

ISTOTNOŚĆ WZGLĘDNA SYGNAŁÓW WEJŚCIOWYCH SIECI NEURONOWEJ

MARCIN PERZYK, ANDRZEJ KOCHAŃSKI, JACEK KOZŁOWSKI

RELATIVE IMPORTANCE OF INPUT SIGNALS OF NEURAL NETWORK

Abstract

Several types of relative importance factors of input signals of MLP type neural network are analyzed and assessed using simulated training sets. Behavior of the factors for characteristic cases of synergetic influences of input signals on network output are presented. Difficulties in utilization of the importance factors for detection of casting defects resulting from manufacturing process are discussed.

1. WSTĘP

Doświadczenia autorów zdobyte w ubiegłych latach w pracach prowadzonych dla przemysłu pokazały, że istotnym problemem jest wnioskowanie na podstawie nauczonej sieci neuronowej, mające na celu uzyskanie lub poszerzenie wiedzy o modelowanym procesie lub zjawisku. Jednym z zadań takiego wnioskowania jest określenie istotności sygnałów wejściowych, czyli wskazanie wielkości odgrywających największą czy przynajmniej bardzo znaczącą, lub też najmniejszą - znikomą bądź żadną, rolę w procesie. W pierwszym przypadku jest to pomocne np. w wykrywaniu przyczyn awarii urządzeń, zakłóceń procesów technologicznych, określaniu parametrów procesu technologicznego decydujących o jakości wyrobu i w innych tego typu sytuacjach. W drugim może służyć do redukcji liczby sygnałów wejściowych, co m. in. oznacza uproszcze-

nie procedur rejestrowania i kontrolowania parametrów procesu.

W pracy dotyczącej identyfikacji przyczyn powstawania wady typu porowatość w odlewach staliwnych (Kochański i Perzyk 2002, Perzyk i Kochański 2002, Perzyk i Kochański 2003), napotkano na trudności z określeniem ważności sygnałów wejściowych. Uszeregowanie sygnałów wg ich istotności miało we wstępnej fazie projektu posłużyć do wyeliminowania nieistotnych sygnałów wejściowych, a w drugiej do wyróżnienia jednego (bądź kilku) sygnału odpowiadającego za wystąpienie wady. Na rysunku 1 przedstawiono trzy przykładowe wykresy względnej istotności sygnałów wejściowych sieci. Wynik 1 i Wynik 2 otrzymano dla tej samej definicji współczynnika istotności ale dla dwóch losowo wybranych uczeń sieci. Wynik 3 uzyskano dla tej samej nauczonej sieci co Wynik 2, ale dla inaczej zdefiniowanego współczynnika istotności.

M. Perzyk, Instytut Technologii Materiałowych Politechniki Warszawskiej, M.Perzyk@wip.pw.edu.pl; A. Kochański, J. Kozłowski,


Widoczna jest całkowita nieprzydatność takich wykresów, zmieniających się diametralnie zarówno dla różnych uczeń sieci, jak i dla różnych metod określania istotności. Ostatecznie do analizy znaczenia sygnałów wejściowych i diagnozowania przyczyn powstawania wady w odlewie wykorzystano inne metody analizy przewidywań sieci neuronowych, opisane szczegółowo w (Perzyk i Kochoński 2003).

Negatywne doświadczenia ze współczynnikami istotności względnej stały się inspiracją do podjęcia niniejszej pracy, której przedmiotem jest ocena metod ilościowego określania względnego wpływu wielkości wejściowych sieci na wartość wielkości wyjściowej. Przyjętą miarą wpływu danego sygnału wejściowego (lub grupy sygnałów) na wielkość wyjściową sieci jest maksymalna zmiana tej wielkości wyjściowej możliwa do uzyskania przy dowolnych, mieszczących się w rzeczywistych granicach, zmianach wartości analizowanego sygnału lub grupy sygnałów.

W pracy uwzględniono m.in. współdziałanie sygnałów wejściowych, rozumiane jako zjawisko polegające na tym, że jednocześnie działanie czynników jest skuteczniejsze niż ich oddzielne działania. Przez „działanie” rozumie się wpływanie na zmiany wielkości wyjściowej sieci, zaś „czynnikami” są zmiany sygnałów wejściowych, tak, jak to określono powyżej.

2. METODYKA BADAŃ

Prowadzone badania obejmowały przygotowanie zbiorów uczących i nauczanie zbudowanych sztucznych sieci neuronowych oraz określenie względnej istotności poszczególnych sygnałów wejściowych i ich łącz-



Rysunek 1. Wykresy współczynników istotności względnej sygnałów wejściowych sieci dla porowatości: Wynik 1 i Wynik 2 – dwa losowo wybrane uczenia sieci, jedna metoda obliczania współczynnika istotności, Wynik 2 i Wynik 3 – jedno uczenie sieci, dwie różne metody obliczania współczynników istotności.

nego wpływu na sygnał wyjściowy, z wykorzystaniem analizowanych współczynników istotności.

