

mgr inż. Gerard Bursy
Instytut Mineralnych Materiałów Budowlanych w Opolu
dr hab. inż. Ryszard Rojek prof. Politechniki Opolskiej
Politechnika Opolska w Opolu

Nowoczesne układy sterowania procesami przemiałowymi oparte na teorii sztucznych sieci neuronowych

Streszczenie: Wysoka energochłonność procesów przemiałowych zmusza do poszukiwania nowych metod sterowania. W pracy przedstawiony został aktualny stan identyfikacji procesu przemiału na przykładzie młyna cementu pracującego w układzie zamkniętym. Do badań wykorzystane zostały dane pomiarowe zarejestrowane podczas normalnej pracy młyna w cementowni. Oprócz podstawowych pomiarów (nadawa do młyna, stopień napelnienia młyna) wykorzystany został automatyczny pomiar stopnia rozdrobnienia cementu. Wszystkie obliczenia przeprowadzone zostały z użyciem pakietu MatLab Simulink wraz z przybornikiem Neural Network.


Modern control systems for grinding processes based on artificial neural networks

Abstract: High energy consumption in grinding processes induces a permanent interest in searching for new methods for their more effective control. This work presents a current state of the art in identification of a grinding process, based on a study of a closed-loop cement mill. The analysis is based on measurement data obtained during normal operation of the plant. In addition to the basic measurements (feed rate to the mill, filling ratio for the mill), an additional important figure, namely fineness of cement, is incorporated in the analysis. All simulations, including those for a closed-loop control system for the cement mill grinding process, are run with the Neural Network Toolbox in the MatLab Simulink environment.

1. WSTĘP

W przemyśle cementowym procesy przemiałowe występują na każdym etapie produkcji, począwszy od przygotowania surowca (kruszarzki i młyny surowca) poprzez wypalanie (młyny węgla), aż do otrzymania gotowego produktu - cementu (młyny cementu). Dla każdego z układów stosuje się odpowiednie urządzenia przemiałowe np. w polskim przemyśle cementowym do przemiału surowca stosuje się młyny kulowo-rurowe lub młyny pionowe, a do przemiału cementu wyłącznie młyny kulowo-rurowe. Młyny te charakteryzują się wysokim zużyciem energii elektrycznej i niską sprawnością. Zużywają one ok. 33 % całkowitej energii elektrycznej potrzebnej na wyprodukowanie 1 Mg cementu. Ze względu na niską sprawność tych układów i brak układów sterowania (używane są jedynie układy sterowania ręcznego,

oraz ewentualnie stabilizacji pojedynczych wielkości) podejmowane są kolejne próby automatyzacji. Zmniejszenie zużycia energii można uzyskać poprzez ograniczenie spektrum ziarna otrzymywanego na wyjściu układu (co widoczne jest to na rys. 1). Celowym jest więc dążenie do uzyskania produktu o jak najmniejszej powierzchni właściwej i jak największym spektrum granulacji.



Rys. 1. Jednostkowe zużycie energii elektrycznej

Jednakże nadmierne rozdrobnienie powoduje obniżenie wytrzymałości betonu zarobionego z takiego cementu.

Uzyskanie właściwych i wymaganych parametrów cementu przy niskim jednostkowym zużyciu energii wymaga nie tylko wysokiej dyscypliny techniczno-technologicznej lecz również racjonalnie pracujących układów sterowania automatycznego, bazujących na dostępnych wielkościach pomiarowych wraz z pomiarem stopnia rozdrobnienia. Rozwiązanie powyższego zadania jest jednak trudne ze względu na złożoność równocześnie zachodzących procesów rozdrobnienia, transportu, mieszania oraz dużą liczbę niemierzalnych wielkości zakłócających. Stosowane dotychczas konwencjonalne układy sterowania i laboratoryjny pomiar stopnia rozdrobnienia nie zapewniają utrzymania stabilnych warunków pracy układu mielenia jako układu nieliniowego z dużym opóźnieniem przy ciągle zmieniających się parametrach. Możliwe jest to jedynie przy wykorzystaniu automatycznego pomiaru stopnia zmielenia, co umożliwił radioizotopowy miernik pomiaru stopnia rozdrobnienia RMGU-01 produkowany przez Instytut Mineralnych Materiałów Budowlanych w Opolu. Wykorzystanie nowoczesnych metod sterowania opartych na sztucznej inteligencji, jak np. teorii sztucznych sieci neuronowych.

