



## ZASTOSOWANIE SIECI NEURONOWYCH DO STEROWANIA JAKOŚCIĄ MAS FORMIERSKICH

### STRESZCZENIE

W ramach niniejszego artykułu zostanie zaprezentowana próba zastosowania sieci neuronowych do sterowania jakością mas bentonitowych. Jest to metoda oceny przydatności mas za pomocą wykrywania korelacji pomiędzy poszczególnymi parametrami masy, przy użyciu systemów sztucznej inteligencji. Przedstawione w pracy badania zostały wykonane przy wykorzystaniu programu Statistica 8.0.

Zaprezentowane badania miały na celu wybór odpowiedniego rodzaju sieci neuronowej do prognozowania wilgotności masy na podstawie określonych właściwości masy formierskiej, takich jak: przepuszczalność, wytrzymałość na ściskanie, wytrzymałość na rozciąganie, wytrzymałość na rozciąganie w strefie przewilżonej, zagęszczalność i osypliwość. Jako dane wejściowe wprowadzone zostały podane wyżej parametry określone w funkcji wilgotności masy zawartej w przedziale od 1,7 do 5,51%.

Zastosowanie programu Statistica pozwoliło na automatyczny dobór typu sieci właściwej dla odwzorowania zależności pomiędzy zaproponowanymi parametrami masy formierskiej. Najkorzystniejsze wyniki uzyskano dla jednokierunkowej sieci wielowarstwowej (MLP). Dla uzyskanych modeli, jako algorytm uczenia, wykorzystano algorytm quasi-Newtona, który w trakcie działania wykorzystuje odwrotność macierzy drugich pochodnych funkcji błędu liczonych względem kolejnych wag. Funkcja błędu wykorzystywana w trakcie uczenia sieci oraz do określania błędu w trakcie działania sieci w przedstawionych modelach jest sumą kwadratów różnic pomiędzy wartościami zadanymi i wartościami otrzymanymi na wyjściu każdego neuronu wyjściowego.

Określono wrażliwość sieci neuronowej na poszczególne parametry masy. Wśród zaproponowanych wyraźnie wyróżnia się osypliwość i zagęszczalność. Wytrzymałość na rozciąganie  $R_m^w$  jest parametrem o najmniejszym oddziaływaniu na predykcję sieci i może

---

<sup>1</sup>Dr inż. Jarosław JAKUBSKI - Katedra Tworzyw Formierskich, Technologii Formy i Odlewnictwa Metali Nieżelaznych, Wydział Odlewnictwa AGH

Prof. zw. dr hab. inż. Stanisław M. DOBOSZ - Katedra Tworzyw Formierskich, Technologii Formy i Odlewnictwa Metali Nieżelaznych, Wydział Odlewnictwa AGH

być brana pod uwagę w przypadku redukcji ilości neuronów wejściowych w celu uproszczenia struktury sieci.

## 1. WSTĘP

Wysoka konkurencja na międzynarodowym rynku odlewniczym a także wysokie wymagania klientów odnośnie do jakości odlewów zmuszają odlewnie do wprowadzania coraz doskonalszych rozwiązań technologicznych, ale także ekonomicznych i ekologicznych. Ich integralną częścią stają się ostatnio także rozwiązania informatyczne. Te ostatnie dotyczą coraz częściej takich obszarów jak przepływy informacji i logistyka [1]. Postęp ten dokonuje się poprzez wdrożenia rozwiązań systemowych. Systemy informatyczne powinny pozwalać na definiowanie i tworzenie baz danych o procesach, śledzić parametry wpływające na jakość, aktualizować bazy danych, a pozyskiwane informacje wykorzystywać do bieżącego sterowania jakością i do jej analiz [2, 3].

W procesach odlewniczych generuje się duża ilość danych, z których zdecydowana większość zazwyczaj nie jest poddawana ciągłym pomiarom bezpośrednim i rejestracji, zwłaszcza automatycznej. Nawet te dane, które są mierzone i archiwizowane (np. składy chemiczne wytopów określane metodą spektrometryczną), nie są wykorzystywane do optymalizacji i komputerowego wspomaganie sterowania jakością. Dostęp do większej ilości wiarygodnych danych wymaga zakupu odpowiedniego sprzętu pomiarowego i zaangażowania nowych pracowników [1].