2.1. Architektura i metodyka uczenia sztucznych sieci neuronowych

Jednym z głównych problemów występujących przy stosowaniu sztucznych sieci neuronowych jest to, że model sieci neuronowej nie jest modelem jednoznacznym. Postawione zadanie mogą realizować jednakowo dobrze sieci o różnej architekturze, topologii połączeń, uczone różnymi zbiorami danych. Ponadto dla danej sieci poszczególne uczenia prowadzą do różnych wartości wag synaps, związanych z osiąganiem minimów lokalnych błędów sieci. W trakcie prowadzonych badań zbudowano i nauczono sieci typu MLP, o różnej architekturze. Ponieważ nie stwierdzono wpływu zwiększenia liczby warstw ukrytych na uzyskiwane wyniki, w badaniach wykorzystano SSN z jedną warstwą ukrytą. Nie zaobserwowano również wpływu zwiększenia liczby neuronów ukrytych powyżej wartości równej liczbie neuronów w warstwie wejściowej, którą ostatecznie zastosowano. Użyto funkcję aktywacji neuronów typu sigmoidalnego. W niniejszych badaniach przyjęto generalną zasadę wielokrotnego uczenia sieci. Dla każdego przypadku wykonano po 10 uczeń, a w analizach wykorzystywano średnie przewidywania sieci oraz ich rozrzut, zdefiniowany przez maksymalną różnicę danej wartości, jaka wystąpiła w 10 elementowym zbiorze.

Do uczenia sieci wykorzystano specjalnie utworzone oprogramowanie szczegółowo przedstawione w (Perzyk i Kochoński 2002b). Proces uczenia przebiega dwuetapowo. Pierwszy, wstępny etap wykorzystuje metodę symulowanego wyżarzania dokładnie opisaną w (Masters 1993). Ma on na celu określenie optymalnych wag początkowych dla etapu drugiego, wykorzystującego klasyczną metodę propagacji wstecznej błędu. W metodzie symulowanego wyżarzania stosowano 2 „temperatury”, równe 5 i 1, wykonując zasadniczo po 100 iteracji w danej temperaturze. Każdorazowe zmniejszenie błędu w danej temperaturze zwiększało liczbę iteracji w tej temperaturze 1,2 raza.

Zgodnie z sugestią zawartą w pracy (Glorfeld 1996), jako kryterium zakończenia uczenia sieci w metodzie gradientowej (w naszym przypadku metodzie propagacji wstecznej błędu) nie przyjmowano wzrostu błędu sieci dla zbioru weryfikującego, lecz doprowadzano proces uczenia do stabiliza-



cji, tj. momentu, gdy dalsze iteracje nie będą przynosiły znaczących zmian wartości wag sieci. Jako kryterium zakończenia uczenia niniejszej pracy przyjęto zmianę błędu średniokwadratowego w kolejnej iteracji poniżej $5 \cdot 10^{-6}$.

2.2. Metodyka określania współczynników istotności sygnałów wejściowych

W pracy zastosowano specjalnie tworzone zbiory uczące otrzymywane drogą symulacji, o założonych istotnościach sygnałów wejściowych i ich jednoczesnym wpływie na wielkość wyjściową sieci. Liczebność zbiorów wynosiła w większości przypadków 1000 rekordów. Metodyka ich generowania była następująca:

- Przyjęcie dowolnego wzoru elementarnego typu $Y = f(X_1, X_2, \dots)$
- Generowanie liczb losowych X_1, X_2, \dots o rozkładzie prostokątnym i obliczanie wyjść Y dla każdego zestawu tych liczb
- Wprowadzenie zakłóceń losowych zgodnie z rozkładem normalnym, o maksymalnej wartości $\pm 20\%$, dla wygenerowanych liczb X_1, X_2, \dots

Uwzględniono 4 różne definicje współczynników istotności względnej sygnałów wejściowych. Wielkości określające te współczynniki były następujące:

Typ A: Różnica pomiędzy średniokwadratowym błędem sieci dla danych uczących, a błędem dla danych różniących się od zbioru uczącego tym, że rozpatrywane wejście ustalone było na stałym, minimalnym poziomie (współczynnik często spotykany w literaturze).

Typ B: Maksymalny przyrost wartości wyjścia z sieci uzyskiwany przy zmianie danego wejścia, przy pozostałych wejściach ustalanych wielokrotnie losowo (po 1000 razy, propozycja własna).

Typ C: na podstawie analizy wag sieci wg Garsona (Garson 1991); wielkość określająca współczynnik istotności obliczana wg wzoru:

$$I_{x_i} = \sum_{j=1}^{N_u} \left\{ \frac{|W_{ij}^{(x \rightarrow u)}|}{\sum_{i=1}^{N_x} |W_{ij}^{(x \rightarrow u)}|} \cdot |W_j^{(u \rightarrow y)}| \right\} \quad (1)$$

gdzie: w oznaczają wagi sieci, x, u, y – warstwy, odpowiednio, wejściową, ukrytą i wyjściową, zaś N – liczby neuronów w odpowiednich warstwach.

Typ D: Na podstawie analizy wag sieci, ale z uwzględnieniem znaku wag poprzez funkcję sigmoidalną (propozycja własna). Istotą tej propozycji jest próba uniknięcia wady wzoru Garsona polegającej na utracie części informacji zawartej w sieci, związanej z obliczaniem bezwzględnych wartości wag sieci w połączeniach typu $x-u$ oraz $u-y$. Zmodyfikowany wzór na wielkość

określającą współczynnik istotności jest następujący:

$$I_{x_i} = \sum_{j=1}^{N_u} \left\{ \text{sig}[W_{ij}^{(x \rightarrow u)}] \cdot \text{sig}[W_j^{(u \rightarrow y)}] \right\} \quad (2)$$

gdzie oznaczenia jak we wzorze (1).

