

MODEL SYSTEMU SAMOUCZĄCEGO W DIAGNOSTYCE MEDYCZNEJ

MODEL OF SELF-LEARNING SYSTEM IN MEDICAL DIAGNOSTICS

**Tomasz Giżewski¹, Ireneusz M. Kowalski^{2,4}, Daniel Zarzycki³,
Anna Radomska-Wilczewska⁴, Roman Lewandowski⁴, Tomasz Kotwicki⁵**

¹ Instytut Podstaw Elektrotechniki i Elektrotechnologii, Politechnika Lubelska

² Katedra i Klinika Rehabilitacji, Wydział Nauk Medycznych, Uniwersytet Warmińsko-Mazurski w Olsztynie

³ Katedra i Klinika Ortopedii i Rehabilitacji, Collegium Medicum, Uniwersytet Jagielloński, Zakopane

⁴ Wojewódzki Szpital Rehabilitacyjny dla Dzieci w Ameryce

⁵ Klinika Ortopedii Dziecięcej, Uniwersytet Medyczny w Poznaniu

STRESZCZENIE

Wstęp. Druga połowa XX w. zapoczątkowała erę komputerowych systemów kontrolnych, pomiarowych i decyzyjnych. Zastosowania medyczne zaowocowały implementacją w urządzeniach cyfrowych do monitoringu stanu pacjenta, diagnostyce obrazowej i diagnostyce laboratoryjnej. W przedstawionym artykule autorzy skoncentrowali uwagę na systemach decyzyjnych, a w szczególności systemach decyzyjnych samouczących, proponowanych do zastosowania w diagnostyce medycznej.

Cel pracy. Celem pracy było stworzenie modelu systemu samouczącego w diagnostyce rehabilitacyjno-ortopedycznej zbudowanego na podstawie danych klinicznych pacjentów.

Materiał i metody. Klasyfikacji poddano jednostki chorobowe 850 pacjentów w wieku od 6 do 20 lat (średnia 14,6 lat), leczonych z powodu skoliozy idiopatycznej (SI) w Katedrze i Klinice Rehabilitacji i Wojewódzkim Szpitalu Rehabilitacyjnym dla Dzieci w Ameryce koło Olsztyna. Technika diagnostyki obrazowej (RTG, TK, TK-3D) została skoncentrowana na identyfikacji charakterystycznych jednostek, wyszukiwanych algorytmami rozpoznawania obrazów lub analizą widma

otrzymanego z dokonanych transformacji Fouriera lub transformacji Falkowych. W przypadku identyfikacji SI, do analizy danych zasadnym było stosowanie technik diagnostyki obrazowej oraz danych wywiadu lekarskiego i środowiskowego.

Wyniki. W wyniku badań utworzono wektor wyjściowy w postaci przewidywanych efektów leczenia. Topologia sieci klasyfikującej zaprojektowana została na podstawie rekurencyjnego algorytmu sztucznej sieci neuronowej.

Wnioski. Przeprowadzona procedura klasyfikacji dowodzi, że ukształtowanie danych wejściowych oraz unormowanie wektora odpowiedzi pozwala na budowę systemu rozmytego do prognozowania wyników leczenia na podstawie zdobytej wiedzy. Dla kompetentnego lekarza, system samouczący może pełnić jedynie funkcję doradczą, który na podstawie zgromadzonych informacji, tworzy reguły stanowiące wygodne narzędzie informacyjne.

ABSTRACT

Introduction. The era of computer testing, measurement and decision-making systems began in the second half of the 20th century. Medical application of such systems manifests itself in digital devices for the observation of the patient's condition, X-ray and laboratory diagnostics. In this article the authors concentrate on the decision-making systems, and, in particular, on decision-making self-learning systems which, as the authors suggest, could be applied in medical diagnostics.

Creating the model of the self-learning system based on patients' clinical records for the use of rehabilitation-orthopedic diagnostics is the principal aim of this research.