Wiedza o procesach odlewania, ich komputerowe modelowanie i prognozowanie jakości odlewów, stosowane metody statystyczne, systemy sztucznej inteligencji (sieci neuronowe) to już dużo, ale w wielu przypadkach za mało, aby poprawnie ocenić pojawiające się anomalie produkcji i im przeciwdziałać, gdyż brakuje wiarygodnych, wciąż aktualizowanych danych.

W dużych odlewniach wdrażane są drogie systemy informatyczne (np. SAP R/3), rozbudowane strukturalnie, służą głównie (według listy modułów najczęściej wybieranych przez firmy) do obsługi obszaru finansowo-ekonomicznego, planowania produkcji, sprzedaży, zakupów, przepływu materiałów [4]. Poszerzenie tych systemów o moduł QM (ang. *Quality management*), ważny z punktu widzenia sterowania jakością, okazuje się rozwiązaniem szczególnie trudnym do wdrożenia, zwłaszcza w odlewniach, mimo że jest oferowany w ogólnym pakiecie SAP/R3. Rozwiązaniem mniej kosztownym niż moduł QM i łatwiejszym do wdrożenia są dostosowane do faktycznych potrzeb odlewni prostsze systemy. Z założenia powinny one lepiej przystawać do natury gromadzonych danych technologicznych. Sprawdzają się wtedy w praktyce sterowania jakością, które powinno być oparte nie tylko na danych rejestrowanych w czasie rzeczywistym, ale także na uporządkowanych, łatwo i szybko dostępnych danych historycznych [4]. Nowoczesna eksploracja danych (ang. *data mining*) wymaga najczęściej opracowania od początku takich systemów, o odpowiedniej architekturze baz danych.

W tym zakresie interesujące jest zaprezentowane w artykule [1,5,6] autorskie narzędzie informatyczne - system KonMas-final - zostało stworzone zgodnie z powyższymi wskazaniem. Ułatwia ono podejmowanie decyzji na podstawie zarejestrowanych danych oraz umożliwia ich przygotowanie jako podstaw do analiz. Jest to narzędzie komplementarne w stosunku do podstawowych modułów systemu SAP R/3. Stanowi ono pierwszy z opracowanych systemów pomocniczych [4] do zarządzania jakością AQ (ang. *Assurance Quality*) i spełniających funkcje, jakich się oczekuje od wskazanego wyżej modułu QM - [1]

Innym interesującym rozwiązaniem jest system analizy wad odlewniczych zaprezentowany w artykule [7]. Duża różnorodność wad występujących w odlewach wynika z samej istoty technologii wytwarzania odlewów, składającej się z operacji technologicznych obejmujących zaprojektowanie i wykonanie formy odlewniczej oraz technologię wytapiania ciekłego metalu. Istotne znaczenie mają również kwalifikacje pracowników odlewni, charakter

produkcji, wyposażenie techniczne odlewni itp. Analizując przyczyny występowania wad, należy uwzględnić tzw. wiedzę stałą o przyczynach ich występowania, sposobach zapobiegania im oraz informacje bieżące z procesu. Strukturę informacyjną systemu analizy wad odlewniczych należy odpowiednio uszeregować [3]. Spośród tzw. siedmiu podstawowych narzędzi zarządzania jakością na uwagę zasługują: diagram Pareto-Lorenza, oparty na empirycznie stwierdzonej prawidłowości, że 2(H30% przyczyn decyduje o 7(K60% skutków, oraz diagram przyczynowo-skutkowy Ishikawy, przedstawiający graficznie powiązania między czynnikami wpływającymi na proces i skutkami, które one wywołują. Wykres Ishikawy umożliwia graficzną prezentację powiązań pomiędzy przyczynami danego problemu i ich hierarchią. Ze względu na swoją budowę i kształt diagram ten nazywany jest często schematem „jodełkowym” lub schematem „rybiej ości”. Diagram Ishikawy ma strukturę hierarchiczną: przyczyny główne znajdują się najbliżej rdzenia, natomiast przyczyny pośrednie, bezpośrednio powiązane z przyczynami głównymi, stanowią ich rozwinięcie. Przy sporządzaniu wykresu obowiązuje zasada „od ogółu do szczegółu”, w myśl której w pierwszej kolejności określa się przyczyny główne, a następnie przyczyny pośrednie: drugiego rzędu, a jeśli zachodzi konieczność, to przyczyny kolejnych rzędów. Sposób sporządzania wykresu Ishikawy opisano w pracy [7].