2. POMIAR STOPNIA ROZDROBNIENIA CEMENTU

Do automatycznego sterowania procesem przemiału wymagane są wiarygodne dane dotyczące wielkości opisujące stan układu (młyna) w określonej chwili. Zapewnia to odpowiedni układ pomiarowy, który powinien dostarczać jak najwięcej istotnych wielkości pomiarowych. Oprócz podstawowych sygnałów takich jak nadawy poszczególnych składników dozowanych do młyna, ciśnienia i temperatury na wejściu i wyjściu młyna oraz na przegrodzie, wymagane są również: informacje o stanie napełnienia młyna (wielkość mierzona z użyciem mikrofonu lub folafonu) i o stanie rozdrobnienia gotowego produktu - cementu.

O ile większość wielkości można zmierzyć wykorzystując standardowe czujniki pomiarowe to pomiar stopnia rozdrobnienia nastęrcza pewnych kłopotów. W większości cementowni w kraju pomiar ten wykonują się co godzinę metodą laboratoryjną, która wymaga pobrania próbki z układu, przeniesienia jej do laboratorium i wykonania pomiaru przy pomocy aparatu Blaine'a. Wynik tego pomiaru obarczony jest dość dużym błędem ok. 200 cm²/g dla wielkości rzędu 2000 - 4000 cm²/g. Dokładniejszy wynik otrzymujemy przeprowadzając analizę sitową, lecz jest jednak bardzo czasochłonna lub badając rozkład granulometryczny z wykorzystaniem laserowego analizatora uziarnienia LAU-10 produkowanego przez IMMB w Opolu. Analizator ten pozwala na określenie rozkładu ziarnowego próbki w zakresie od 1,5 do 200 μm w czasie ok. 2 minut [1].

Powyższe metody mają jednak jedną wadę - wymagają ręcznego pobrania próbki i przetransportowania jej do laboratorium co wyklucza możliwość automatycznego przeprowadzenia pomiarów. Wady tej pozbawiony jest radioizotopowy miernik pomiaru

stopnia rozdrobnienia RMGU-01, który pozwala na określenie stanu rozdrobnienia materiałów sypkich, do których zalicza się cement. Urządzenie to pozwala na quasi-ciągły pomiar z czasem aktualizacji wyniku poniżej 10 minut [2]. Wynikiem pomiaru nie jest pełny rozkład granulometryczny jak w przypadku analizy sitowej czy analizatora laserowego lecz wielkość charakteryzująca stan zmielenia jaką wg polskiej normy PN 80/B-04300 jest powierzchnia właściwa wg Blainie'a.

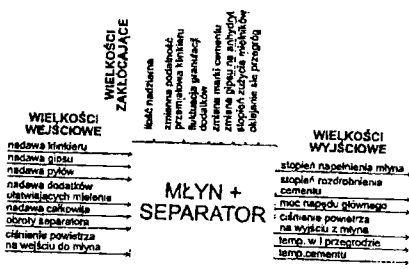
3. WYKORZYSTANIE STRUKTURY SIECI NEURONOWYCH

