



METRO

MEtalurgiczny TRening *On-line*

Sztuczne sieci neuronowe w analizie procesów odlewniczych

Marcin Perzyk

PW




Edukacja i Kultura



Definicja sztucznej sieci neuronowej



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



Neuron (węzeł sieci)

Synapsa
(połączenie węzłów, także wejście i wyjście sieci)

Synapsy zawierają (przekazują) wartości zmiennych – sygnały oraz stałe modelu - wagi synaps.

Neurony wykonują operacje (działania) matematyczne na tych wielkościach.



Sztuczne sieci neuronowe

Podstawowe zalety



- Zdolność do uczenia się i uogólniania nabytej wiedzy. Sztuczne sieci neuronowe pozwalają na znalezienie prawidłowości w warunkach dużej liczby zmiennych o różnym charakterze. Prawidłowości takie są często niewykrywalne przez zmysły naukowców i inne metody matematyczne.
- Sieć jest odporna na błędy w danych (zaszumienia) oraz błędy pojawiające się w niektórych wagach, czyli błędnie wyznaczonych niektórych stałych modelu.
- Szybkie przetwarzanie informacji, często możliwe w czasie rzeczywistym.



Sztuczne sieci neuronowe

Informacje ogólne




Sieci neuronowe należą do systemów uczących się. Wartości stałych (wag sieci) wyznaczane są na podstawie wyników doświadczeń (przykładów uczących) drogą kolejnych poprawek (korekt) tak, aby wyjścia (odpowiedzi sieci) zbliżały się do wartości rzeczywistych. Jest to tzw. uczenie nadzorowane (inaczej z nauczycielem), spotykane najczęściej.

Przykład zależności opisywanej przez sieć:

$$Y_1 = f_1(X_1, X_2, X_3, \dots) \quad X - \text{sygnały wejściowe (zmiennie niezależne),}$$
$$Y_2 = f_2(X_1, X_2, X_3, \dots) \quad Y - \text{sygnały wyjściowe (zmiennie zależne)}$$

Współczynniki tych równań W (wagi synaps) są znajdowane (korygowane) w procesie uczenia na podstawie różnic pomiędzy wartościami przewidywanymi przez sieć Y , a uczącymi Z (znanymi, zaobserwowanymi):

$$W' = F \{W, (Y - Z)\}$$



Sztuczne sieci neuronowe

Informacje ogólne



Sieci neuronowe mogą realizować kilka *rodzajów zadań*. W modelowaniu procesów technologicznych (produkcyjnych), w tym metalurgicznych i odlewniczych wykorzystywane są:

- **Regresja** inaczej aproksymacja nieznanej funkcji wielu zmiennych (najczęściej), na podstawie znanych obserwacji doświadczalnych.
- **Predykcja**, czyli przewidywanie przyszłych zachowań się systemu na podstawie ciągu wartości z przeszłości z ciągłą adaptacją wag sieci (rzadziej).
- **Wykrywanie wzorców**, umożliwiające grupowanie sygnałów wykazujących podobne cechy (sieci typu Kohonena, stosowane rzadko). Jest to uczenie nienadzorowane, nie wymagające zbioru uczącego typu: wejście – zaobserwowane wyjście.




Sztuczne sieci neuronowe

Informacje ogólne



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

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



Sztuczne sieci neuronowe


Przykład sieci typu MLP



Sieć jednokierunkowa czterowarstwowa realizująca aproksymację funkcji typu:

$$Y1 = f_1 (X1, X2, X3, \dots, X10)$$


$$Y2 = f_2 (X1, X2, X3, \dots, X10)$$



Kolorem **zielonym** oznaczono warstwy ukryte sieci (w tym przypadku występują dwie)


Kolorem **niebieskim** oznaczono warstwę wyjściową

Kolor **czzerwony** oznacza warstwę wejściową, w której neurony nie wykonują żadnych operacji matematycznych



Sztuczne sieci neuronowe

Działanie pojedynczego neuronu




Neuron liniowy:
$$y = \sum_{i=1}^n x_i \cdot w_i + w_0$$

Neuron nieliniowy:
$$y = f\left(\sum_{i=1}^n x_i \cdot w_i + w_0\right)$$

f oznacza tzw. funkcję aktywacji, najczęściej mającą kształt sigmoidalny, np. dany wzorem:

$$f(s) = [1 + \exp(-\alpha \cdot s)]^{-1}$$





Nadzorowane uczenie sieci neuronowej

Istota problemu



Uczenie sieci polega na rozwiązaniu zagadnienia optymalizacyjnego funkcji wielu zmiennych (równej liczbie wszystkich wag synaps plus wyrazów wolnych występujących w całej sieci).

Dążymy do znalezienia takich wartości wag, aby wartość błędu średniokwadratowego E wszystkich odpowiedzi sieci, w stosunku do obserwacji doświadczalnych, była najmniejsza.

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

m – liczba wyjść sieci,

p – liczba prezentacji, czyli rekordów obserwacji doświadczalnych

d – wartości doświadczalne

Y – wartości otrzymywane z sieci



Zasady i praktyka uczenia nadzorowanego sieci neuronowych



Zbiór danych doświadczalnych 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: obliczenie błędu – modyfikacja wag nazywamy *epoką*.

Koniec uczenia następuje najczęściej wówczas, gdy zaczyna rosnąć błąd dla danych weryfikujących. Ma to na celu niedopuszczenie do przeuczenia się sieci, czyli do nadmiernego dopasowania się do danych uczących bez zdolności do generalizacji przewidywań dla innych danych.



Metody uczenia nadzorowanego sieci neuronowych



Znanych jest wiele metod znajdowania minimum błędu sieci, które można podzielić na dwie grupy:

- **Metody gradientowe** (stosowane najczęściej)

Losowo ustala się początkowy zbiór wartości wag, a następnie koryguje się ich wartości tak, aby błąd sieci stale ulegał zmniejszeniu. Prowadzi to często do znajdowania minimum lokalnego tego błędu.