Materials and methods. Pathological entities displayed by 850 patients (at the age of 6–20 years, on average 14.6 years) were classified. All the patients underwent treatment for idiopathic scoliosis (IS) in the Department and Clinic of Rehabilitation and in the Provincial Rehabilitation Hospital for Children in Ameryka near Olsztyn, Poland. The diagnostics imaging technique (X-ray, CT, CT-3D) was focused on identifying characteristic entities, discovered by the image algorithm identification and by the analysis of spectrum obtained out of Fourier transformation and Falk transformation. As regards the IS identification, it was appropriate to use diagnostics imaging techniques, as well as anamnesis to analyze the data.

Results and discussion. The research resulted in creating the output vector in the form of anticipated treatment effects. The topology of the classification network was designed on the basis of the artificial neural networks recurrent algorithm.

Conclusions. The applied classification procedure proves that defining input data and normalizing reply vector allows researchers to build the artificial neural network for the purpose of anticipating treatment effects on the basis of the acquired

knowledge. For a competent medical doctor, the self-learning system can function only as an advisory device, which produces a useful information tool by means of accumulated information.

Słowa kluczowe: sztuczne sieci neuronowe, system samouczący, prognozowane efekty leczenia.

Key words: artificial neural network, self-learning system, anticipated treatment effects.

WSTĘP

Druga połowa XX w. charakteryzowała się dynamicznym rozwojem technik komputerowych, stosowanych zarówno w przetwarzaniu informacji, jak i w systemach pomiarowych i kontrolnych. Szczególną uwagę należy zwrócić na powstanie automatycznych procesów decyzyjnych, opracowanych na regułach rozmytych. Uporządkowanie informacji o medycznych klasyfikacjach stanu pacjenta umożliwiło aplikację systemów komputerowych w monitoringu czynności życiowych, diagnostyce obrazowej i laboratoryjnej [1–5].

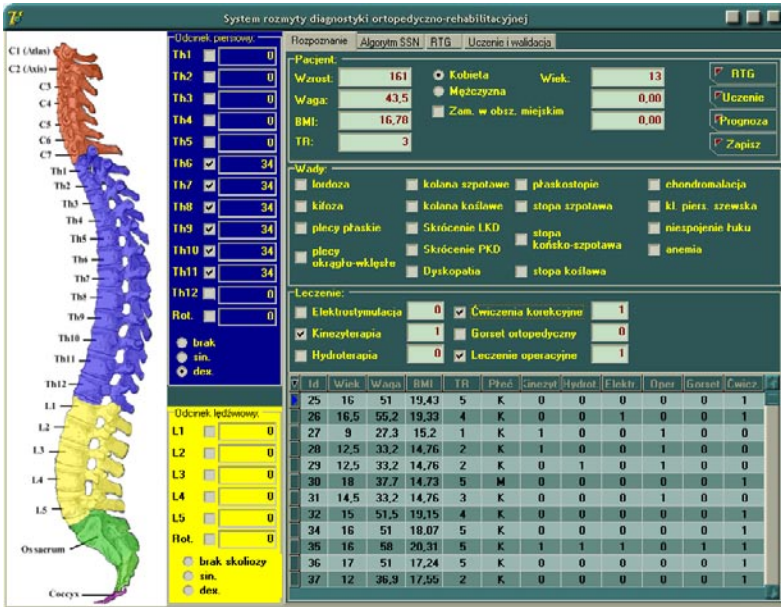
Doniesienia autorów pracujących nad szczególnymi rozwiązaniami aplikacji medycznych pozwoliły na sformułowanie hipotezy o zastosowaniu technik rozmytych w prognozowaniu i klasyfikacji jednostek chorobowych, typowych także dla oddziałów rehabilitacyjnych. Szczególną uwagę zwrócono na problematykę diagnostyki rehabilitacyjno-ortopedycznej skrzywień kręgosłupa [1–5, 8–11].

CEL PRACY

Celem pracy było stworzenie modelu systemu samouczącego w diagnostyce rehabilitacyjno-ortopedycznej zbudowanego na podstawie danych klinicznych pacjentów.