Sztuczne sieci neuronowe charakteryzują się możliwością aproksymacji dowolnych odwzorowań liniowych i nieliniowych (zgodnie z równaniem Cybenki), równoległością przetwarzania informacji, możliwością uczenia się i adaptacji, przetwarzaniem sygnałów z wielu wejść i generowanie wielu sygnałów wyjściowych. Zdolność uczenia się przez sieć pozwala na analizę obiektów, których model matematyczny jest nieznanym bądź jest zbyt złożony by mógł być użyty do potrzeb sterowania. Aby móc sterować tak złożonym obiektem jakim jest młyn cementu przyjęta została metoda syntezy regulatora neuronowego zaproponowana przez Nguyena i Widorowa, zgodnie z którą w pierwszym etapie buduje się neuronowy emulator obiektu. Jego zadaniem jest pełne odwzorowanie charakterystyk statycznych i dynamicznych obiektu. W dalszej kolejności, dzięki zastosowaniu algorytmu wstecznej propagacji błędów, regulator dostrajając swoje współczynniki wagowe uczy się sterować emulatorem zgodnie z określoną strategią [3]. Tak nauczony regulator można wykorzystać do sterowania obiektem rzeczywistym.

W przedstawionym referacie zaprezentowana zostanie pierwsza część zadania, czyli opracowanie wiarygodnego emulatora neuronowego młyna kulowego na przykładzie młyna cementu pracującego w układzie zamkniętym.

3.1. Wielkości uczące i testujące sieć

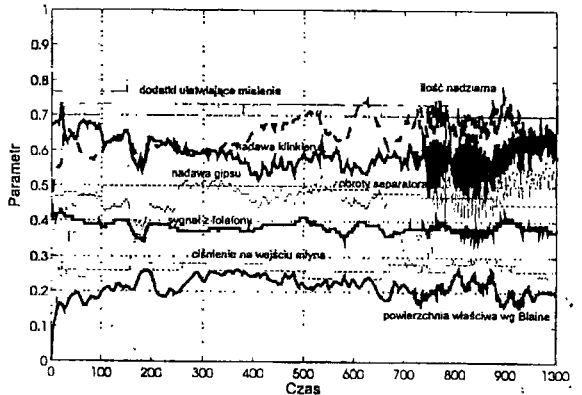
Do uczenia wykorzystane zostały dane pomiarowe zarejestrowane podczas normalnej pracy młyna cementu z separatorem powietrznym. Rejestrowane wielkości można podzielić na: wielkości wejściowe (nadawa klinkieru, nadawa gipsu, nadawa pyłów, nadawa dodatków ułatwiających mielenie, obroty separatora powietrznego, ciśnienie powietrza na wejściu do młyna), wielkości zakłócające (ilość nadziarna, zmienna podatność przemiatłowa klinkieru, fluktuacja granulacji dodatków, zmiana marki cementu, zmiana gipsu w anhydryt przy przekroczeniu temperatury 105 °C, stopień zużycia mielników, oklejanie się przegród) oraz wielkości wyjściowe (stopień rozdrobnienia cementu, stopień napełnienia młyna, moc napędu głównego, ciśnienie powietrza na wyjściu z młyna, temperatura na I przegrodzie, temperatura cementu). Spośród wszystkich dostępnych wielkości do procesu identyfikacji użyte zostały: składniki nadawy, obroty separatora, ciśnienie powietrza na wejściu do młyna, ilość nadziarna, stopień napełnienia młyna, stopień rozdrobnienia cementu. Ogólny schemat blokowy młyna kulowego został przedstawiony na rys. 2 [4].



Rys. 2. Schemat blokowy młyna

Dane wykorzystane do procesu identyfikacji rejestrowane były przez ok. 35 godzin z rozdzielczością 2-ch minut podczas normalnej pracy młyna cementu produkującego cement

portlandzki P45 bez dodatków pyłowych. Przebiegi przedstawione zostały na rys. 3. Wynika z nich, iż na wysokości ok. 740 pomiaru (godz. 14) nastąpiła zmiana, przyczyną jej była zmiana operatora bądź zaprzestanie dozowania sulfatu. Również w okolicy 150 - 190 punktu pomiarowego można zaobserwować chwilowe wahania charakterystyczne dla wyłączenia młyna. Zarejestrowane wielkości zostały przeskalowane do zakresu 0 - 1 ponieważ duże rozbieżności wartości pomiędzy sygnałami stopnia napełnienia młyna (ok. 40 %) i stopnia rozdrobnienia cementu (ok. 3000 cm²/g) powodowały zanik uczenia przez sieć sygnału stopnia napełnienia młyna, który przyjmuje niższe wartości bezwzględne.