Wszystkie wielkości normalizowano przez podzielenie ich przez wartość maksymalną spośród wartości otrzymanych dla wszystkich wejść. W ten sposób współczynnik istotności dla najbardziej znaczącego sygnału wejściowego zawsze był równy 1.

Warto zwrócić uwagę, że istotności typu A i B opierają się na odpytywaniu sieci, natomiast istotności typu C i D – wyłącznie na wartościach wag.

3. WYNIKI

3.1. Ocena przydatności współczynników istotności

Przeprowadzono wstępną ocenę współczynników istotności zdefiniowanych w poprzednim rozdziale. W tym celu wygenerowano zbiór uczący na podstawie wzoru typu:

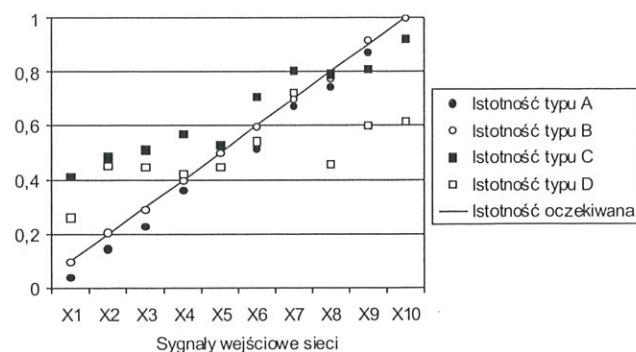
$$Y = a_1 \cdot X_1 + a_2 \cdot X_2 + \dots + a_{10} \cdot X_{10} \quad (3)$$

gdzie: $a_1 = 1, a_2 = 2, \dots, a_{10} = 10$.

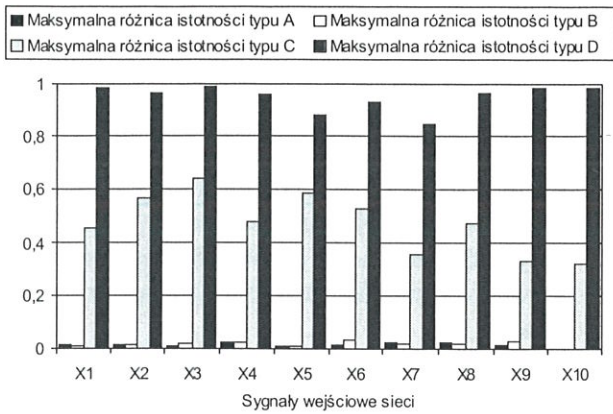
Na rysunku 2 pokazano wartości otrzymanych współczynników istotności względnych (punkty) oraz wartości, jakich należałoby oczekiwać na podstawie wzoru (3) (linia prosta).

Na rysunku 3 przedstawiono porównanie rozrzutów współczynników istotności z 10 kolejnych uczeń sieci neuronowej.

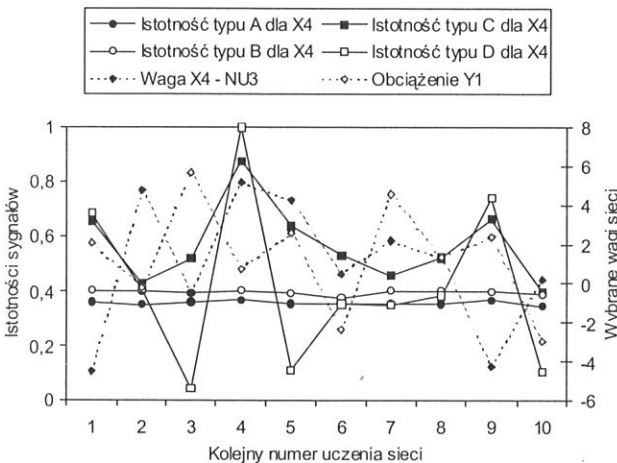
Widoczne jest, że najlepsze wyniki uzyskano obliczając współczynniki istotności względnej wykorzystując metody polegające na odpytywaniu sieci (typ A i B). Współczynniki, do których obliczania wykorzystuje się tylko wagi sieci, dają bardzo duże różnice wyników w poszczególnych uczeniach, zaś ich średnie war-



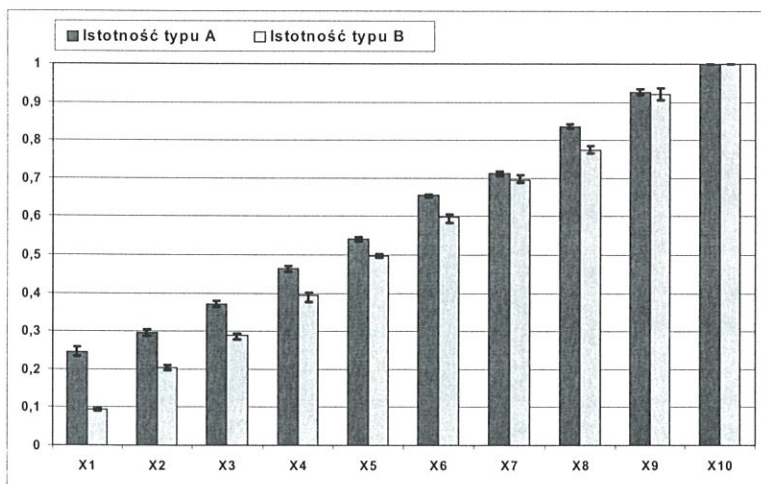
Rysunek 2. Porównanie średnich (z 10 uczeń) współczynników istotności względnych sieci neuronowej obliczanych metodami podanymi w rozdziale 3.2, dla zbioru uczącego wygenerowanego wg wzoru (3).