## 2. SIECI NEURONOWE

Jedną z nowoczesnych metod optymalizacji produkcji są sztuczne sieci neuronowe. Swoją popularność sieci neuronowe zawdzięczają temu, że są wygodnym narzędziem. Może być wykorzystywane w niezwykle szerokim zakresie problemów. Spowodowane jest to zdolnością sieci neuronowych do odwzorowywania złożonych funkcji. Szczególnie należy tu podkreślić ich nieliniowość. Zyskują one coraz szersze zastosowanie w szeroko pojętym przemyśle odlewniczym między innymi do sterowania procesami wytopu w żeliwiaku i piecu łukowym, projektowania odlewów i układów zasilających, sterowania procesem przerobu masy formierskiej, przewidywania własności odlewanych stopów, czy doboru parametrów odlewania ciśnieniowego.

Sztuczna sieć neuronowa jest to złożona *zależność matematyczna*, której struktura naśladuje strukturę i przetwarzanie sygnałów, jakie mają miejsce w korze mózgowej.

Sztuczne sieci neuronowe charakteryzują się wieloma zaletami, wśród których najważniejsze to:

- Zdolność do uczenia się i uogólniania nabytej wiedzy. Sztuczne sieci neuronowe umożliwiają znalezienie prawidłowości w warunkach dużej liczby zmiennych o różnym charakterze. Zależności takie wymagają często stosowania skomplikowanych operacji matematycznych lub są niewykrywalne za pomocą metod matematycznych.
- Sieć jest odporna na błędy w danych wejściowych (zaszumienia) oraz błędy pojawiające się w niektórych wagach, czyli błędnie wyznaczonych niektórych stałych modelu.
- Sieci umożliwiają szybkie przetwarzanie informacji, często możliwe w czasie rzeczywistym.

Sieci neuronowe należą do nowoczesnych systemów uczących się. Wartości stałych określające istotność poszczególnych danych wejściowych (wag sieci) wyznaczane są na podstawie wyników doświadczeń (przykładów uczących). Także drogą kolejnych poprawek (korekt) tak, aby dane wyjściowe (odpowiedzi sieci) zbliżały się do wartości rzeczywistych. Jest to tzw. uczenie nadzorowane (inaczej z nauczycielem), które jest najczęściej wykorzystywane. Sieci neuronowe, w zależności od rodzaju rozwiązywanego problemu mogą realizować kilka rodzajów zadań.

W modelowaniu procesów technologicznych (produkcyjnych), wykorzystywane są:

- Regresja czyli inaczej aproksymacja nieznanej funkcji wielu zmiennych (najczęściej), na podstawie wyników obserwacji doświadczalnych.

- Predykcja, czyli przewidywanie przyszłych zachowań się systemu na podstawie ciągu wartości z przeszłości z ciągłym dostosowaniem wag sieci.
- Wykrywanie wzorców, umożliwiający grupowanie sygnałów wykazujących podobne cechy (sieci typu Kohonena). Jest to uczenie nienadzorowane, nie wymagające zbioru uczącego.

Sieci neuronowe mogą posiadać różne typy struktury oraz ich konkretne realizacje w ramach danego typu. Do najważniejszych należą:

- Sieć jednokierunkowa wielowarstwowa, zwana siecią MLP (Multilayer Perceptron), najczęściej wykorzystywana w realizacji zadań związanych z modelowaniem procesów technologicznych.
- Sieć rekurencyjna, charakteryzująca się występowaniem sprzężeń zwrotnych między elementami wejściowymi a wyjściowymi

Uczenie sieci polega na rozwiązaniu zagadnienia optymalizacyjnego funkcji wielu zmiennych. Z matematycznego punktu widzenia dążymy do znalezienia takich wartości wag, aby wartość błędu średniokwadratowego ze wszystkich odpowiedzi sieci, w stosunku do obserwacji doświadczalnych, była najmniejsza.

$$E = \frac{1}{p} * \sum_{k=1}^p \left( \frac{1}{m} * \sum_{j=1}^m (d_{kj} - Y_{kj})^2 \right) \quad (1)$$

gdzie: m – liczba wyjść sieci, p – liczba prezentacji, czyli rekordów obserwacji doświadczalnych, d – wartości doświadczalne, Y – wartości otrzymywane z sieci [8].