Rys. 3. Przebiegi wykorzystane do uczenia i testowania sieci

3.2. Struktury sieci neuronowych

Sieci neuronowe posiadają strukturę umożliwiającą budowanie dowolnych układów zawierających odpowiednio dobraną: ilość warstw, ilość neuronów w warstwie oraz dowolne połączenia pomiędzy neuronami. Ze względu na złożoność procesu uczenia (algorytmy uczenia złożonych sieci o nieregularnej strukturze nie są znane) badania zostały ograniczone do typowych struktur sieci warstwowych. Przebadane zostały sieci jednowarstwowe z neuronami o liniowej funkcji przejścia, sieć Elmana, sieć typu Radial Basis, oraz sieci nieliniowe dwuwarstwowe. Sieci zostały przebadane jako układy ze sprzężeniem zwrotnym i bez niego, oraz w układach równoległym i szeregowo-równoległym. Do budowy wykorzystany został model rzędu 1-go:

$$y(k+1) = a \cdot u(k) + b \cdot u(k-1) + c \cdot y(k-1) + d \quad (1)$$

gdzie: $y(k+1)$ oznacza wartość sygnału wyjściowego dla następnej (obliczanej) próbki czasowej, $u(k)$ i $u(k-1)$ wartości sygnałów wejściowych w chwili bieżącej i poprzedniej, $y(k-1)$ wartość sygnału wyjściowego obliczonego przez sieć (w przypadku układu równoległego) lub rzeczywistego (w przypadku modelu szeregowo-równoległego) w chwili poprzedniej.

Wszystkie sieci uczono wykorzystując ciągi zawierające 500 pierwszych (lub mniej albo więcej zgodnie z wartością podaną w odpowiednim punkcie) pomiarów zarejestrowanych podczas normalnej pracy młyna cementu, które zostały opisane w punkcie 3.1. Pozostałe pomiary wykorzystane zostały do sprawdzenia jakości działania sieci. Jakość sieci oceniona została na podstawie przebiegów graficznych otrzymanych przy pomocy pakietu Simulink i błędów obliczonych jako różnica kwadratów sygnałów generowanych przez sieć i sygnałów z obiektu rzeczywistego. Błędy te obliczone zostały osobno dla fragmentu przebiegu wykorzystanego w procesie uczenia (średniokwadratowy błąd uczenia) oraz wykorzystanego do testowania (średniokwadratowy błąd testowania).

Z przeprowadzonych prób wynika, że sieci jednowarstwowe (rys. 4) zawierające dwa neurony o liniowej funkcji aktywacji uczą się bardzo szybko (czas uczenia wynosił ułamki sekund), a błąd uczenia i testowania jest porównywalny z siecią wielowarstwową i wynosi dla sygnału stopnia napełnienia młyna ok. 10 %, dla sygnału stopnia rozdrobnienia cementu ok. 25-30 %.

Proces uczenia sieci Elmana (rys. 5) przebiegał dłużej wynosząc ok. 1547 sekund w przypadku sieci zawierającej 1 neuron w warstwie ukrytej i ok. 4578 sekund w przypadku sieci zawierającej 10 neuronów w warstwie ukrytej i uczonej zbiorem zawierającym 500 próbek. W przypadku tej sieci otrzymane przebiegi były obciążone większym błędem zarówno dla sygnałów uczących jak i testujących.


Oprócz sieci jednowarstwowej i sieci Elmana przebadana została także sieć typu Radial Basis, która złożona jest z warstwy ukrytej zawierającej neurony, z funkcją aktywacji typu Radial Basis i warstw wyjściowej posiadającej neurony liniowe. Do utworzenia struktury i uczenia tej sieci wykorzystana została funkcja `solverb` zawarta w przyborniku Neural Network [5]. Uczenie tego typu sieci polega na dodawaniu kolejnych neuronów do warstwy ukrytej w każdym kolejnym kroku uczenia (epoch), co zwiększa zdolności przetwarzania i pamiętania w sieci. Sieć ta charakteryzowała się krótkimi czasami uczenia oraz słabą zbieżnością procesu uczenia.