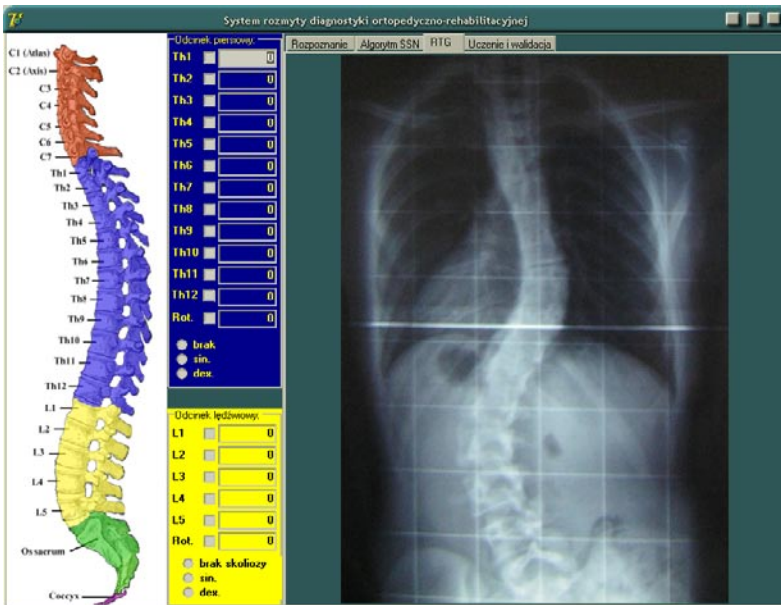
MATERIAŁ I METODY

Analiza fenomenologiczna procesu diagnostyki medycznej umożliwiła sprecyzowanie czynników decydujących o klasyfikacji jednostki chorobowej 850 pacjentów w wieku od 6 do 20 lat (średnia 14,6 lat), leczonych z powodu skoliozy idiopatycznej (SI) w Katedrze i Klinice Rehabilitacji i Wojewódzkim Szpitalu Rehabilitacyjnym dla Dzieci w Ameryce koło Olsztyna. W odróżnieniu od automatycznych systemów rozpoznawania obiektów (w wynikowych danych z technik obrazowych czy sygnałowych) w proponowanych rozwiązaniach przyjęto uwzględnianie danych dotyczących pacjenta. Technika diagnostyki obrazowej (RTG, TK, TK-3D) została skoncentrowana na identyfikacji charakterystycznych jednostek, wyszukiwanych algorytmami rozpoznawania obrazów lub analizą widma otrzymanego z dokonanych transformacji Fouriera lub transformacji Falkowych. W przypadku identyfikacji SI, do analizy danych zasadnym było stosowanie technik diagnostyki obrazowej oraz danych wywiadu lekarskiego i rodowiskowego [4–8, 10–13].



Ryc. 1. Główne okno programu do gromadzenia oraz parametryzowania danych diagnostycznych.

Fig. 1. The principal window of the program to accumulate and gathering parameters of diagnostics data.



Ryc. 2. Projektowany moduł analizy cyfrowych zdjęć RTG.

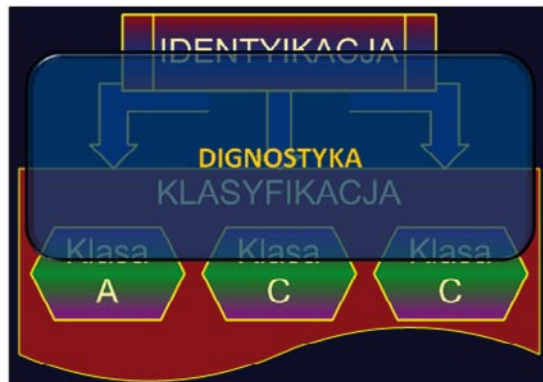
Fig. 2. Designed module of digital X-ray analysis.

Poszukiwanie rozwiązań, potwierdzających stawianą hipotezę, wymagało szczegółowej analizy zbioru informacji uzyskiwanych w trakcie wywiadu lekarskiego [8, 13]. Do wymienionego celu stworzono bazę danych oraz aplikację do ich interpretacji i manipulacji, której główne okno przedstawiono na rycinie 1.