Rysunek 3. Porównanie rozrzutów (z 10 uczeń) współczynników istotności względnej sieci neuronowej obliczanych metodami podanymi w rozdziale 3.2, dla zbioru uczącego wygenerowanego wg wzoru (3).



Rysunek 4. Współczynniki istotności względnej dla losowo wybranego neuronu wejściowego (X_4) obliczone metodami podanymi w rozdziale 3.2 oraz wybrane wagi sieci neuronowej otrzymywane w kolejnych uczeniach dla zbioru uczącego wygenerowanego wg wzoru (3).



Rysunek 5. Porównanie istotności typu A i B wraz z zaznaczonymi rozrzutami wartości obliczonych dla zbioru wygenerowanego wg wzoru (3).

tości znacznie odbiegają od oczekiwanych. Częściowo wyjaśnia to wykres pokazany na rysunku 4, pokazujący wyniki kolejnych uczeń sieci.

Sieć uczy się za każdym razem zupełnie inaczej, co jasno widać na przykładzie zasadniczo różniących się wag sieci dla kolejnych uczeń. Zmianom tym towarzyszą duże zmiany wartości współczynników istotności typu C i D. Warto zauważyć jest to, że współczynniki oparte na odpytywaniu sieci (typ A i B) dają wartości praktycznie takie same dla każdego uczenia, pomimo że do ich obliczania wagi sieci są oczywiście także wykorzystywane. Do dalszych badań przyjęto zatem tylko dwa pierwsze typy współczynników istotności. Na rysunku 5 przedstawiono porównanie istotności typu A i B z naniesionymi wartościami ich rozrzutu, w postaci wykorzystywanej w dalszych analizach.

Powyższe wnioski potwierdziły się także dla innych zbiorów uczących. I tak np. dla wzoru wyjściowego typu:

$$Y_1 = a_1 \cdot X_1 + a_2 \cdot X_2 \dots a_5 \cdot X_5; \quad (4)$$

$$Y_2 = a_6 \cdot X_6 + a_7 \cdot X_7 \dots a_{10} \cdot X_{10}$$

przedstawiającego sieć z dwoma wyjściami uzależnionymi tylko od części sygnałów wejściowych, otrzymano wyniki pokazane na rysunku 6.

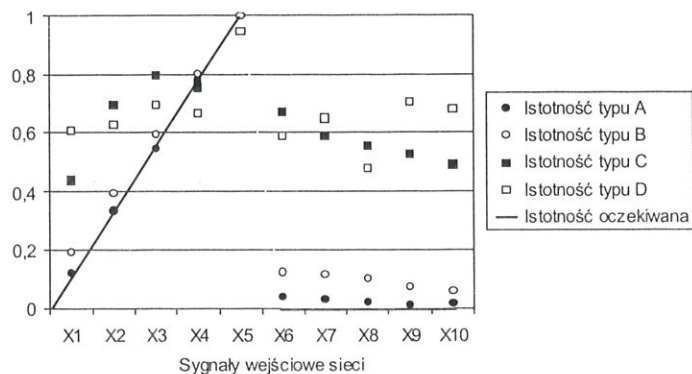
Przedstawiony wykres punktowy obliczonych istotności typu A i B dla wyjścia Y_1 dość dobrze odwzorowuje rozkład wartości oczekiwanych (przedstawionych w postaci linii). Osiągnięte wartości dla sygnałów $X_1 \dots X_5$ pokrywają się z wartościami spodziewanymi (istotność typu A wykazuje większą zgodność), a dla sygnałów $X_6 \dots X_{10}$ są zbliżone do zera, co również odpowiada oczekiwaniom. Istotności typu C i D mieszczą się w przedziale 0,4–0,8 dla wszystkich sygnałów $X_1 \dots X_{10}$, wskazując na ich nie odpowiadający stanowi faktycznemu wpływ na wartość sygnału wyjściowego.

3.2. Zachowanie się współczynników istotności względnej dla zbiorów symulowanych różnego typu


We wszystkich dalszych analizach zakładano, że zmienne niezależne (wejścia do sieci) mogą przyjmować wartości z przedziału (0–1). Na tym etapie pracy, dla uproszczenia rozważań i obliczeń, przyjmowano do generacji zbiorów symulowanych wyłącznie funkcje monotoniczne.