Z wszystkich przebadanych struktur optymalna wydaje się sieć nieliniowa dwuwarstwowa. Sieć ta przebadana została w układzie ze sprzężeniem zwrotnym i bez niego. Do procesu uczenia wykorzystane zostały metody wstecznej propagacji błędów, wstecznej propagacji błędów z momentem oraz Levenberga-Maquardta. Metoda wstecznej propagacji błędów została odrzucona na samym początku ponieważ proces uczenia nie był zbieżny. Dodanie do algorytmu adaptacji wag i przesunięcie współczynnika zwanego momentem poprawiło zbieżność procesu uczenia. Najlepszą z wszystkich przebadanych metod okazała się metoda Levenberga-Maquardta, której proces uczenia jest zbieżny, czas większy, a błąd uczenia mniejszy niż w przypadku algorytmu z momentem. Przykładowe czasy uczenia sieci dwuwarstwowej w zależności od ilości neuronów w warstwie ukrytej i zastosowanej metody zostały przedstawione na rys. 6. Biorąc pod uwagę zbieżność procesu uczenia, dokładność odwzorowania przebiegów oraz czas uczenia najbardziej optymalny wydaje się sieć wielowarstwowa uczona zgodnie z algorytmem Levenberga-Maquardta. W przyborniku Neural Network realizuje go funkcja `trainlm`.

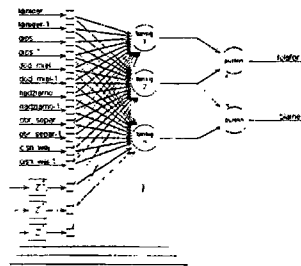
3.2.1. Sieć wielowarstwowa bez sprzężenia zwrotnego

Bazując na modelach opartych o sieci posiadające strukturę dwuwarstwową przebadane zostały sieci ze sprzężeniem zwrotnym (rys. 11) i bez niego. Sieci bez sprzężenia zwrotnego (rys. 7) sprawdzone zostały w oparciu o modele rzędu 1-go (2) i drugiego (3).


$$y(k+1) = a \cdot u(k) + b \cdot u(k-1) \quad (2)$$



Rys. 4. Struktura jednowarstwowej sieci liniowej bez sprzężenia zwrotnego




Rys. 5. Struktura sieci Elmana





Rys. 6. Porównanie czasów uczenia dla algorytmu wstecznej propagacji błędów z momentem i metody Levenberga-Maquardta

$$y(k+1) = a \cdot u(k) + b \cdot u(k-1) + c \cdot u(k-2) \quad (3)$$



Przebadany został również wpływ ilości neuronów warstwy ukrytej na dokładność odwzorowania przebiegów. Z przeprowadzonych badań wynika, iż w przypadku wzrostu rzędu modelu lepsza jest jakość otrzymanego emulatora. Generowany przebieg sygnału stopnia rozdrobnienia młyna i stopnia napełnienia młyna charakteryzuje się mniejszym błędem. Jest to widoczne na rys. 8 i 9. Natomiast w obu przypadkach zwiększanie liczby neuronów w warstwie ukrytej na początku powoduje wzrost dokładności odwzorowania przebiegów, lecz po przekroczeniu pewnej granicy, która w naszym przypadku wynosi ok. 3-5 neuronów, wzrasta dokładność odwzorowania ciągów wykorzystywanych w procesie uczenia przy stałym wzroście błędu testowania. Związane jest to z dużym „potencjałem pamięciowym sieci” - sieć uczy się nieistotnych szczegółów. Można to zaobserwować porównując przebiegi z rys. 9 i 10.



