

Ryszard KNOSALA, Aleksander GWIAZDA  
Instytut Budowy Maszyn, Politechnika Śląska, Gliwice

## PERCEPTRONOWA PRZYSTAWKA KOREKCYJNA W UKŁADZIE STEROWANIA ROBOTEM IRp-6

**Streszczenie.** W pracy przedstawiono zastosowanie sieci neuronowych do poprawienia dokładności pozycjonowania robota przemysłowego. Część pierwsza artykułu obejmuje opis sześciu głównych modeli sieci neuronowych, na bazie którego dokonano wyboru odpowiedniej, ze względu na zastosowanie, sieci. W drugiej części opisano budowę i zasadę pracy neuronowej przystawki korekcyjnej.

**Summary.** Industrial robots control systems (are not perfect) in spite of the robotics success. Robots can work only in completely described environment. Any change cause their fault work. They can't adapt to variable work conditions. Application of neural nets is one possible solution of this problem.

**Zusammenfassung.** In der vorliegenden Arbeit wird die Anwendung neuronaler Netze zur Position - Korrektur des Roboters dargestellt. Zunächst werden die sechs am häufigsten verwendeten Netztypen näher beschrieben. Aufgrund einer Analyse wird ein geeignetes zur Realisierung der Steuerebewegung neuronales Netz, d.h. Perceptron - Netz ausgewählt. Im folgenden wird die Struktur des Bewegungskorrekturmoduls sowie die Simulationsergebnisse beschrieben.

### 1. WSTĘP

Dotychczas opracowane układy sterowań robotów przemysłowych, pomimo sukcesu, jaki odniosła robotyzacja, są dalekie od doskonałości. Roboty mogą pracować tylko w znanym sobie środowisku. Jakakolwiek zmiana warunków pracy powoduje ich wadliwe działanie. Nie mają one możliwości dostosowywania się do zmieniających się warunków pracy. Jedno z rozwiązań tego problemu może polegać na zastosowaniu sieci neuronowych [1].

Sztuczne sieci neuronowe mają być kopią sieci neuronowych, jakie występują w mózgu ludzkim, tak jak ramię robota jest kopią ręki człowieka. Ostatnie lata, a szczególnie rozwój mikroelektroniki oraz informatyki, pozwoliły na wprowadzenie tej idei w życie. Praca ta będzie traktowała o zastosowaniu sieci neuronowej do poprawienia dokładności pozycjonowania manipulatora robota przemysłowego.

### 2. OBSZAR BADAŃ

Idea przystawki korekcyjnej mającej za zadanie poprawę dokładności pozycjonowania chwytaka manipulatora robota przemysłowego została przedstawiona przez G. Josina, D. Charneya, i M. White'a w pracy [2]. Jedną z ważniejszych zalet tego rozwiązania jest to,



że sieć pracuje jako przystawka do już istniejących układów sterowania. Unika się w ten sposób, w razie zastosowania tego rozwiązania, wymiany istniejących układów sterowania. Również wyniki prób symulacyjnych, jakie zaprezentowali autorzy, były bardzo obiecujące. Gdy sieć była szkolona tylko na jednym punkcie szkoleniowym, uzyskiwano przeciętnie poprawę dokładności pozycjonowania o 60%. Przy 3 punktach szkoleniowych dokładność pozycjonowania była 6 razy wyższa, a przy 8 punktach szkoleniowych aż 11 razy.