Wpływ kształtu zależności pomiędzy wejściem a wyjściem sieci stwierdzono na podstawie zbioru uczącego wygenerowanego wg wzoru:

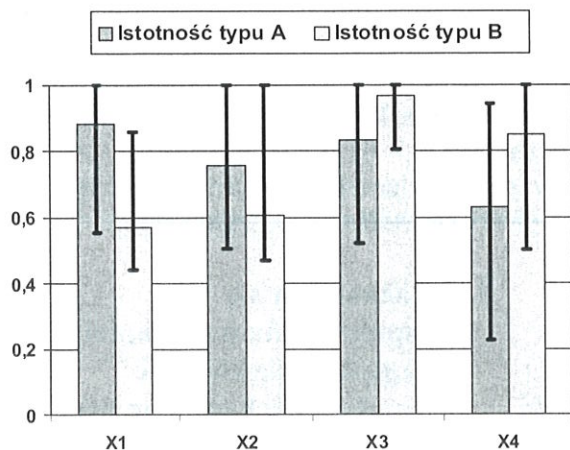
$$Y = X_1^{0,25} + X_2^{0,25} + X_3^4 + X_4^4 \quad (5)$$



Rysunek 6. Porównanie średnich (z 10 uczeń) współczynników istotności względnych sieci neuronowej dla wyjścia sieci Y , obliczanych metodami podanymi w rozdziale 3.2, dla zbioru uczącego wygenerowanego wg wzoru (4).



Rysunek 7. Przebieg zależności wyjścia sieci od czterech sygnałów wejściowych wg wzoru (5).



Rysunek 8. Wykresy istotności względnych sygnałów sieci (wartości średnie oraz maksymalne różnice z 10 uczeń) dla zbioru wygenerowanego wg wzoru (5).

dającego zależność pomiędzy wyjściem a wejściem jak pokazano na rysunku 7. Wykresy współczynników istotności typu A i B pokazano na rysunku 8.

Pomimo, że definicje współczynników istotności A i B opierają się tylko na wyznaczaniu maksymalnych zmian wyjścia dla danego wejścia oraz braku we wzorze sprzężeń pomiędzy zmiennymi niezależnymi, to istotności względne sygnałów o przebiegach „wkle-

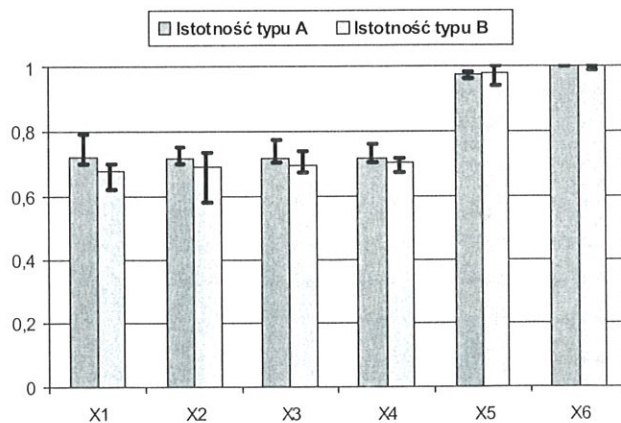
ślach do dołu” są istotnie większe. Zdaniem autorów wynik ten spowodowany jest sposobem nauczania się sieci w warunkach występowania celowo wprowadzonych zakłóceń losowych, dających istotne efekty w przypadku dużych gradientów funkcji (jak w przypadku zależności typu x_4). Potwierdzałyby to znacznie większe, niż w przypadku zależności liniowych, rozrzuty wartości współczynników istotności dla poszczególnych uczeń.

W ramach niniejszego projektu przeprowadzono badania z wykorzystaniem zbiorów uczących uzyskanych drogą symulacji dla szeregu różnych postaci zależności między wejściem a wyjściem sieci, tj. typu $Y = f(X_1, X_2, \dots)$. Poniżej przedstawiono wyniki dla niektórych z nich, ilustrujące charakterystyczne zachowania się współczynników istotności względnej w warunkach współdziałania, także typu synergicznego, sygnałów wejściowych.

Przykład 1. Zbiór uczący wygenerowano wg wzoru:

$$Y = \frac{X_1 + 1}{X_2 + 1} + \frac{X_3 + 1}{X_4 + 1} + X_5 + X_6 \quad (6)$$

Występuje tu współdziałanie wszystkich 6 sygnałów X_1, X_2, X_3, X_4, X_5 i X_6 . Poprzez zmianę każdego z 6 wejść możliwe jest osiągnięcie przyrostu wyjścia Y równego 1, jednakże w przypadku sygnałów X_1, X_2, X_3 oraz X_4 jest ono uwarunkowane przez wartości innego z tych sygnałów (X_1 przez X_2 i na odwrót oraz X_3 przez X_4 i na odwrót). Osiągnięcie takiego samego przyrostu wyjścia Y przez X_5 lub X_6 jest nie uwarunkowane i sygnały te osiągnęły wyższe wartości współczynników istotności (patrz rysunek 9), pomimo że sygnały X_1, X_2, X_3 oraz X_4 mogą być w konkretnych przypadkach równie znaczące dla wyniku.



Rysunek 9. Wykresy istotności względnych sygnałów sieci (wartości średnie oraz maksymalne różnice z 10 uczeń) dla zbioru wygenerowanego wg wzoru (6).