Zbiór danych doświadczalnych zastosowany w sieci, dzieli się zazwyczaj na:

- Zbiór uczący, podstawowy, wykorzystywany do korygowania wag sieci,
- Zbiór weryfikujący (na ogół mniejszy) służący do bieżącego obliczania błędu dla innych danych w celu sprawdzenia zdolności sieci do uogólnienia.

Korekty wag sieci przeprowadza się wielokrotnie, dla całego zbioru uczącego. Jeden cykl obejmujący obliczenie błędu i modyfikację wag nosi nazwę epoki. Koniec uczenia następuje najczęściej wówczas, gdy błąd średniokwadratowy zaczyna rosnać dla danych weryfikujących. Jest to związane z możliwością przeuczenia sieci, czyli do nadmiernego dopasowania się do danych uczących bez zdolności do generalizacji przewidywać dla innych danych.

Istotnym problemem jest wytypowanie odpowiednich danych wyjściowych. Jest to związane z istotnością danych dla zmiennych wyjściowych. Dane najmniej znaczące należy odrzucić. Ułatwi to proces uczenia i analizę uzyskanych wyników. Ustalając liczbę wyjść (równą liczbie wielkości wynikowych modelu) należy zawsze rozważyć konstruowanie kilku sieci z pojedynczymi wyjściami, co daje zmniejszenie liczby poszukiwanych wag.

### 3. SIECI NEURONOWE W STEROWANIU JAKOŚCIĄ MAS FORMIERSKICH

Hu`lya Kacar Durmus, Erdog`an Ozkaya, Cevdet Meric [9] przeprowadzili badania dotyczące zastosowania sieci neuronowych do badania wpływu temperatury starzenia, obciążenia, szybkości ścierania na ścieranie i chropowatości powierzchni stopu aluminium. Autorzy wykazali, że przewidywane przez sieć po „uczeniu” wyniki bardzo dobrze korelują z danymi eksperymentalnymi.

Interesujące badania dotyczące właściwości klasycznych mas formierskich przedstawili Mahesh B. Parappagoudar, D.K. Pratihari, G.L. Datta [10]. Wykonali badania zależności właściwości form wykonanych z klasycznych mas formierskich (stopień zagęszczenia, przepuszczalność, twardość formy) od parametrów masy formierskiej (kształt i wielkość ziarna, rodzaj lepiszcza, wilgotność). Autorzy przedstawili możliwości wykorzystania

algorytmu wstecznej propagacji błędów oraz regresji uogólnionej do prognozowania zarówno właściwości formy w funkcji parametrów masy formierskiej jak również określenia wejściowych parametrów masy na podstawie właściwości formy. W pracy tej przedstawiono szereg przypadków sieci neuronowych, które pozwoliły stwierdzić przydatność zastosowanych algorytmów do odwzorowania założonego problemu. Z innych opracowań wykorzystujących sieci neuronowe do prognozowania parametrów mas formierskich należy przytoczyć badania M. Perzyka [11, 12].

#### 4. BADANIA WŁASNE

W pracy podjęto próbę wykorzystania modułu sieci neuronowych do wspomagania decyzji dotyczących procesów odświeżania mas formierskich. Przedstawione w pracy badania zostały wykonane przy wykorzystaniu programu Statistica 8.0.

W pierwszym etapie przeprowadzono badania, które miały na celu określenie wyboru odpowiedniego rodzaju sieci neuronowej do prognozowania wilgotności masy na podstawie określonych właściwości masy formierskiej. Były to: przepuszczalność, wytrzymałość na ściskanie, wytrzymałość na rozciąganie w strefie przewilżonej, zagęszczalność i osypliwość. Jako dane wejściowe wprowadzone zostały podane wyżej parametry określone w funkcji wilgotności zawartej w przedziale od 1,7 do 5,51%.