Podobną ideę przedstawił dwa lata później B. Macukow w pracy [3]. Idea przystawki korekcyjnej pozostała, natomiast zmiany dotyczyły stosowanego aparatu matematycznego. Wyniki przedstawione w wymienionej pracy są również interesujące, bowiem gdy sieć była uczona tylko na jednym punkcie szkoleniowym, następowała poprawa dokładności o około 50%. Natomiast po uczeniu sieci na ośmiopunktowym zbiorze szkoleniowym dokładność pozycjonowania wzrastała dziesięciokrotnie. Podsumowując pracę, autor stwierdził, że w praktyce powinien wystarczyć trzypunktowy zbiór szkoleniowy. Prace te miały jednak znacznie ograniczone założenia, gdyż badania symulacyjne przystawki zostały przeprowadzone dla robota o dwóch stopniach swobody. Przypadki takie w zasadzie nie występują w rzeczywistości. Budowa takiej przystawki dla robotów o większej liczbie stopni swobody nie jest tylko problemem zwiększenia liczby węzłów w sieci. Manipulator robota o dwóch stopniach swobody pracuje na płaszczyźnie. Stąd łatwo opisać przemieszczenia końcówki roboczej w postaci prostych równań wiążących jej położenie z kątami pomiędzy ramionami. W prosty sposób można też otrzymać przekształcenie odwrotne. Daje ono układ równań potrzebnych do obliczenia, jakie wartości muszą przyjąć kąty pomiędzy ramionami, aby końcówka robocza zajęła pożądane położenie. Natomiast w przypadku manipulatora robota o trzech i więcej stopniach swobody nie jest możliwe otrzymanie przekształcenia odwrotnego. W praktyce przekształcenie takie otrzymuje się stosując dodatkowe założenia dotyczące pożądanej orientacji przestrzennej końcówki roboczej.

### 3. PRZEGLĄD ALGORYTMÓW SIECI NEURONOWYCH

Najistotniejszym zagadnieniem, jakie mieli do rozwiązania autorzy wspomnianych prac, był wybór odpowiedniego modelu sieci neuronowej. Każdy model został opracowany w taki sposób, aby spełniał przyjęte założenia, w związku z czym nadaje się tylko do określonych, a nie nadaje się do różnych zastosowań. Istnieje więc potrzeba analizy znanych modeli sieci neuronowych w celu dokonania wyboru odpowiedniego modelu dla przystawki korekcyjnej robotów o trzech i więcej stopniach swobody.

Pierwszą z omawianych będzie sieć Hopfielda. Została ona opracowana jako pamięć skojarzeniowa. Stąd najlepiej działa, gdy na podstawie danych częściowych lub zafałszowanych trzeba odtworzyć cały wzorzec. Ma ona w związku z tym szerokie zastosowanie w telekomunikacji. Sieć ta nie może pracować jako klasyfikator, gdyż wynikiem jej działania jest wzorzec właściwej klasy, jednak bez określenia, jaka to klasa. Do ograniczeń tej sieci należą również: mała liczba wzorców możliwa do zapisania w sieci oraz możliwa niestabilność wytworzonego wzorca, gdy dwa zapisane w sieci wzorce mają dużą liczbę punktów wspólnych.



Następna sieć - sieć Hamminga charakteryzuje się już innym sposobem pracy. Jej zadaniem jest wybór klasy, do której należy wzorzec wejściowy. Zadanie to jest realizowane w dwóch etapach. Najpierw w niższej podsieci następuje obliczenie odległości Hamminga pomiędzy zapisanymi w sieci wzorcami a wzorcem wejściowym. W drugim etapie wyższa podsieć, nazywana „Maxnet”, wybiera węzeł mający najmniejszą odległość Hamminga. Numer wybranego węzła odpowiada wybranej przez sieć klasie. Sieć Hamminga ma wiele zalet w porównaniu z siecią Hopfielda. Po pierwsze, sieć Hamminga wymaga około 10 razy mniej połączeń niż sieć Hopfielda. Po drugie zaś sieć ta nie daje niestabilnej odpowiedzi, gdy dwa zapisane w niej wzorce mają dużo punktów wspólnych.

Trzecią analizowaną siecią będzie klasyfikator Carpentera - Grossberga. Zaletą tej sieci jest to, że może ona pracować bez nadzoru. Zapisanie wzorca w sieci odbywa się automatycznie. Pierwszemu zapisanemu wzorcowi zostaje przypisany pierwszy węzeł wyjściowy, drugiemu drugi itd. W poprzednich sieciach zapisywanie wzorców odbywało się w procesie szkolenia sieci przez operatora. Praca tego klasyfikatora polega na wzmacnianiu sygnału wyjściowego z tego węzła, który odpowiada najbardziej prawdopodobnej klasie, do jakiej należy prezentowany wzorzec wejściowy. Gdy wzorzec wejściowy nie odpowiada żadnemu z zapisanych wzorców, to wtedy następuje przypisanie następnego wolnego węzła wyjściowego klasie, jaką reprezentuje ten prezentowany wzorzec wejściowy. Sieć ta ma jednak dwa poważne ograniczenia. Po pierwsze, gdy ustali się zbyt wysoki próg „czułości”, następuje lawinowy wzrost ilości wzorców zapisanych w sieci. Poza tym specyficzny sposób modyfikowania zapisanych wzorców przez stosowanie logicznej operacji AND pomiędzy starym i nowym wzorcem sprawia, że tak zmodyfikowane wzorce mogą się różnić od prawidłowego wzorca danej klasy.