Rys. 7. Schemat sieci nieliniowej dwuwarstwowej bez sprzężenia zwrotnego





Rys. 8. Przebiegi dla sieci nieliniowej dwuwarstwowej bez sprzężenia zwrotnego zawierającej 5 neuronów w warstwie ukrytej



Rys. 9. Przebiegi dla sieci nieliniowej dwuwarstwowej bez sprzężenia zwrotnego zawierającej 5 neuronów w warstwie ukrytej; model 2-go rzędu

Sieć ta została poddana także próbie zmiany ciągu uczącego. Na wejście sieci zamiast pełnego zestawu danych podany został jedynie sygnał nadawy klinkieru i ilości nadziarna. Spowodowało to konieczność doboru sieci z mniejszą ilością neuronów w warstwie ukrytej.



Rys. 10. Przebiegi dla sieci nieliniowej dwuwarstwowej bez sprzężenia zwrotnego zawierającej 20 neuronów w warstwie ukrytej; model 2-go rzędu

Dokładność odwzorowania przebiegów wyjściowych była porównywalna z przebiegami otrzymanymi dla sieci uczonej pełnym zestawem danych, lecz proces uczenia częściej kończył się w minimum lokalnym (a nie globalnym) co powodowało konieczność kilkukrotnego uczenia jednej sieci z bardzo różnymi wynikami końcowymi. Przykładowe wyniki uczenia sieci przy użyciu pełnego i uproszczonego zestawu danych zostały przedstawione w tabeli 1.

Tabela 1. Błędy i czasy uczenia dla sieci nieliniowej dwuwarstwowej

Ilość neuronów warstwy ukrytej	Błąd uczenia sieci SSE	Błąd średniokwadratowy dla danych wykorzystanych do uczenia		Błąd średniokwadratowy dla danych nie wykorzystanych do uczenia		Błąd średniokwadratowy dla pełnych danych		Czas uczenia [sek]
		folafon	blaine	folafon	blaine	folafon	blaine	
uproszczony zestaw danych uczących								
1	0,244798	0,0109	0,0235	0,0203	0,0353	0,0135	0,0256	25,97
2	0,151353	0,0042	0,0133	0,0178	0,0198	0,0110	0,0166	31,25
3	0,131760	0,0029	0,0130	0,0158	0,0210	0,0092	0,0170	44,66
5	0,104548	0,0034	0,0107	0,0137	0,0219	0,0085	0,0163	87,28
7	0,084662	0,0039	0,0094	0,0169	0,0333	0,0104	0,0213	149,67
10	0,106111	0,0037	0,0108	0,0150	0,0313	0,0093	0,0211	259,74
pełny zestaw danych uczących								
1	0,1820190	0,0086	0,0121	0,0149	0,0300	0,0119	0,0215	33,89
2	0,9776170	0,0059	0,0096	0,0209	0,1182	0,0115	0,0141	81,51
3	0,0559519	0,0044	0,0072	0,0174	0,0702	0,0121	0,0206	140,66
5	0,0347107	0,0025	0,0059	0,0167	0,0293	0,0104	0,0153	371,57
7	0,0351413	0,0028	0,0060	0,0135	0,0692	0,0111	0,0299	778,29
10	0,0308872	0,0024	0,0055	0,0154	0,0487	0,0091	0,0241	1659,20

3.2.2. Sieć wielowarstwowa ze sprzężeniem zwrotnym

Sieć dwuwarstwowa nieliniowa badana była także w układzie ze sprzężeniem zwrotnym (rys. 11). Przebieg procesu uczenia i testowania był identyczny jak w przypadku sieci bez sprzężenia zwrotnego. Dodatkowo sieć przetestowano w układach: równoległym (na wejście sieci podany został sygnał wypracowany przez sieć) i szeregowo-równoległym (na wejście sieci podany został sygnał rzeczywisty z obiektu). Zachowanie tej sieci w układzie równoległym było analogiczne z zachowaniem sieci bez sprzężenia zwrotnego. Wszystkie zaobserwowane wcześniej zależności również w tym przypadku miały miejsce. Jednakże

przebiegi generowane charakteryzowały się większym błędem i mniejszą stabilnością obliczeniową układu. W przypadku układu testowego szeregowo-równoległego generowane przebiegi posiadały błąd bliski zeru.