W tym etapie zastosowano automatyczne projektowanie modelu sieci. Metoda ta polega na doborze właściwych parametrów modelu (funkcja agregacji, funkcja aktywacji, liczba neuronów) na podstawie wyników uzyskanych w kolejnych eksperymentach, które wykorzystują różne modele. Najkorzystniejsze modele uzyskane w czasie automatycznego modelowania przedstawiono w tabeli 1.

Tabela 1.  
Najlepsze modele sieci zaprojektowanych z wykorzystaniem automatycznego modelowania sieci neuronowych w Statistica 8.0

Id	Nazwa sieci	Algorytm uczenia	Funkcja błędu	Funkcja aktywacji (warstwa ukryta)	Funkcja aktywacji (warstwa wyjściowa)
1	MLP 7-19-1	BFGS 97	SOS	Tanh	Linear
2	MLP 7-12-1	BFGS 153	SOS	Tanh	Linear
3	MLP 7-18-1	BFGS 47	SOS	Tanh	Linear
4	MLP 7-22-1	BFGS 154	SOS	Logistic	Tanh
5	MLP 7-20-1	BFGS 162	SOS	Logistic	Exponential
6	MLP 7-8-1	BFGS 197	SOS	Logistic	Exponential
7	MLP 7-15-1	BFGS 92	SOS	Tanh	Sinus
8	MLP 7-12-1	BFGS 88	SOS	Exponential	Sinus
9	MLP 7-24-1	BFGS 104	SOS	Logistic	Linear
10	MLP 7-8-1	BFGS 147	SOS	Tanh	Sinus

Analizując przedstawione w tabeli 1 dane, można jednoznacznie stwierdzić, że w przypadku danych wejściowych przedstawionych do uczenia sieci, najkorzystniejsze wyniki uzyskuje się dla jednokierunkowej sieci wielowarstwowej (MLP). Dla uzyskanych modeli jako algorytm uczenia nadaje się algorytm quasi-Newtona, który w trakcie działania wykorzystuje odwrotność macierzy drugich pochodnych funkcji błędu liczonych względem kolejnych wag. *Funkcja błędu* wykorzystywana jest w trakcie uczenia sieci, jak również przy określaniu błędu w trakcie jej działania. W przedstawionych modelach błąd jest sumą kwadratów różnic pomiędzy wartościami zadanymi i wartościami otrzymanymi na wyjściach każdego neuronu

wyjściowego. Kolejne kolumny określają rodzaje funkcji jakie zostały zastosowane do aktywacji w warstwie ukrytej i wyjściowej sieci neuronowej. Wykorzystano tu szereg zależności matematycznych (funkcje tangensoidalne, liniowe, logistyczne i wykładnicze) wśród których najczęściej występują funkcje tangensoidalne w warstwie ukrytej i liniowe w warstwie wyjściowej, które w połączeniu dawały najlepsze wyniki.