Wszystkie wymienione wyżej sieci mają jedno wspólne ograniczenie. Sieci te mogą pracować tylko ze wzorcami wejściowymi, przedstawionymi w postaci binarnej. Natomiast omówione w dalszej części sieci mogą już pracować ze wzorcami wejściowymi przedstawionymi zarówno w postaci binarnej, jak i ciągłej. Perceptron jednopoziomowy jest najprostszym przykładem tego typu sieci. Cieszył się on zainteresowaniem w swoim początkowym okresie rozwoju. Posiadał możliwość przypisywania wzorca wejściowego do jednej z dwóch klas. Klasyfikacja ta polegała na przypisaniu wzorcowi wejściowemu wartości +1, gdy został zaklasyfikowany do klasy A lub 0 (ewentualnie -1), gdy został zaklasyfikowany do klasy B. Jednak z drugiej strony perceptron działał poprawnie tylko wtedy, gdy klasy dało się rozdzielić linią prostą, zwaną granicą decyzyjną. Ograniczenia perceptronu jednopoziomowego usuwa perceptron wielopoziomowy. Może on rozróżniać klasy pomieszane ze sobą dzięki zdolności tworzenia dowolnych obszarów decyzyjnych. Przy czym zastosowanie sigmoidalnej funkcji węzłów pozwoliło na zastąpienie linii prostych, używanych do tworzenia obszarów decyzyjnych, krzywymi. Do zalet tej sieci należy również łatwość szkolenia.

Ostatnią omawianą siecią jest sieć Kohonena. Jej idea polega na odwzorowaniu map tworzonych w biologicznych sieciach neuronowych. W procesie szkolenia poszczególnym węzłom wyjściowym zostaje przypisana pewna klasa wzorca wejściowego, przy czym im bliżej znajdują się dwa węzły, tym bardziej podobne są odpowiadające im wzorce. Ważne dla pracy tej sieci jest więc położenie węzła, a nie sygnał wyjściowy.

Z przedstawionego przeglądu wynika jasno, że w charakterze przystawki korekcyjnej najlepiej będzie pracował perceptron wielopoziomowy. Jest to jedyna sieć posiadająca możliwość tworzenia skomplikowanych obszarów decyzyjnych, odpowiadających złożoności



problemów związanych ze sterowaniem robotów. Poza tym możemy nauczyć tę sieć, które węzły odpowiadają określonym kątom w układzie kinematycznym robota. W przypadku sieci Kohonena nie mamy takiej możliwości, gdyż sieć ta przypisuje węzłom wartości wyjściowe w sposób losowy, a ponadto metoda szkolenia tej sieci jest o wiele bardziej skomplikowana.