Przykład 2. Zbiór uczący wygenerowano wg wzoru:

$$Y = (a \cdot X_1)^4 + (b \cdot X_2)^4 + (c \cdot X_3 + d \cdot X_4)^4 \quad (7)$$

gdzie $a = b = c = d = 1$

Występuje tu silnie wspomagające się wzajemnie działanie sygnałów X_3 i X_4 . Maksymalne przyrosty wyjścia Y są znacznie większe wskutek przyrostów X_3 lub X_4 niż X_1 lub X_2 , ale tylko pod warunkiem, że drugie z tych wejść (X_3 lub X_4) osiągnie wartość równą 1. Natomiast maksymalne przyrosty wyjścia Y wskutek przyrostów X_3 lub X_4 są identyczne jak wskutek X_1 lub X_2 , ale tylko pod warunkiem, że drugie z tych wejść (X_3 lub X_4) przyjmie wartość równą 0. Współczynniki istotności względnej przedstawione na rysunku 10 sugerują, że sygnały X_3 i X_4 są *generalnie* zdecydowanie istotniejsze.

Przykład 3. Zbiór uczący wygenerowano wg wzoru:

$$Y = (a \cdot X_1)^4 + (b \cdot X_2)^4 + (c \cdot X_3 + d \cdot X_4)^4 \quad (8)$$

gdzie: $a = 2$; $b = 1,8$; $c = d = 1$, a więc: $a_4 = (c + d)^4$

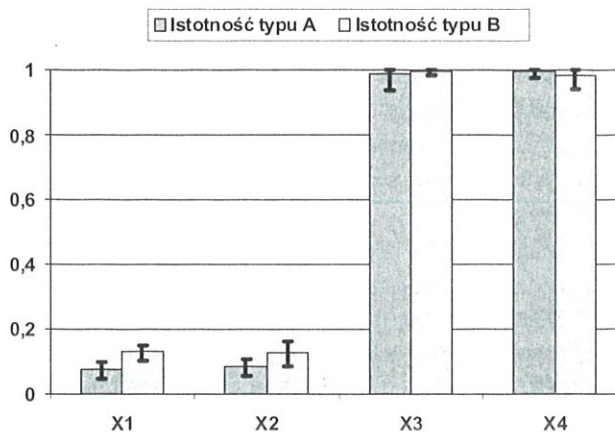
Podobnie jak w przykładzie 2 występuje tu silnie wspomagające się wzajemnie działanie sygnałów X_3 i X_4 . Maksymalne przyrosty Y wskutek łącznego przyrostu X_3 i X_4 są tu jednak takie same, jak wskutek przyrostu pojedynczego sygnału X_1 . Przyrost Y wskutek przyrostu pojedynczego sygnału X_2 jest mniejszy, ale jego istotność względna jest większa niż istotności pojedynczych sygnałów X_3 i X_4 (patrz rysunek 11).

W powyższych rozważaniach przyjęto intuicyjnie, że znaczenie danej wielkości wejściowej (lub kilku wielkości wejściowych) jest zdefiniowane poprzez maksymalną zmianę danego wyjścia sieci, jaka można osiągnąć przy maksymalnych zmianach tej (tych) wielkości wejściowej (wejściowych). Definicja ta jest zgodna z oczekiwaniami praktycznymi, które najczęściej sprowadzają się do odpowiedzi na pytanie, co w maksymalnym stopniu może zaważyć na przebiegu modelowanego procesu.

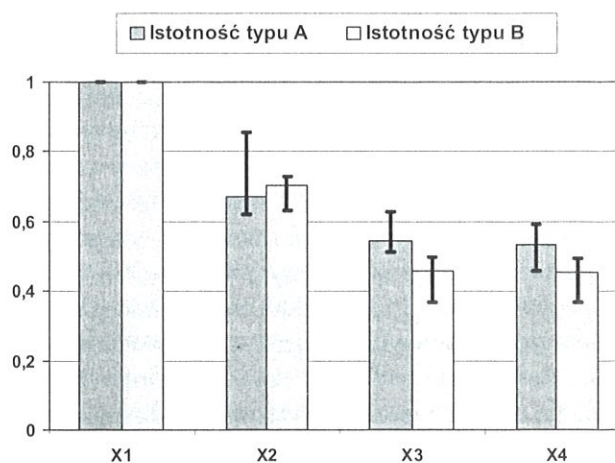
Z analizy pokazanych na rysunkach 8–11 wykresów istotności względnych wynika, że nie można na ich podstawie wnioskować, które sygnały wejściowe działają synergicznie, a więc, między innymi, jaki efekt przyniosą działając łącznie.

3.3. Analiza istotności względnej dla zbiorów rzeczywistych


Na rysunku 12 przedstawiono wykres istotności względnej pierwiastków chemicznych w żelazie sferoidalnym dla jego wytrzymałości sporządzony na podstawie wyników przemysłowych uzyskanych w pracy (Perzyk i Kochański 2001).



Rysunek 10. Wykresy istotności względnych sygnałów sieci (wartości średnie oraz maksymalne różnice z 10 uczeń) dla zbioru wygenerowanego wg wzoru (7).



Rysunek 11. Wykresy istotności względnych sygnałów sieci (wartości średnie oraz maksymalne różnice z 10 uczeń) dla zbioru wygenerowanego wg wzoru (8).



Rysunek 12. Istotności względne pierwiastków chemicznych w żelazie sferoidalnym dla jego wytrzymałości (dane przemysłowe zaczerpnięte z pracy (Perzyk i Kochański 2001)).