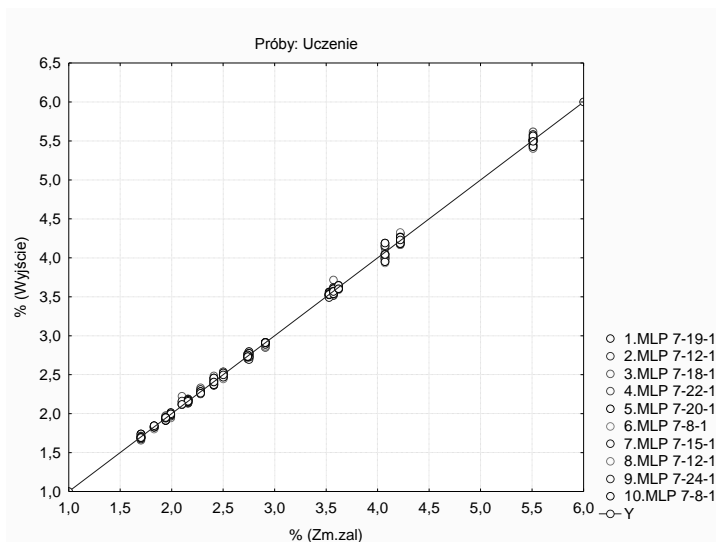
W tabeli 2 przedstawiona została analiza wrażliwości. Pozwala ona na odróżnienie ważnych zmiennych od takich, które niewiele wnoszą do wyniku działania sieci, i które można odrzucić. Jest to szczególnie przydatne w przypadku potrzeby uzyskania wyników wejściowych niezbędnych do określenia parametru wyjściowego w krótkim czasie. Określenie wrażliwości poszczególnych parametrów masy formierskiej może umożliwić odrzucenie czasochłonnych pomiarów, które niewiele wnoszą do procesu uczenia sieci. STATISTICA Sieci Neuronowe ma procedury kompensowania braków danych występujących w zmiennych. Procedury te używane są w trakcie analizy wrażliwości. Dane prezentowane są sieci wielokrotnie, przy czym w każdym z testów, wszystkie wartości jednej zmiennej, innej w każdym powtórzeniu, zamieniane są na braki danych i obliczany jest całkowity błąd, podobnie jak w standardowym uczeniu sieci. Ponieważ odrzucona zostaje pewną ilość danych spodziewać się należy zwiększenia błędu sieci. Tak więc podstawową miarą wrażliwości sieci jest iloraz błędu uzyskanego przy uruchomieniu sieci dla zbioru danych bez jednej zmiennej i błędu uzyskanego z kompletem zmiennych. Im większy błąd po odrzuceniu zmiennej, w stosunku do pierwotnego błędu, tym bardziej wrażliwa jest sieć na brak tej zmiennej. Jeżeli iloraz błędów wynosi 1 lub jest nawet mniejszy, to usunięcie zmiennej nie ma wpływu na jakość sieci a nawet poprawia jej jakość.

Dane przedstawione w tabeli 2 pokazują dużą wrażliwość sieci na wszystkie zaproponowane parametry wejściowe, wśród których wyraźnie wyróżnia się osypliwosć i zagęszczenie. Wytrzymałość na rozciąganie  $R_m^w$  jest parametrem o najmniejszym oddziaływaniu na predykcję sieci i może być brana pod uwagę w przypadku redukcji ilości neuronów wejściowych w celu uproszczenia struktury sieci.

Tabela 2.  
Analiza wrażliwości sieci neuronowych na parametry masy

Nazwa sieci	Miara wrażliwości sieci na wybrane właściwości masy						
	Q	P <sup>w</sup>	R <sup>w</sup> <sub>C</sub>	R <sup>w</sup> <sub>M</sub>	R <sup>w</sup> <sub>P</sub>	Z	S
1.MLP 7-19-1	169,672	82,6678	9,0318	1,174124	134,5562	143,94	2188,735
2.MLP 7-12-1	359,200	171,7424	21,9157	3,986822	234,2631	1023,75	6054,136
3.MLP 7-18-1	125,989	38,7477	7,2049	1,048626	50,9379	648,55	1845,241
4.MLP 7-22-1	2884,192	185,8513	44,1385	8,792164	487,4788	1004,72	6028,084
5.MLP 7-20-1	293,737	85,0375	146,5530	1,794755	35,3758	19305,33	2587,766
6.MLP 7-8-1	244,258	155,1530	26,2979	1,811465	37,7904	107,08	1339,016
7.MLP 7-15-1	102,524	107,0288	13,8996	1,021880	106,1709	206,20	1722,746
8.MLP 7-12-1	199,951	188,6687	8,6761	2,627012	94,0629	591,72	2869,694
9.MLP 7-24-1	241,966	71,3200	32,7840	4,850252	115,2891	1063,92	3665,957
10.MLP 7-8-1	218,182	67,8113	9,4547	1,364985	81,9740	281,17	2130,053

Na rysunku 1 przedstawiony jest wykres zależności przewidywanych wartości wilgotności dla najlepszych modeli sieci od wartości określonych doświadczalnie, który pokazuje bardzo dobre odwzorowanie predykowanego parametru.