4. WNIOSKI

Z przeprowadzonych badań wynika, iż możliwe jest wykorzystanie metod opartych na teorii sztucznych sieci neuronowych do identyfikacji młyna kulowego. Autorzy wyrażają pogląd, iż możliwe i efektywne będzie wykorzystanie sztucznych sieci neuronowych do sterowania procesem przemiału.

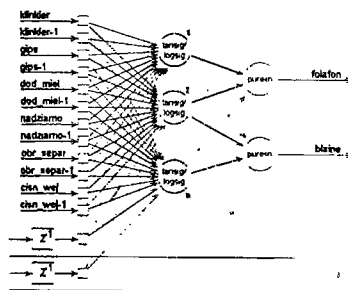
Analizując otrzymane wyniki można zauważyć, iż sieci neuronowe, w zależności od swej struktury i zastosowanych metod uczenia, posiadają różne własności. Sieć Elmana mimo posiadania wewnętrznego sprzężenia zwrotnego nie potrafi odwzorować przebiegów z wymaganą dokładnością. Krótszym czasem uczenia charakteryzuje się sieć typu Radial Basis lecz brak zbieżności w uczeniu oraz duży błąd uczenia nie pozwalają na użycie jej do dalszych badań. Lepsze właściwości posiada liniowa sieć jednowarstwowa, zawierająca w swej strukturze dwa neurony liniowe. Sieć ta potrafi generować przebiegi zbliżone (lecz z większym błędem) do przebiegów generowanych przez nieliniowe sieci wielowarstwowe jednakże czas ich uczenia wynosi ok. 1 sekundy¹. Najmniejszym błędem średniokwadratowym uczenia i testowania charakteryzowały się sieci wielowarstwowe bez sprzężenia zwrotnego z odpowiednio dobraną ilością neuronów w warstwie ukrytej. W sieciach z sprzężeniem zwrotnym otrzymywane przebiegi znacząco odbiegały od wartości rzeczywistych oraz występowały oscylacje dla przebiegu testowego. Niezależnie od występowania sprzężenia zwrotnego w sieciach tych zwiększenie rzędu modelu poprawiało jakość emulatora.

Wszystkie obliczenia symulacyjne i uczenie sieci zostały przeprowadzone z wykorzystaniem pakietu MatLab-Simulink zawierającym przybornik Neural Network.

LITERATURA

- [1] *Laserowy analizator uziarnienia LAU-10*; Materiały Instytutu Mineralnych Materiałów Budowlanych w Opolu, 1997
- [2] Polednia E., Werszler A.: *Radiometryczna metoda pomiaru dyspersji ciała stałego*; Rozprawa doktorska, Promotor prof. dr hab inż. Mieczysław Lech; Politechnika Wroclawska Instytut Techniki Ciepłej i Mechaniki Płynów, Wrocław 1997
- [3] Korbicz J., Obuchowski A., Uciński D.: *Sztuczne sieci neuronowe. Podstawy i zastosowanie*; Akademicka Oficyna Wydawnicza, Warszawa 1994
- [4] Bursy G., Siemiątkowski G.: *Identyfikacja Procesu przemiału z wykorzystaniem teorii sztucznych sieci neuronowych w środowisku MatLab-Simulink*; I Krajowa Konferencja Metody i systemy komputerowe w badaniach naukowych i projektowaniu inżynierskim, Kraków, 25-26.11.1997r., str. 27-34
- [5] Demuth H., Beale M. „*Neural Network Toolbox For Use with MatLab*”; The Math Works Inc. Natick 1994

¹ Wszystkie czasy uczenia podane zostały dla komputera 486DX4 100MHz z pamięcią RAM 16Mb



Rys. 11. Schemat sieci nieliniowej dwuwarstwowej ze sprzężeniem zwrotnym