#### 4. DZIAŁANIE I ZALETY PERCEPTRONOWEJ PRZYSTAWKI KOREKCYJNEJ

Trzeba jasno stwierdzić, że pracujące układy sterowań robotów przemysłowych posiadają wiele ograniczeń. Po pierwsze, zdarza się, że robot jest narażony na różnego rodzaju oddziaływania mechaniczne. Mogą one spowodować przesunięcie się podstawy robota, a co za tym idzie i przesunięcie układu współrzędnych robota. Powstaje w wyniku tego stały błąd pozycjonowania i stąd przypadek ten nosi nazwę „przypadku błędu stałego”. Po drugie, na skutek różnic temperatury otoczenia ramiona robota mogą zmieniać swoją długość. Zmiana długości ramion spowoduje, że położenie punktu końcowego będzie różnić się od położenia obliczonego na podstawie układu równań sterujących. Jednakże w określonych warunkach błąd ten możemy traktować jako stały, nosi więc nazwę „przypadku błędu quasi-stałego”. Po trzecie, trzeba uwzględnić fakt, że robot pracuje w określonych warunkach i przy określonych obciążeniach. Ramiona robota są, w ujęciu wytrzymałościowym, belkami obciążonymi na końcu ciężarem innych ramion i końcówki roboczej. Wobec czego następuje ugięcie ramion i związana z tym zmiana położenia końcówki roboczej nie uwzględniona przez układ sterowania robota. Wielkość tego błędu zależy od ciężaru ramion i końcówki roboczej, stąd przypadek ten nosi nazwę „przypadku błędu zmiennego”. Wszystkich wspomnianych błędów można uniknąć poprzez zastosowanie neuronowej przystawki korekcyjnej. W procesie szkolenia sieć można nauczyć obliczania poprawek korygujących, na podstawie których układ sterowania mógłby korygować położenie końcówki roboczej. Wspomniane poprawki korygujące można przedstawić w postaci następujących równań:


$$\begin{aligned}\Delta\theta &= \theta_{1rz} - \theta_{1teor} \\ \Delta\theta &= \theta_{2rz} - \theta_{2teor}\end{aligned}$$

Praca sieci odbywa się w dwóch etapach. W pierwszym następuje uczenie sieci. Jako dane wejściowe do sieci są wprowadzane informacje o położeniu docelowym w postaci współrzędnych punktu końcowego oraz teoretycznie obliczone wartości kątów ustawienia ramion robota. Na podstawie tych wartości sieć określa wielkość poprawek. Te obliczone przez sieć poprawki są porównywane z poprawkami rzeczywistymi i na podstawie tego porównania następuje modyfikacja wag połączeń, tak aby różnica pomiędzy poprawkami rzeczywistymi i obliczonymi była jak najmniejsza. W zależności od liczby kroków uczenia, różnica pomiędzy tymi wielkościami może być większa lub mniejsza. Natomiast w drugim etapie sieć na podstawie informacji zapisanej w procesie szkolenia oraz aktualnych danych wejściowych określa wartości poprawek. Danymi wejściowymi są: wymagane położenie końcowe oraz teoretycznie obliczone wartości kątów. W wyniku przetworzenia tych danych otrzymujemy poprawione sygnały sterujące położeniem ramion robota.



## 5. METODA BADAŃ I SPOSÓB PREZENTACJI WYNIKÓW

Przyjęto metodę komputerowych badań symulacyjnych układu sterowania z neuronową przystawką korekcyjną przedstawionego na rys.1. Jak widać, przystawka korekcyjna została włączona w konwencjonalny układ sterowania robota, przez co unika się wymiany całego starego układu na nowy. Obniżyłoby to koszty w wypadku wdrożenia tego typu układu.



Rys.1. Neuronowa przystawka korekcyjna w układzie sterowania robota  
Fig.1. Neural correction attachment in robot control system

Na rys. 2 pokazana jest konfiguracja perceptronu trójpoziomowego, zastosowanego jako neuronowa przystawka korekcyjna. Liczba węzłów na pierwszym poziomie odpowiada liczbie danych wejściowych. Danymi tymi są współrzędne punktu docelowego  $x_k, y_k, z_k$  oraz teoretycznie obliczone wartości kątów ustawienia ramion  $\theta_i, i = 1, 2, 3, 4$  (liczba stopni swobody dla robota IRp-6). Liczba węzłów wyjściowych odpowiada liczbie kątów sterowanych. Są to:

