużenia w funkcji wytrzymałości dla wytopów odpowiadających klasie żeliwa sferoidalnego 400/18.

Figure 4. Elongation related to tensile strength for melts classified as 400/18 ductile cast iron class.

### 3. WNIOSKI

Sztuczne sieci neuronowe wykorzystywane do klasyfikowania zgromadzonych danych umożliwiają podział tych danych na spójne podzbiory danych wykazujących silne podobieństwo. Ręczny podział tego samego zbioru wg przyjętego kryterium (w przypadku tej analizy jest to klasa żeliwa sferoidalnego określana na podstawie wytrzymałości i wydłużenia) i porównanie tego podziału z podzbiorymi utworzonymi z wykorzystaniem klasyfikatorów pozwala na wskazanie przypadków odstających, czyli takich, które w wyniku podziałów znajdują się w różnych podzbiorych.

### 4. PODSUMOWANIE

Przeprowadzenie klasyfikacji zgromadzonych danych umożliwia zwrócenie uwagi na pewne grupy sygnałów wejściowych bez konfrontacji z sygnałami wyjściowymi, np. wówczas, gdy są one niedostępne. Rozpad zbioru danych wejściowych na większą niż zakładana liczbę homogenicznych podzbiorych, w analizowanym przypadku są to trzy podzbiory odpowiadające trzem produkowanym klasom żeliw, wskazuje na silną niejednorodność procesu. Daje to podstawy do określenia, kto lub, co na tę niejednorodność wpływa.

Dla kompletnych zbiorów danych zawierających również sygnały wyjściowe wstępna klasyfikacja umożliwia analizowanie tych danych również w in-

nym sposób. Dane wyjściowe ręcznie przyporządkujemy do grup (np. tak jak to przedstawiono na rysunku 2), a następnie oceniamy i analizujemy sygnały inaczej sklasyfikowane.

Obie metody analizy mają na celu zwrócenie uwagi personelowi na niejednorodność procesu. Analiza przeprowadzona np. tak jak to przedstawiono z wykorzystaniem rysunku 4 służy wyeliminowaniu przyczyn tych zakłóceń w celu poprawy procesu produkcyjnego i w efekcie obniżenie wadliwości.

### LITERATURA

- Maciaszczyk, A., 2003, Rozdział 3 Ewolucja metod zarządzania jakością i początki systemów zarządzania jakością, *Materiały konferencyjne "Gospodarka i Społeczeństwo w obliczu zmian"* - opracowanie naukowe pracowników nauk. - dydaktyk. Katedry Inżynierii Systemów Produkcji Politechniki Gdańskiej, Sobieszewo.
- Perzyk, M., Kochański, A., Detection of causes of casting defects assisted by artificial neural networks, *J. Manufacturing Engineering*, part B, 217, 1279-1284.

Artykuł otrzymano 3 czerwca 2005 r.