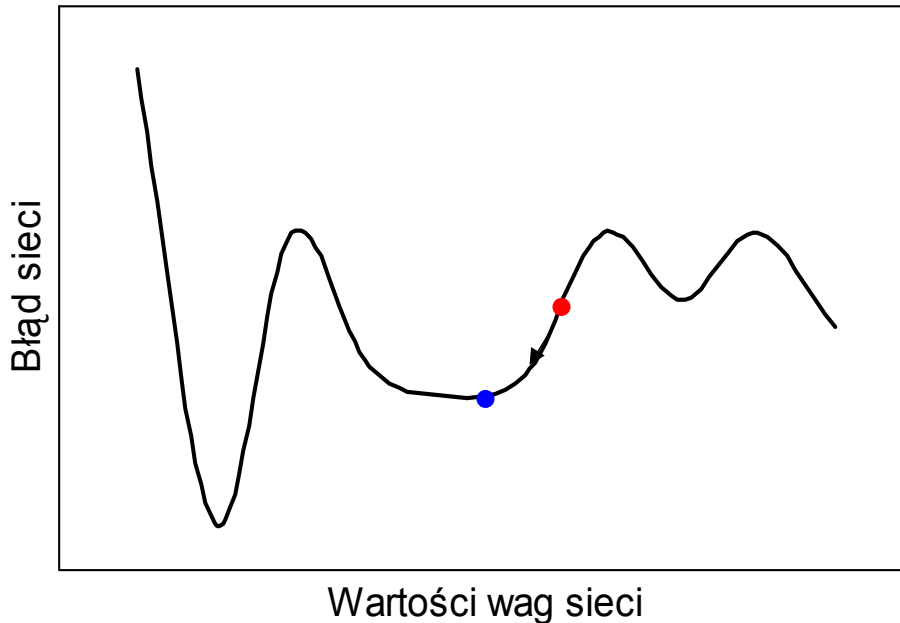
- **Metody poszukujące minimum globalnego błędu** (stosowane rzadko)

Obejmują metodę symulowanego wyżarzania (omówioną dalej) oraz metody ewolucyjne (omówione w innym wykładzie).




Uczenie nadzorowane sieci

Ilustracja metod gradientowych



- Wylosowany punkt startowy
- Osiągnięte najbliższe minimum błędu



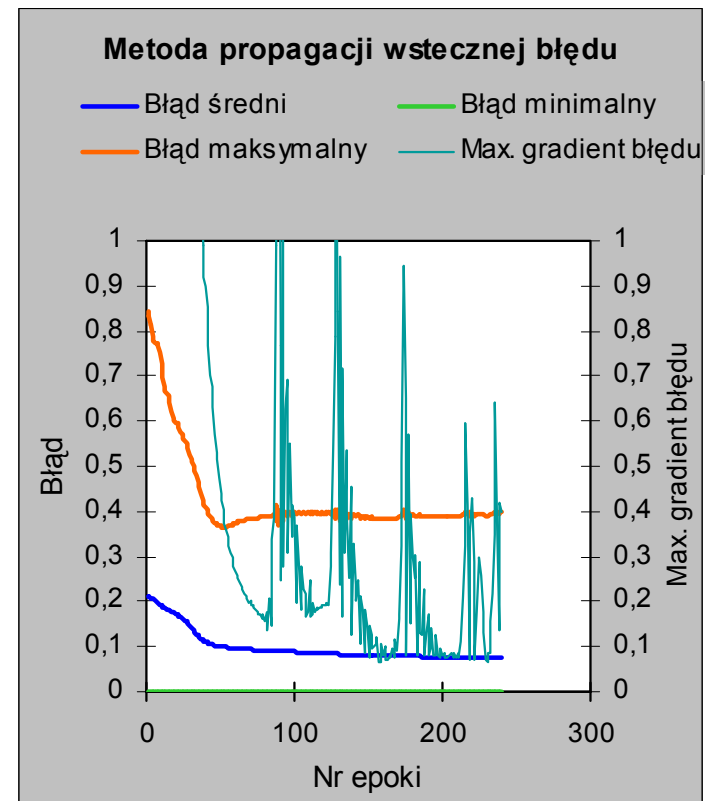
Uczenie nadzorowane sieci

Ilustracja metod gradientowych



Znanych jest wiele metod gradientowych, z których metodą klasyczną i najczęściej stosowaną jest metoda *propagacji wstecznej błędu*.

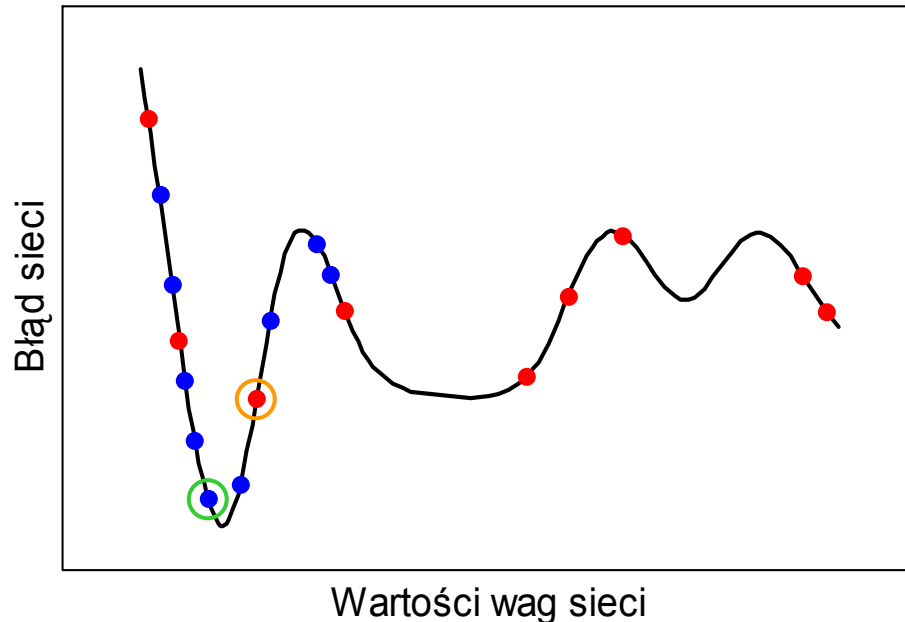
Rysunek przedstawia przykładowy przebieg korekt błędu sieci w kolejnych iteracjach. Dla tych samych danych wylosowanie innego punktu startowego może dać zupełnie inny kształt krzywych.