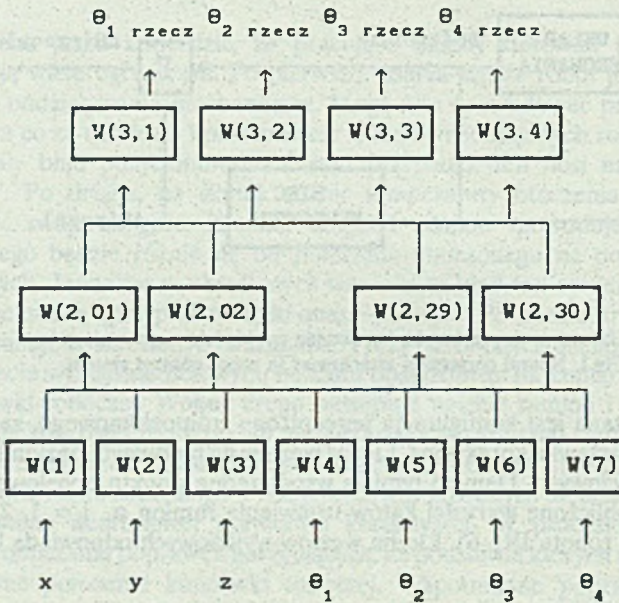
- $\theta_1$  - kąt obrotu pierwszego ramienia,
- $\theta_2$  - kąt obrotu drugiego ramienia,
- $\theta_3$  - kąt obrotu chwytaka,
- $\theta_4$  - kąt obrotu robota wokół podstawy.

W warstwie środkowej przyjęto w drodze prób 30 węzłów.

Na podstawie przyjętego modelu sieci został opracowany program, który posłużył do przeprowadzenia badań symulacyjnych. Celem badań było sprawdzenie sposobu modyfikacji wag połączeń, w przypadku gdy sieć pracuje jako przystawka korekcyjna robota o pięciu stopniach swobody. Sprawdzenie to może dać również odpowiedź na pytanie o skuteczność tego typu przystawki. Wyniki badań są prezentowane w postaci wykresów. Przedstawiają one w ujęciu względnym zmianę poprawki w trakcie uczenia się sieci. Wartość względną poprawek liczona była według następującego wzoru:

$$B_{wz} = \frac{|\theta_{rz} - \theta_{obl}|}{\theta_{rz}} 100\%$$

Badania były prowadzone dla różnej wielkości błędów pozycjonowania oraz dla różnej liczby cykli uczenia.



Rys.2. Schemat sieci perceptronowej  
Fig.2. Scheme of a perceptron network

## 6. OMÓWIENIE WYNIKÓW BADAŃ


Analizując wyniki badań trzeba stwierdzić, że w ogólnych zarysach potwierdziły one wnioski cytowanych prac. Sieć w sposób łatwy uczyła się odchyłek. Dopasowywanie wyników następowało po około 4 do 7 krokach iteracji. Otrzymane wyniki w sposób dobry przybliżały rzeczywiste wartości kątów. Średnio następowała trzykrotna poprawa dokładności pozycjonowania. Jest to wynik wielce obiecujący.

Jednakże z drugiej strony przeprowadzone badania wykazały też kilka istotnych mankamentów w pracy sieci. Po pierwsze, gdy jedna odchyłka jest mała, a inne są duże, to występuje tzw. zjawisko wpływu. Przejawia się to tym, że wartość poprawki, generowana



przez sieć dla małej wartości odchyłki, staje się duża i zbliża się do wartości poprawek generowanych dla pozostałych wartości odchyłek. Powoduje to wzrost wartości błędu pozycjonowania, zamiast obniżenia. Przypadek ten ilustruje rys. 3, na którym pokazano, w jaki sposób zbliżone wartości poprawek kątów  $\theta_2$ ,  $\theta_3$  i  $\theta_4$  (oznaczone odpowiednio jako  $\otimes$ ,  $\ominus$ ,  $\odot$ ) wpływają na modyfikację poprawki dla kąta  $\theta_1$  (oznaczonego jako  $\oplus$ ). Jak widać, wartość poprawki dla tego kąta odbiega w sposób zasadniczy od wartości poprawek dla pozostałych trzech kątów.

Następną niedogodnością jest wąski przedział pracy. Sieć potrafi dobierać wagi tylko wtedy, gdy odchyłki należą do przedziału pracy sieci. Gdy odchyłki nie należą do przedziału pracy, sieć wygeneruje, jako poprawkę, wartość dolnej granicy przedziału pracy, jeśli odchyłka rzeczywista jest mniejsza od tej wielkości. Gdy wartość odchyłki jest większa od górnej granicy przedziału pracy, to zostanie ona podana jako odpowiedź sieci. Fakt ten, niestety, zawęża zakres stosowności tego typu przystawki. Na rys. 4 pokazano przykładowe wyniki dla poszczególnych kątów, które wynosiły odpowiednio 0.022 dla  $\theta_1$ , 0.138 dla  $\theta_2$ , 0.116 dla  $\theta_3$  i 0.132 dla  $\theta_4$ . Przedział pracy sieci zawierał się w określonym przez funkcję węzła zakresie od 0.182 do 0.818, więc sieć nie dobierała odchyłek poza tym przedziałem.