Rys. 1. Zależności przewidywanych wartości wilgotności dla najlepszych modeli sieci od wartości określonych doświadczalnie

## 5. PODSUMOWANIE

Na podstawie wstępnych symulacji z wykorzystaniem sztucznych sieci neuronowych stwierdzono, że mogą one stanowić interesujące narzędzie IT wspierające kontrolę procesów przygotowania masy formierskiej. Wymagane jest wykonanie dalszych badań w celu odnalezienia układów najlepiej odwzorowujących zachowania syntetycznych mas formierskich. Określenie parametrów masy formierskiej, które są szczególnie wrażliwe na zawartość lepszca aktywnego i wody umożliwi zbudowanie modeli sieci, które mogą być użyteczne w odlewniach.

## LITERATURA

- [1] Ignaszak Z., Sika R.: System do eksploracji wybranych danych produkcyjnych oraz jego testowanie w odlewni. *Archiwum Technologii Maszyn i Automatyzacji*, 28, 1, 2008, p. 61 - 72.
- [2] Ignaszak Z., Ciesiołka J. i in.: Kompleksowe zastosowanie metod badań nieniszczących do optymalizacji technologii i kosztów wytwarzania odlewów, w aspekcie wzrostu efektywności wykorzystania komputerowych systemów symulacyjnych, raport końcowy projektu celowego nr 6 T08 2003 C 06228, Poznań - Śrem 2007 (maszynopis).
- [3] Rojek-Mikołajczak I.: Integracyjna rola baz danych w przedsiębiorstwie, w: *Computer Integration in Manufacturing*, Poznań 1997.
- [4] Bramczewski K., Idee M., Szwajkowski S.: System pomiaru i rejestracji temperatury zalewania form, instrukcja obsługi programu RTO PC Soft s.c, Piła 1996.
- [5] Sika R.: Studium nad strukturą systemu SAP R/3 i możliwości jego dostosowania do zarządzania oraz sterowania jakością w Odlewni Żeliwa ŚREM S.A., praca dyplomowa pod kierunkiem Z. Ignaszaka, Politechnika Poznańska, Wydział Budowy Maszyn i Zarządzania 2006.
- [6] Sika R., Ignaszak Z.: Po wdrożeniu programu KonMas-final -jego wykorzystanie do analizy procesu produkcji odlewów na wydziale W6 - Odlewni Żeliwa ŚREM S.A., w: *XI International Symposium - Modeling of casting and foundry processes*, 26<sup>TM</sup> 27 October 2006, Poznań-Śrem (Poland).
- [7] Łybacki W., Zawadzka K.: Wspomaganie diagnostyki wad odlewów narzędziami zarządzania jakością, *Archiwum Technologii Maszyn i Automatyzacji*, 28, 1, 2008, s. 89 - 101.
- [8] [fluid.ippt.gov.pl/metro/CDROM-PL/kursy/METRO-pdf-pl/metro-ippt-lecture-mp2pl.pdf](http://fluid.ippt.gov.pl/metro/CDROM-PL/kursy/METRO-pdf-pl/metro-ippt-lecture-mp2pl.pdf).
- [9] Hülya Kaçar Durmuş, Erdoğan Özkaya, Cevdet Meri Ç: The use of neural networks for the prediction of wear loss and surface roughness of AA 6351 aluminium alloy. *Materials& Design*, 27, 2006, p. 156-159.
- [10] Mahesh B. Parappagoudar D.K. Pratihari, Datta G.L.: Forward and reverse mappings in green sand mould system using neural networks. *Applied Soft Computing*, 8, 2008, p. 239-260.
- [11] Perzyk M., Kochański A. W.: Prediction of ductile cast iron quality by artificial neural networks. *Journal of Material Processing Technology*, 109, 2001, p. 305-307.

[12]Perzyk M., Biernacki R., KOCHAŃSKI A.: Modeling of manufacturing processes by learning systems: The naïve Bayesian classifier versus artificial neural networks. Journal of Material Processing Technology, 164–165,2005, p. 430–1435.

*Praca naukowa finansowana ze środków na naukę w latach 2008-2011 jako projekt badawczy  
nr N N508 387335*