Uczenie nadzorowane sieci

Ilustracja metody symulowanego wyżarzania



- Losowania w pierwszym (szerszym) zakresie (wyższa temperatura)
- Losowania w następnym (węższym) zakresie (niższa temperatura)

- Najlepszy wynik z pierwszych losowań (środek przedziału następnego losowania)
- Najlepszy wynik z następnymi losowaniami



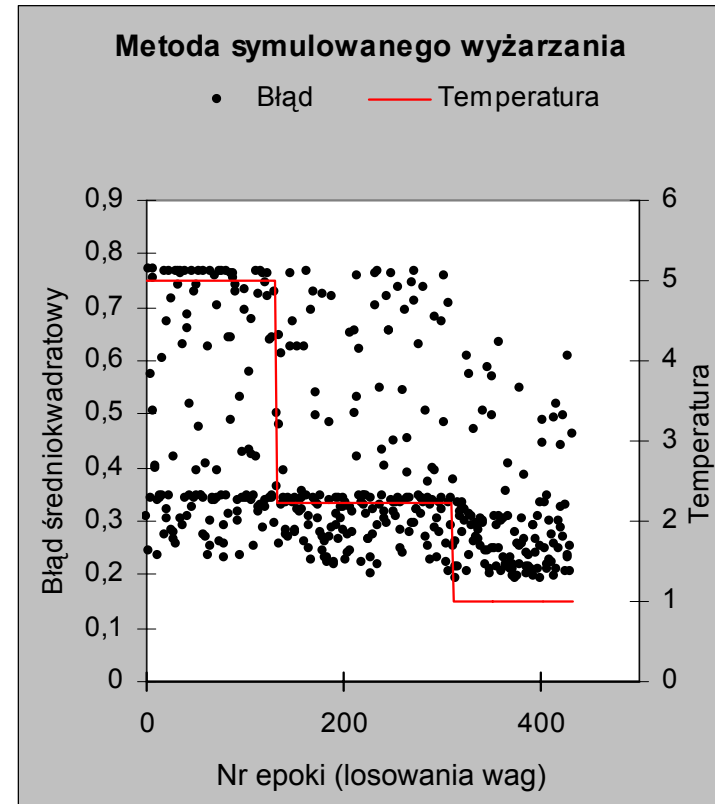
Uczenie nadzorowane sieci

Ilustracja metody symulowanego wyżarzania



Rysunek przedstawia przykładowy przebieg korekt błędów sieci w kolejnych losowaniach wartości wag, dla trzech kolejno zawężanych zakresów (temperatur).

Metoda symulowanego wyżarzania może być stosowana jako *samoistna*, albo jako *wstępna*, dla ustalenia najlepszego punktu startowego do metody gradientowej.





Sztuczne sieci neuronowe

Wstępna analiza danych



Należy wytypować zmienne wejściowe i wyjściowe modelu, kierując się następującymi zasadami:

- **Wytypowanie zmiennych wejściowych** (niezależnych) należy poprzedzić analizą istotności ich znaczenia dla zmiennych wyjściowych (zależnych), z wykorzystaniem np. metod statystycznych z grupy analizy wariancji. Należy odrzucić te najmniej znaczące, co ułatwi uczenie sieci i analizę wyników.
- Ustalając **liczbę wyjść** (równą liczbie wielkości wynikowych modelu) należy zawsze rozważyć konstruowanie kilku sieci z pojedynczymi wyjściami, co daje zmniejszenie liczby poszukiwanych wag.

Dla uzyskania wiarygodnych rezultatów *liczebność zbioru uczącego* powinna istotnie przewyższać liczbę poszukiwanych wag.



Sztuczne sieci neuronowe

Zasady konstrukcji sieci typu MLP



- **Liczba warstw ukrytych** najczęściej wynosi 1, rzadziej 2, bardzo rzadko 3.
- **Liczba neuronów w warstwie wyjściowej** (równa liczbie wielkości wynikowych modelu) może być dowolna.
- Większe **liczby neuronów w warstwach ukrytych**, związane z większą liczbą poszukiwanych wag, dają dokładniejsze, bardziej elastyczne przewidywania modelu. Wymagają jednak większych zbiorów uczących lub mogą prowadzić do przeuczenia sieci (nadmiernego dopasowania do danych) oraz powodują wydłużenie czasu obliczeń.

Dobłą praktyką jest wstępne ustalenie liczby neuronów w poszczególnych warstwach wg zasady postępu geometrycznego pomiędzy liczbą wejść a wyjść sieci.



Sztuczne sieci neuronowe

Proces uczenia



- Wykorzystuje się programy komputerowe, niektóre dostępne są na zasadzie shareware.
- Różne architektury sieci i poszczególne uczenia tych samych sieci mogą prowadzić do różnych wyników. Należy zatem:
 - przeprowadzić próby z różnymi wariantami sieci (liczbami warstw ukrytych – poczynając od jednej)
 - spróbować stosować różne liczby neuronów w tych warstwach
 - dla każdej konfiguracji wykonać po kilka lub kilkanaście uczeń.




Sieci neuronowe typu MLP

Wykorzystanie i analiza wyników



- *Jakość nauczonej sieci* można ocenić wyliczając błąd średniokwadratowy dla zbioru testowego, nie wykorzystywanego w procesie uczenia, tj. niezależnego od zbioru uczącego i weryfikującego (służącego do ustalenia zakończenia procesu uczenia).
- Jeżeli stosowano różne architektury sieci i/lub wielokrotne uczenie, to w przypadku rozwiązywania zadań typu regresji:
 - stosuje się *uśrednianie* przewidywanych przez sieci rezultatów, albo
 - korzysta się z sieci o *najmniejszym błędzie* przewidywania.



Sieci neuronowe typu MLP

Wykorzystanie i analiza wyników



- Najprostszym sposobem wykorzystania nauczonej sieci jest jej *odpytywanie*, tj. obliczanie wartości wyjść (odpowiedzi) dla zadanych wejść.
- Ważnym rezultatem nauczonej sieci mogą być także wartości tzw. *współczynników istotności wielkości wejściowych*, pozwalające na wykrycie znaczenia poszczególnych parametrów dla modelowanego procesu.

Są różne sposoby obliczania współczynników istotności. Przykłady podano w dalszej części wykładu.



Sztuczne sieci neuronowe

Ogólne zastosowania przemysłowe



- Przewidywanie własności wyrobów na podstawie parametrów procesu technologicznego
- Zastąpienie symulacji numerycznej procesów fizycznych uogólnionymi przez sieć neuronową wynikami 'eksperymentów numerycznych'
- Opis własności materiałów (równania empiryczne)
- Projektowanie oparte na doświadczeniach zebranych w przemyśle, uogólnionych przez sieć neuronową
- Przewidywanie awarii urządzeń na podstawie sygnałów typu obciążenie siłowe, temperatura itp.
- Stosowanie sieci jako sterowników w automatyce



Sztuczne sieci neuronowe

Dotychczasowe ogólne zastosowania w odlewnictwie metali



- Przewidywanie różnego typu awarii, zwłaszcza przy odlewaniu ciągłym
- Sterowanie procesami wytopu w żeliwiaku i piecu łukowym
- Gospodarka energetyczna w odlewni
- Projektowanie odlewów i układów zasilających dla odlewów
- Projektowanie odpowietrzeń w rdzennicach
- Sterowanie procesem przerobu masy formierskiej
- Przewidywanie własności odlewanych stopów
- Dobór parametrów odlewania ciśnieniowego



Zastosowania sieci neuronowych

Prognozowanie własności żeliwa sferoidalnego




W jednej z odlewni polskich zebrano wyniki blisko 800 wytopów, dla których określano zawartość 9 pierwiastków w kąpeli metalowej oraz mierzono wytrzymałość na rozciąganie, twardość Brinella i wydłużenie otrzymanego żeliwa.