Rys.3. Ilustracja zjawiska wpływu  
Fig.3. The illustration of the influence case

Na rysunku widać, że po piątym kroku sieć nie modyfikuje już poprawek, ponieważ wartości, jakie do tego czasu określiła, odpowiadają dolnej granicy przedziału pracy. Stąd też każda następna wartość, jaką wygeneruje sieć, będzie dolną granicą przedziału pracy sieci.

Dodatkowo trzeba stwierdzić, że sieć ta cechuje się pewną bezwładnością. To znaczy, że dopasowywanie wag odbywa się w sposób cykliczny, przy czym sieć przechodzi przez punkt optymalny. Na rys. 5 widać, jak po dobraniu w piątym kroku poprawek sieć zaczyna w każdym następnym kroku odchodzić od wartości optymalnej.

Tak omówione osobliwości w działaniu sieci występują niestety w pełnym zakresie pracy, lecz ich wpływ zależy głównie od wielkości poprawek, jakie mają zostać wygenerowane.




Rys.4. Ograniczenie zakresu pracy  
Fig.4. The restriction of a work range

Jeśli leżą one daleko poza zakresem pracy lub w pobliżu środka przedziału pracy, to ich wpływ na poprawność działania sieci jest duży. Gdy natomiast znajdują się w pobliżu granic przedziału pracy, ich wpływ na funkcjonowanie sieci jest ograniczony.

Podsumowując trzeba stwierdzić, że sieci neuronowe mogą stać się pomocnym narzędziem pracy, pod warunkiem poprawienia wspomnianych niedociągnięć oraz rozszerzenia zakresu pracy, aby można je było zastosować nie tylko do manipulatorów



robotów z obrotowymi parami kinematycznymi, ale i przesuwными. Badania nad tymi zagadnieniami są kontynuowane.



Rys.5. Przykład bezwładności sieci  
Fig.5. An example of the net inertia

## LITERATURA

- [1] Lippmann R. An Introduction to Computing with Neural Nets. IEEE ASSP Magazine, April 1987.
- [2] Josin G., Charney D., White D.: Robot Control Using Neural Networks. Proc. of the IEEE Int. Conf. on Neural Networks 2, San Diego, California 1988.
- [3] Macukow B.: Sieci neuronowe w układach sterowania robotów. Prace Naukowe Instytutu Cybernetyki Technicznej Politechniki Wrocławskiej Nr 83, 1990.



## THE PERCEPTRON CORRECTION ATTACHMENT IN THE IRp-6 CONTROL SYSTEM

### Abstract

Industrial robots control systems (are not perfect) in spite of the robotics success. Robots can work only in completely described environment. Any change cause their fault work. They can't adapt to variable work conditions. Application of neural nets is one possible solution of this problem. Artificial neural nets are copies of biological ones existing in human brain like the robot arm is a copy of human one. Development of micro electronics and computer science let to built good working neural nets. This paper presents an application of a such neural net to improve the positioning accuracy of the robot arm. It was discussed the main idea of the neural correction attachment. This correction attachment can learn the differences between real joint angles and theoretical ones. So it is possible to determine the real value of the joint angles and improve the accuracy of positioning. This idea was presented by G. Josin, D. Charney and M. White in 1988. Two years later B. Macukow presented the same idea of correction attachment. But he changed the algorithm of work. In the first part was described six main neural nets to show why the perceptron was chosen. And why it is the best net for that application. The computer simulation was used to do research work to determine how that correction attachment work.

The results show that perceptron works good as a correction attachment. It is possible to improve the accuracy of work. but from the other hand it was discovered that in some special cases net work not so good. In authors opinion it will be a powerful instrument of work.

Recenzent: Prof. Ewald Macha

Wpłynęło do redakcji w styczniu 1992