Widoczne jest wyróżniające się działanie miedzi, co zgodne jest z praktyką stosowaną w odlewni. Jednakże wnioskowanie na podstawie wykresu o możliwo-

ściach decydującego wpływania na wytrzymałość żeliwa przez odpowiednią kombinację innych pierwiastków (np. niklu i chromu) nie jest możliwe. Zachodzić tu może sytuacja podobna jak na rysunku 11, gdzie odpowiednikami tych pierwiastków są sygnały X_3 i X_4 , zaś odpowiednikiem miedzi – sygnał X_1 .

Na rysunku 13 przedstawiono wykres istotności względnej dla przyczyn porowatości gazowej w odlewach stalowych, sporządzony na podstawie wyników przemysłowych uzyskanych w pracy, która stała się inspiracją do podjęcia niniejszego projektu (Kochański i Perzyk 2002, Perzyk i Kochański 2002, Perzyk i Kochański 2003).

Widoczne są bardzo duże rozrzuty wyników uzyskiwanych w poszczególnych uczeniach sieci oraz brak zdecydowanie wyróżniającego się znaczenia zespołu sygnałów, które zostały zidentyfikowane jako składające się na przyczynę braków, przy zastosowaniu innych metod analizy wyników (Kochański i Perzyk 2002, Perzyk i Kochański 2002, Perzyk i Kochański 2003). Czynnikiem tymi było 7 sygnałów, wpływających na ciśnienie pary wodnej w formie w chwili zalewania, a mianowicie: wilgotność masy formierskiej w chwili formowania, przepuszczalność masy, wytrzymałość (czynnik pośrednio wskazujący na wilgotność), temperatura otoczenia przed zmianą zalewającą w odlewni, temperatura otoczenia na zmianie zalewającej w odlewni, czas od zaformowania do zalania oraz wilgotność powietrza przed zmianą zalewającą.

Na rysunku 13 występuje dość wyróżniająca się istotność sygnału „Brygada formująca”, który także mógł być ważną przyczyną powstawania wady.

W ramach niniejszej pracy postanowiono wygenerować symulowane zbiory uczące, które naśladowałyby charakter rozkładów istotności uzyskany z danych przemysłowych i tym samym pomogłyby w wyjaśnieniu trudności interpretacyjnych wykresu sporządzonego na podstawie danych przemysłowych, pokazanego na rysunku 13. W tym celu przyjęto wstępnie wzór typu:

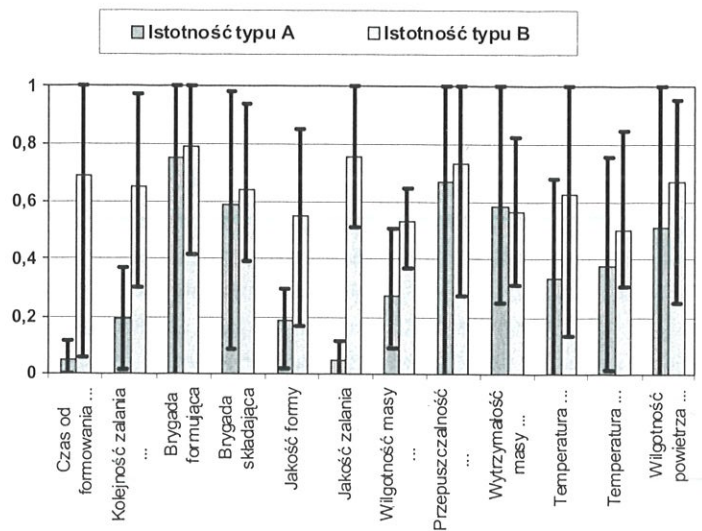
$$Y = A + B + C \quad (9)$$

gdzie: $A = (a_1 \cdot X_1)^3 + \dots + (a_5 \cdot X_5)^3$, $B = (a_6 \cdot X_6)^3$, $C = (a_7 \cdot X_7 + \dots + a_{12} \cdot X_{12})^3$

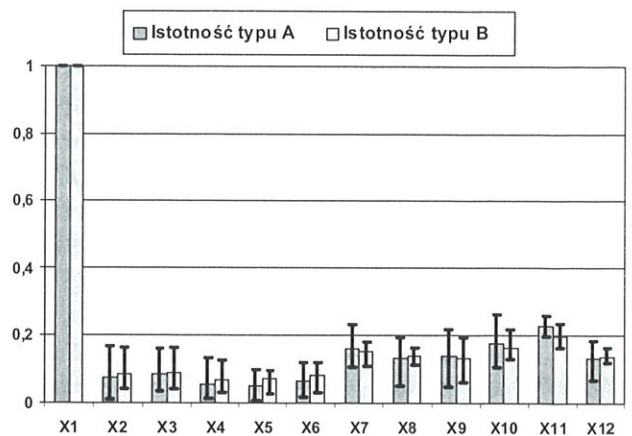
$$a_1 = 6 \quad a_2 \dots a_6 = 0,001 \quad a_7 \dots a_{12} = 1$$

Otrzymane współczynniki istotności względnej pokazano na rysunku 14. Ilustrują one fakt wyróżniającego się działania jednego sygnału X_1 , a także nieco większe istotności sygnałów $X_7 \dots X_{12}$.