Sieć neuronową typu MLP uczono wielokrotnie kombinowaną metodą symulowanego wyżarzania (dla ustalenia startowych wartości wag) oraz propagacji wstecznej błędu.

Wykonano następujące porównania z innymi modelami:

- Przewidywania sieci z przewidywaniami modelu typu wielomianu, zastosowanego w jednej z odlewni w Finlandii.
- Jakość dopasowania do danych uczących i weryfikujących dla sieci i dla naiwnego klasyfikatora Bayesa

Ponadto obliczono współczynniki istotności względnej sygnałów wejściowych, odzwierciedlających znaczenie poszczególnych pierwiastków

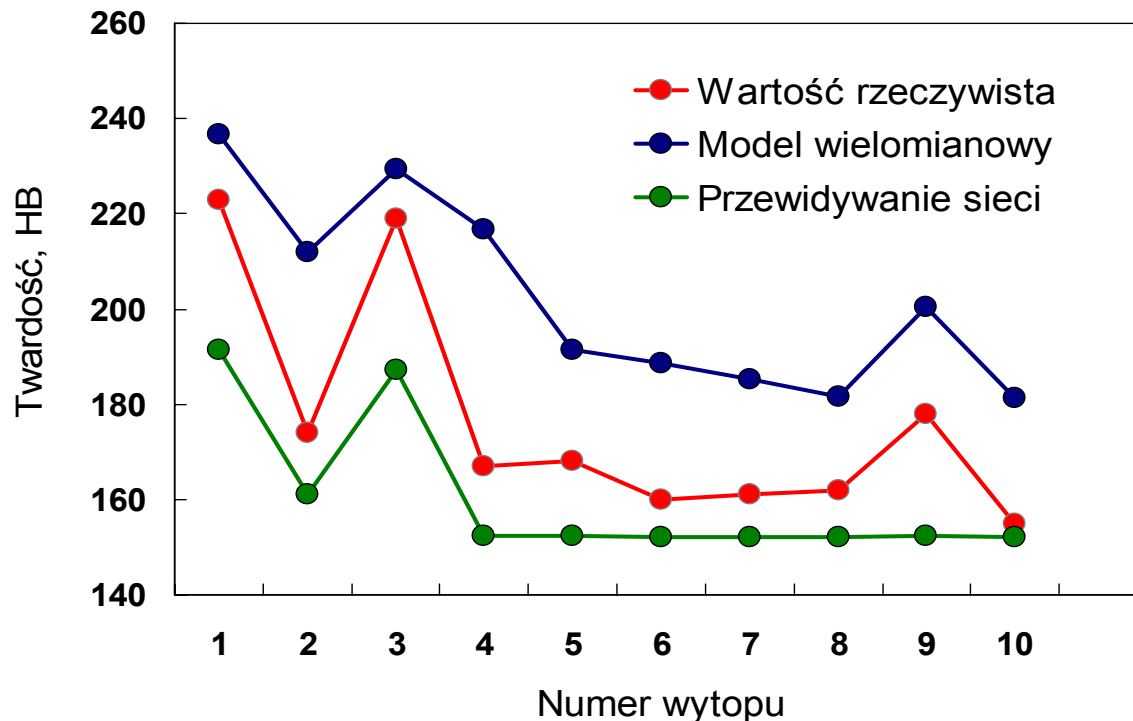


Zastosowania sieci neuronowych

Prognozowanie własności żeliwa sferoidalnego




Porównanie prognozowania twardości żeliwa na podstawie jego składu chemicznego metodą wielomianową, zastosowaną w odlewni fińskiej, z uzyskanym z odpytywania sieci neuronowej



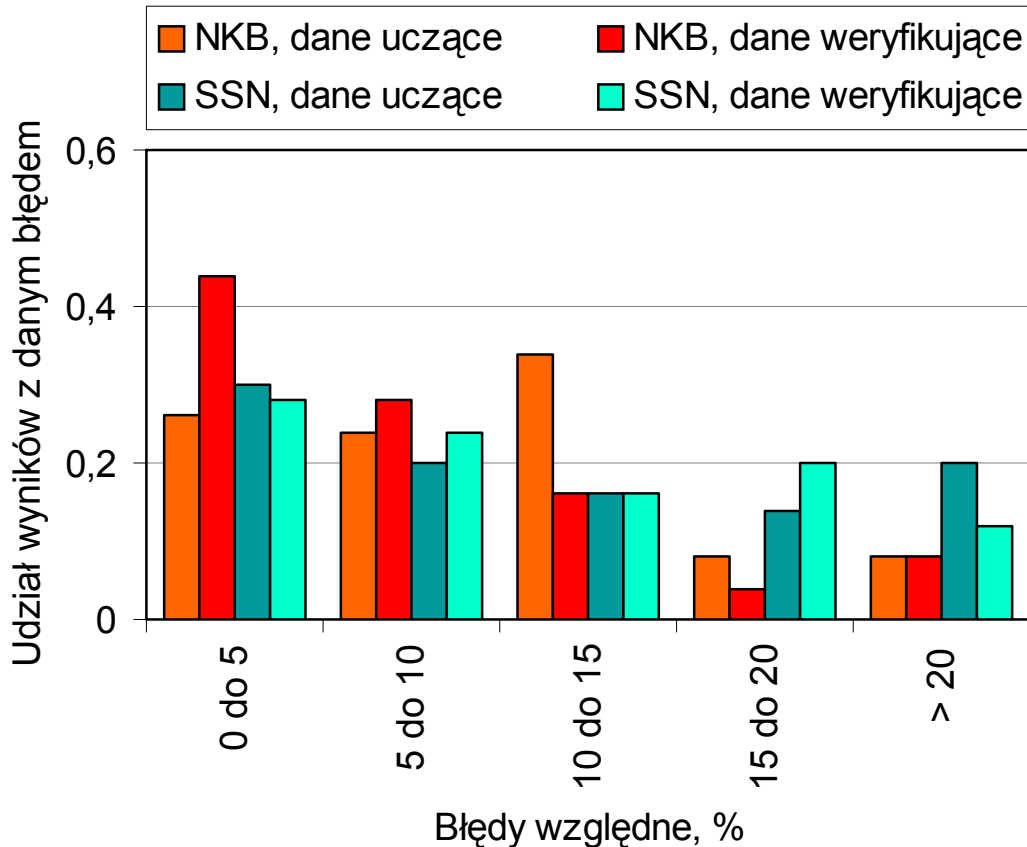
Żeliwo otrzymane w jednej z odlewni fińskich.

Sieć neuronowa nauczona na podstawie wyników zebranych w jednej z odlewni polskich.



Zastosowania sieci neuronowych

Prognozowanie własności żeliwa sferoidalnego




Porównanie błędów średniokwadratowych wytrzymałości żeliwa dla odpowiedzi sieci i klasyfikatora Bayesa.

Otrzymane rozkłady są typowe dla zaszumionych danych przemysłowych

Oznaczenia:

NKB – naiwny klasyfikator Bayesa,
SSN – sieć neuronowa




Zastosowania sieci neuronowych

Prognozowanie własności żeliwa sferoidalnego



Istotności względne pierwiastków z punktu widzenia wytrzymałości żeliwa sferoidalnego, otrzymane z nauczonej sieci neuronowej. Decydujące znaczenie miedzi jest zgodne z wiedzą metalurgiczną.



Wysokości słupków odpowiadają wartościom uśrednionym z 10 uczeń tej samej sieci, zaś czarne linie oznaczają rozstęp w tej próbie.



Zastosowania sieci neuronowych


Optymalizacja parametrów obróbki cieplnej żeliwa ADI



Żeliwo ADI (Austempered Ductile Iron) jest jednym z najnowocześniejszych odlewanych tworzyw konstrukcyjnych.

Jego własności mechaniczne zależą od:

- parametrów obróbki cieplnej wyjściowego żeliwa sferoidalnego:
 - temperatury austenizacji
 - czasu austenizacji
 - temperatury hartowania izotermicznego
 - czasu hartowania izotermicznego
- składu chemicznego żeliwa
- ilości i kształtu wydzieleń grafitu
- geometrii i sposobu wykonania odlewu



Zastosowania sieci neuronowych

Optymalizacja parametrów obróbki cieplnej żeliwa ADI



Na podstawie badań własnych i danych literaturowych utworzono bazę danych zawierającą informacje otrzymane z ponad 300 wytopów i dotyczące:

- parametrów obróbki cieplnej żeliwa
- składu chemicznego żeliwa
- modułów odlewów
- uzyskanej wytrzymałości na rozciąganie R_m
- uzyskanego wydłużenia A_5

Nauczona sieć neuronowa typu MLP pozwala na przewidywanie wytrzymałości i wydłużenia dla danego odlewu przy zastosowaniu określonej obróbki cieplnej.



Zastosowania sieci neuronowych

Optymalizacja parametrów obróbki cieplnej żeliwa ADI



Ponadto napisano specjalne *oprogramowanie służące do optymalizacji* dowolnie wybranych wielkości wejściowych, np. parametrów obróbki cieplnej dla uzyskania określonego wyniku, np. maksymalnej lub zadanej wytrzymałości lub wydłużenia.

Algorytm stosuje omówioną wcześniej metodę optymalizacji wielu zmiennych zwaną metodą symulowanego wyżarzania. Polega ona w tym przypadku na wielokrotnym odpytywaniu sieci, dla losowo wybieranych wartości zmiennych wejściowych wg zasady tej metody, w zakresie wskazanym przez użytkownika.

Użytkownik może zadać także dokładność obliczeń, jako ułamek całego zakresu zmienności tych parametrów, który w procedurze obliczeniowej równy jest ostatniemu przedziałowi losowania.

Na następnym slajdzie pokazano reprodukcje dwóch okien tego oprogramowania.



Zastosowania sieci neuronowych

Optymalizacja parametrów obróbki cieplnej żeliwa ADI



Okno wyboru parametrów optymalizacji

Okno wyników optymalizacji

Optymalizacja wielkości WEjściowych dla zadanego WYjścia

Wybór wielkości optymalizowanej (WYjściowej):

Rm [MPa]

Rodzaj optymalizacji:

Maksimum Minimum

Wartość:

Określenie zakresu zmiennych niezależnych (WEjściowych):

Minimum:

Tpi [oC]: 245,00
tpi [min]: 10,00
Taust. [oC]: 850,00
taust. [min]: 30,00

Maksimum:

Tpi [oC]: 400,00
tpi [min]: 480,00
Taust. [oC]: 927,00
taust. [min]: 240,00

Nowa wartość: Akceptuj

Nowa wartość: Akceptuj

Dokładność optymalizacji (jako ułamek zakresu każdej zmiennej):

Oblicz Anuluj

Znalezione wartości dla określonego wyniku

Znalezione (i ustalone) wartości danych WEjściowych:

Tpi [oC]: 245,00
tpi [min]: 480,00
Taust. [oC]: 850,00
taust. [min]: 30,00

Zapisz ten zbiór Przeglądaj inne zbiory

Dane WYjściowe (wynik zakładany i pozostałe):

Rm [MPa]: 1597,0

Koniec




Zastosowania sieci neuronowych

Identyfikacja przyczyn powstawania wad typu porowatość gazowa w odlewach stalowych



Przesłanki podjęcia projektu:

- Wykrywanie przyczyn nieregularnego pojawiania się wad w odlewach jest zadaniem trudnym, z uwagi na wielką liczbę losowo zmieniających się czynników mogących je powodować
- Analiza parametrów produkcyjnych, organizacyjnych, ludzkich i materiałowych, jako potencjalnych przyczyn wad, musi być wykonana w oparciu o system uczący się na podstawie zarejestrowanych przypadków występowania lub braku wady




Zastosowania sieci neuronowych

Identyfikacja przyczyn powstawania wad typu porowatość gazowa w odlewach stalowych



Główne etapy projektu

- Określenie wszystkich możliwych parametrów mogących mieć związek z wadą typu porowatość gazowa (39 wielkości)
- Opracowanie systemu gromadzenia informacji o tych parametrach i stopniu wystąpienia wady
- Przetworzenie zebranych danych do postaci zbiorów uczących dla sieci neuronowej, w tym napisanie odpowiedniego oprogramowania
- Zaprojektowanie, uczenie i testowanie sieci neuronowej
- Analiza działania nauczonej sieci i diagnoza przyczyn powstawania wady. Wprowadzenie działań zaradczych