Ponieważ dane przemysłowe odnoszące się do wyjścia sieci miały charakter binarny (0 – brak wady, 1 – wystąpienie wady) wygenerowano inny zbiór uczący



Rysunek 13. Istotności względne parametrów produkcyjnych i środowiskowych związanych z formą odlewniczą dla powstawania wady porowatości gazowej w odlewach stalowych (dane przemysłowe zaczerpnięte z pracy opisaną w publikacjach (Kochański i Perzyk 2002, Perzyk i Kochański 2002, Perzyk i Kochański 2003)).



Rysunek 14. Wykresy istotności względnych sygnałów sieci (wartości średnie oraz maksymalne różnice z 10 uczeń) dla zbioru wygenerowanego wg wzoru (9) – wyjście typu ciągłego.



Rysunek 15. Wykresy istotności względnych sygnałów sieci (wartości średnie oraz maksymalne różnice z 10 uczeń) dla zbioru wygenerowanego wg wzoru (9) – wyjście typu binarnego.

na podstawie wzoru (9) w taki sposób, że:

$$(10) \quad \begin{aligned} Y &= 1 \text{ jeśli } B \text{ lub } C > G, \\ Y &= 0 \text{ jeśli } B \leq G \text{ i } C \leq G \end{aligned}$$

G – wartość graniczna dająca udział wyników $Y = 1$ taki jak w zbiorze przemysłowym.

Otrzymane współczynniki istotności względnej pokazano na rysunku 15. Widoczne jest znaczne zwiększenie rozrzutów wyników dla poszczególnych uczeń, charakterystyczne dla wyników przemysłowych (porównaj rysunek 13).

Podobnie jak tam, wyróżnianie się sygnału pojedynczego (tutaj X_1) jest teraz o wiele mniej wyraźne. Wyróżnił się sygnał X_6 należący do grupy sygnałów o znaczeniu należącym do grupy 5 sygnałów najmniej znaczących w zbiorze symulowanym. Podobnie jak dla danych przemysłowych niemożliwe okazało się wykrycie istotnego współdziałania zespołu parametrów (X_7, \dots, X_{12}).

4. PODSUMOWANIE I WNIOSKI

W pracy przeprowadzono analizę współczynników istotności względnej sygnałów wejściowych sieci neuronowej, stosowanych jako narzędzie służące do ilościowej oceny znaczenia tych sygnałów. Szczególną uwagę poświęcono zachowaniu się tych współczynników w przypadku wzajemnie wspomagającego się działania sygnałów.

Należy zauważyć, że odpowiednio przygotowane symulowane zbiory uczące są w stanie naśladować wyniki uzyskiwane dla danych rzeczywistych. Generalne wnioski wypływające z przeprowadzonych badań i analiz są następujące:

- Współczynniki istotności względnej oparte na odpytywaniu sieci dają bardziej prawidłowe wartości niż obliczane tylko na podstawie wag sieci.
- Współczynniki istotności mogą być mało użyteczne w przypadku wzajemnie wspomagającego się działania sygnałów wejściowych.
- Binarny charakter wyjść sieci neuronowej może powodować większe trudności w uczeniu się sieci, skutkujące znacznym rozrzutem wyników dla poszczególnych uczeń.

- Istnieje potrzeba opracowania algorytmów poszukiwania najbardziej znaczących kombinacji sygnałów wzajemnie się wspomagających.

Należy podkreślić, że poprawna identyfikacja najbardziej znaczących sygnałów wejściowych sieci neuronowej, wspomagająca wykrywanie najbardziej prawdopodobnych przyczyn awarii urządzeń lub zakłóceń procesów technologicznych, w tym metalurgicznych oraz określanie parametrów procesu technologicznego decydujących o jakości wyrobu, powinna w istotny sposób przyczynić się do zwiększenia zakresu zastosowań sztucznych sieci neuronowych.

LITERATURA

- Garson, D., 1991, Implementing neural network connection weights. *AI Expert*, 6 (4), 45-51.
- Glorfeld, L.W., 1996, A Methodology for Simplification and Interpretation of Backpropagation-Based Neural Network Models. *Expert Systems With Applications*, 10 (1), 37- 4.
- Kochański, A., Perzyk, M., 2002, Identyfikacja przyczyn wady porowatości w odlewach stalowych z wykorzystaniem sztucznych sieci neuronowych, *Archiwum Odlewnictwa*, 2, (5), 87-92.
- Masters, T., 1993, *Practical Neural Network Recipes in C++*, Academic Press, 1993.
- Perzyk, M., Kochański A., 2001, Prediction of ductile cast iron quality by artificial neural networks, *J. Mat. Proc. Techn.*, 109 (3), 305 - 307.
- Perzyk, M., Kochański, A., 2002a, Methodology of detection of casting defects causes by neural networks, *Mat. Sci.*, 8, (4), 375 - 379.
- Perzyk, M., Kochański, 2002b, System komputerowy wspomagający projektowanie procesów metalurgicznych wykorzystujący modelowanie sztucznymi sieciami neuronowymi, *Rozdział w monografii Polska metalurgia w latach 1998 - 2002*, red. Świątkowski, K., tom 2. Wyd. Komitet Metalurgii PAN, Kraków, 236-242.
- Perzyk, M., Kochański, A., 2003, Detection of causes of casting defects assisted by artificial neural networks, *J. Eng. Manufacture*, Proceedings of the Institution of Mechanical Engineers, 217, Part B, 1279-284.

Artykuł otrzymano 3 czerwca 2003 r.