Zastosowania sieci neuronowych

Identyfikacja przyczyn powstawania wad typu porowatość gazowa w odlewach staliwnych

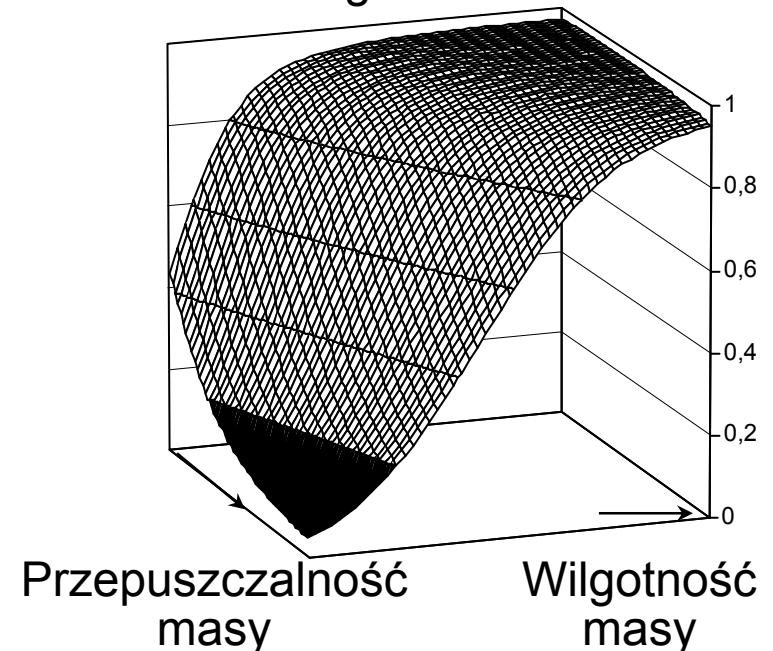



Wykresy uzyskane z odpowiedzi nauczonej sieci neuronowej stanowiące podstawę identyfikacji przyczyn powstawania porowatości

Pogoda ciepła
i sucha



Pogoda chłodna
i wilgotna



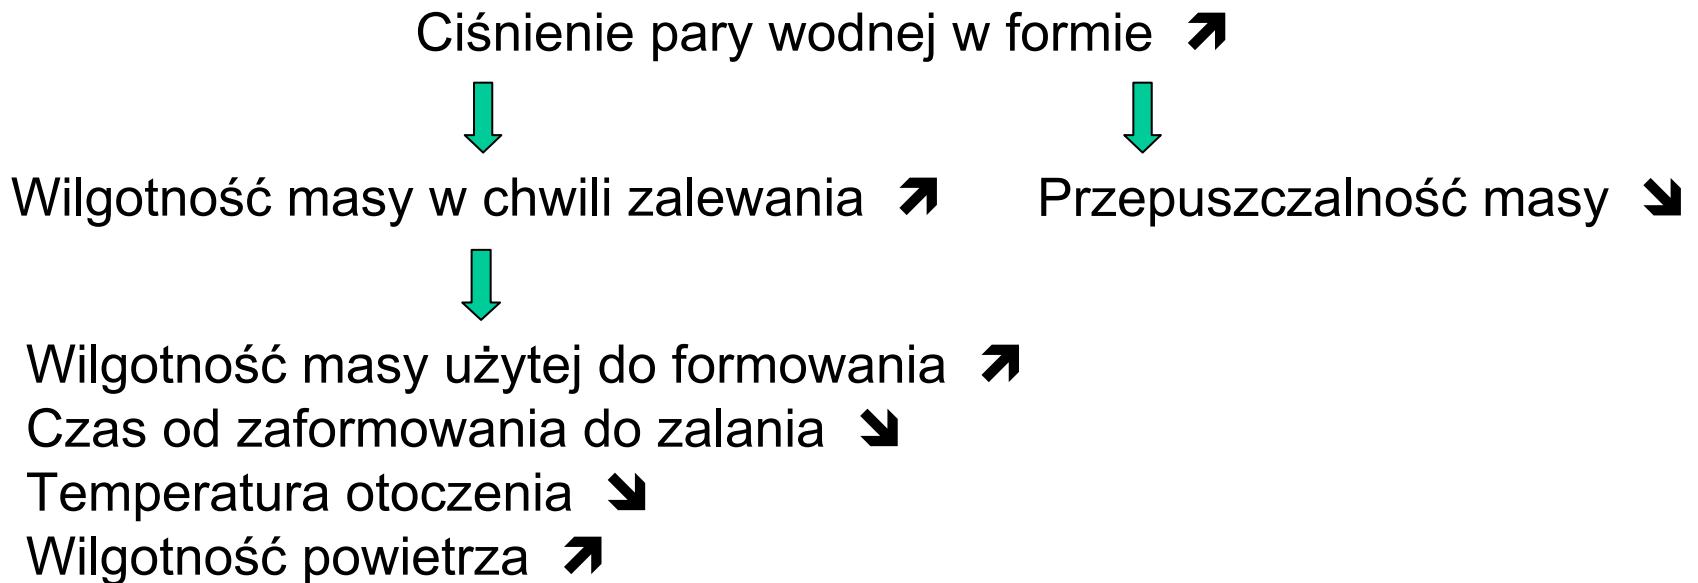


Zastosowania sieci neuronowych

Identyfikacja przyczyn powstawania wad typu porowatość gazowa w odlewach stalowych



Główną przyczyną porowatości był nadmierny wzrost ciśnienia pary wodnej w formie, spowodowany zespołem przyczyn, wg schematu:



Czarne strzałki wskazują na przewidywane przez sieć cząstkowe kierunki zmian częstotliwości występowania wady



Zastosowania sieci neuronowych

Wspomaganie decyzji odnośnie dodatków odświeżających do wilgotnych mas formierskich




Podjęto próbę zastosowania SSN do wspomagania decyzji dotyczących ilości składników odświeżających i wody dodawanych do bentonitowych mas formierskich. W przypadku systemów nie w pełni zautomatyzowanych ustalenie tego typu dodatków dokonywane jest na ogół przez mistrza formiarni, na podstawie analizy składu i pierwszych wyników pomiarów własności masy, na początku dziennej zmiany. Koncepcja pracy polegała na sprawdzeniu, czy sieć neuronowa jest w stanie nauczyć się takiej analizy i proponować wielkości dodatków równie dobrze lub lepiej niż człowiek.




Zastosowania sieci neuronowych

Wspomaganie decyzji odnośnie dodatków odświeżających do wilgotnych mas formierskich

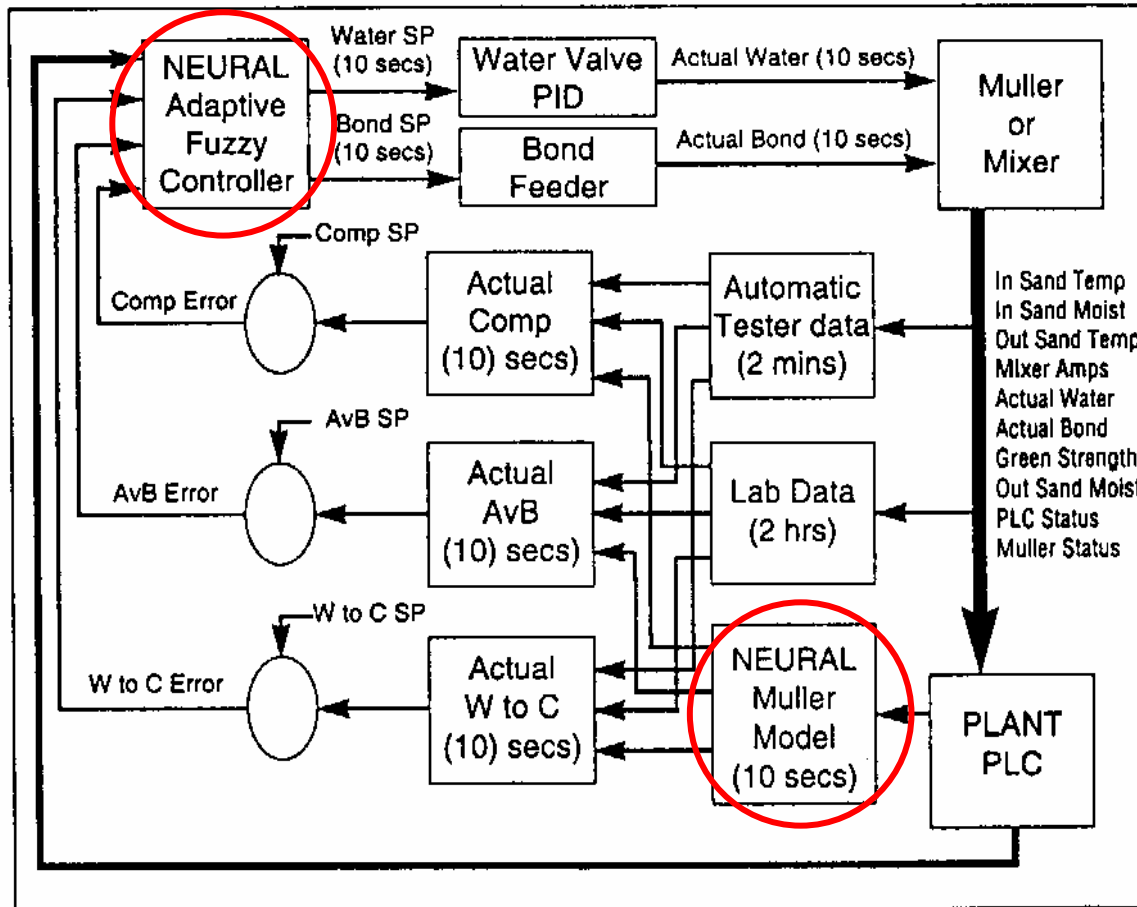


Błędy dodawanych ilości składników masy, o których decydował człowiek, są istotnie wyższe niż błędy popełniane przez sieć



Zastosowania sieci neuronowych

Automatyczny system dozowania dodatków odświeżających do wilgotnych mas formierskich



System działa w odlewni
John Deer Foundry,
Iowa, USA

Miejsca, w których
wykorzystuje się sieci
neuronowe zaznaczono
czerwonymi kołami

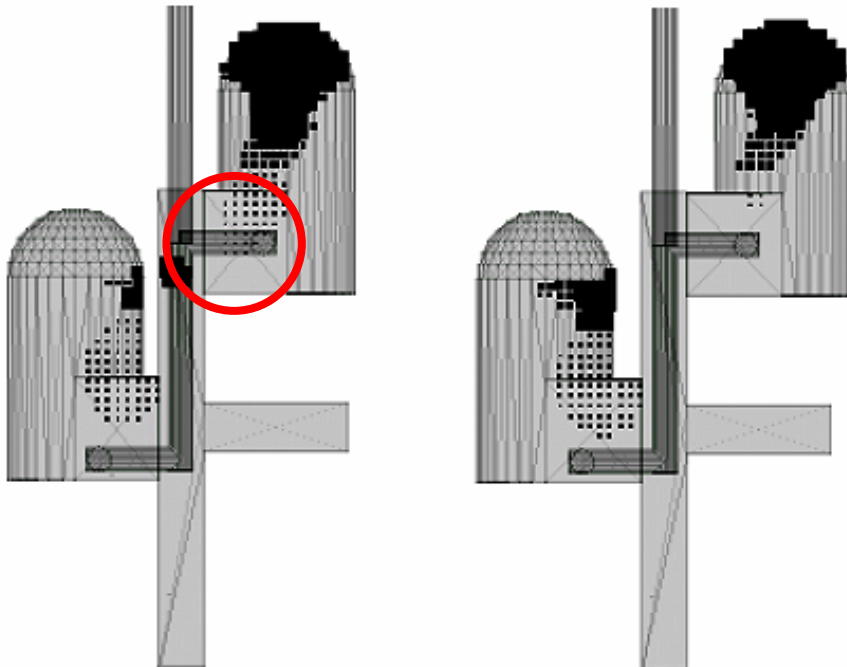


Zastosowania sieci neuronowych

Projektowanie układów zasilania odlewów



Celem projektu było uzyskanie zależności umożliwiających wyznaczenie poprawnych wymiarów zasilaczy bocznych w odlewie, stwarzających największe problemy związane m.in. z lokalnym przegrzewaniem się formy. Przeprowadzone zostały symulacje krzepnięcia specjalnie zaprojektowanych odlewów.



Otrzymano obrazy z rozkładem wad skurczowych, zależne od: proporcji i wielkości nadlewu, odległości nadlewu od odlewu oraz modułu szyi.

Na przykładowym wyniku symulacji kółkiem zaznaczono typową wadę wynikłą z lokalnego przegrzania.



Zastosowania sieci neuronowych

Projektowanie układów zasilania odlewów



Sieć neuronowa pozwoliła na uogólnienie wyników numerycznej symulacji krzepnięcia w celu uzyskania zaleceń projektowych dla układów zasilania odlewów.

- Optymalny stosunek wysokości nadlewu bocznego do jego średnicy wynosi 1,5. Zapewnia on niewielki stopień przegrzewania przyległej ściany odlewu i dość korzystny stosunek czasu krzepnięcia do objętości
- Minimalna długość szyi (odległość między nadlewem a odlewem) wynosi 20 mm.
- Dla aluminium wystarczający stosunek modułów nadlewu i odlewu wynosi 1 dla zalewania przez nadlew, zaś dla równomiernego początkowego rozkładu temperatury 1,3. Dla staliwa stosunek ten w obu wypadkach wynosi 1,2.



Zastosowania sieci neuronowych

Diagnostyka zakłóceń procesów ciągłych




W odlewni wiele procesów można traktować jako ciągłe, czyli takie, których parametry powinny być utrzymywane na ustalonym poziomie w dłuższym przedziale czasu.

Przykładem może być każdy proces związany z produkcją w długich seriach, np. wytop jednego gatunku stopu, formowanie lub odlewanie dla jednego asortymentu odlewów.

Diagnostyka zakłóceń procesów ciągłych obejmuje dwa etapy działań:

- Wykrycie i ocena stopnia rozregulowania się procesu, na podstawie wzrostu lub spadku jego niektórych parametrów (np. temperatury, własności wyrobu itp.). Typowym narzędziem matematycznym są metody statystycznego sterowania procesem (SPC). W nowym rozwiązaniu zadanie to rozwiązuje sieć neuronowa I.
- Identyfikacja przyczyn rozregulowania, która w tradycyjnym postępowaniu dokonywana jest przez analizę sytuacji, zazwyczaj przez zespoły kadry technicznej zakładu. W nowym rozwiązaniu zadanie to rozwiązuje sieć neuronowa II.



Zastosowania sieci neuronowych


Diagnostyka zakłóceń procesów ciągłych



*L pomiarów parametrów
procesu z okienka czasowego*




Parametr 1
Parametr 2
.....
Parametr N



Sieć neuronowa I
Określa charakter
i stopień rozregulowania
procesu


Stopnie wzrostu
N parametrów
Stopnie stabilności
N parametrów
Stopnie spadku
N parametrów

Stopnie wzrostu
N parametrów
Stopnie stabilności
N parametrów
Stopnie spadku
N parametrów



Sieć neuronowa II
Modeluje relacje między
rozregulowaniem,
a wystąpieniem wady lub
uszkodzenia

Wada 1
Wada 2
.....
Wada M



Zastosowania sieci neuronowych

Diagnostyka zakłóceń procesów ciągłych



Uczenie sieci I

Zbiór uczący składa się tylko z 3 rekordów tworzonych następująco:

WEjście

L elementów – liczba pomiarów
w okienku czasowym

Np. dla L= 10:

-1	-0.8	-0.6	+0.6	+0.8	+1	1	0	0
0	0	0	0	0	0	0	1	0
+1	+0.8	+0.6	-0.6	-0.8	-1	0	0	1

WYjście

3 elementy – definiujące
(kolejno): wzrost,
stabilność i spadek

Wyniki: dla zaobserwowanego ciągu wartości WEjściowych (kolejnych pomiarów parametrów procesu w okienku czasowym), np. -1, -1, -1, 0, +0.5, +1, otrzymuje się trójki liczb charakteryzujące stopień wzrostu, stabilności i spadku danej wielkości, np.: 0.72, 0.01, 0.12 oznacza dość wyraźny wzrost.



Zastosowania sieci neuronowych

Diagnostyka zakłóceń procesów ciągłych



Uczenie sieci II

Zbiór składa się z zarejestrowanych przypadków przemysłowych, w których określone są stopnie i charakter rozregulowania parametrów procesu oraz fakt lub stopień wystąpienia wady lub uszkodzenia.

Wielkościami wejściowymi będą przetworzone do postaci trójek liczb sygnały o zmianach parametrów w okienku czasowym, zaś wielkościami wyjściowymi informacje o stwierdzonych rzeczywistych przyczynach zakłócenia, jakie zidentyfikowano – być może zbyt późno – w przeszłości.

WEjście


3 x N elementów

N - liczba parametrów procesu

WYjście

M elementów - liczba

analizowanych wad lub uszkodzeń



Zastosowania sieci neuronowych o radialnych funkcjach bazowych



- Sieci o radialnych funkcjach bazowych (zwanymi krótko sieciami typu RBF od skrótu angielskiego) służą do realizowania zadań typu regresji, a także predykcji czy klasyfikacji, podobnie jak sieci typu MLP z neuronami o sigmoidalnej funkcji aktywacji.
- Typowa sieć radialna zawiera warstwę wejściową, jedną warstwę ukrytą o neuronach realizujących funkcję radialną oraz warstwę wyjściową zwykle złożoną z jednego neuronu liniowego.
- Sieci typu RBF znajdują coraz częstsze zastosowania w modelowaniu procesów technologicznych, w szeregu przypadkach wykazując lepsze odwzorowanie cech charakterystycznych modelowanego procesu od sieci typu MLP.



Zastosowania sieci neuronowych samoorganizujących się



Grupowanie sygnałów wykazujących podobne cechy realizowane przez sieci typu Kohonena, uczone bez nadzoru, może mieć również zastosowanie w modelowaniu procesów produkcyjnych.

Przykłady korzyści z grupowania przypadków podobnych pod względem wartości parametrów produkcyjnych:

- Jeżeli okazałoby się, że grupa w której występują pewne kombinacje wartości parametrów procesu, charakteryzuje się większym udziałem wyrobów wadliwych niż inne to może oznaczać, że dana kombinacja jest przyczyną pogarszania się jakości produkcji.
- Jeżeli okazałoby się, że grupa w której występują skrajne wartości parametrów najczęściej związana jest z określonym pracownikiem, to oznaczać mogłoby, że nie wykonuje on dobrze swojej pracy.
- Jeżeli sieć grupowałaby parametry procesu w większą liczbę znacząco różniących się grup niż liczba typów wytwarzanych wyrobów, to może to oznaczać, że w procesie występują nieprzypadkowe zakłócenia.



METRO

MEtalurgiczny TRening *On-line*

Sztuczne sieci neuronowe w analizie procesów odlewniczych

Koniec wykładu



Edukacja i Kultura