Konstrukcja aplikacji umożliwia wprowadzenie danych z wywiadu lekarskiego oraz charakterystyczne cechy fizjologiczne pacjenta. Niezależnie od użytkownika aplikacji dane zostają sparametryzowane w utworzony ciąg wartości liczbowych. Otrzymany w ten sposób uporządkowany wektor został przetworzony za pomocą metod rozmytych. Pomocniczym, znajdującym się w fazie projektowania modułem programu jest analiza cyfrowych zdjęć RTG (Ryc. 2.). Projektowane są w nim możliwości rozpoznawania charakterystycznych obiektów, dzięki którym zautomatyzowany został proces ich częściowej interpretacji.

WYNIKI I ICH OMÓWIENIE

Diagnostyka w ujęciu proponowanego modelu skupiła się wokół klasyfikacji do jednostki chorobowej. Na podstawie informacji uzyskanych po przeprowadzeniu badania i wywiadu lekarskiego zaprojektowano podstawowe funkcje analityczne: identyfikację, klasyfikację oraz prognozowanie, dla których diagram strukturalny modelu przedstawiono na rycinie 3.

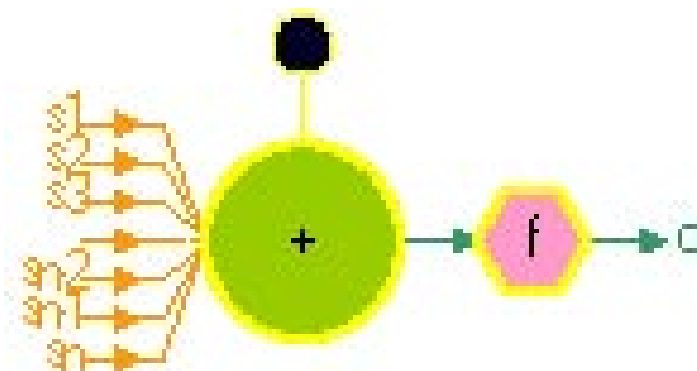


Ryc. 3. Diagram strukturalny modelu.

Fig. 3. Structural graph of the model.

Jako podstawowy element utworzonego systemu rozmytego wybrano model sztucznego neuronu (Ryc. 4).

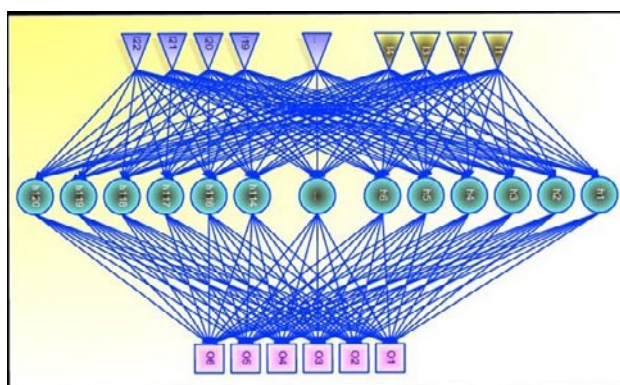
Utworzono w programie wirtualną strukturę perceptronów prostych (Ryc. 5), o jednej warstwie ukrytej z liczbą neuronów 120 oraz 132, w warstwie wejściowej – 22 i wyjściowej – 6. Wartości wejściowe utworzono z wymienianego uporządkowanego zbioru informacji zdobytych na podstawie wywiadu oraz wyników badań. Każdemu z neuronów przyporządkowano sigmoidalną funkcję aktywacji neuronu.



Ryc. 4. Model sztucznego neuronu.

Fig. 4. Artificial neuron model.

W wyniku badań utworzono wektor wyjściowy w postaci przewidywanych efektów leczenia. Topologia sieci klasyfikującej zaprojektowana została na podstawie rekurencyjnego algorytmu sztucznej sieci neuronowej.

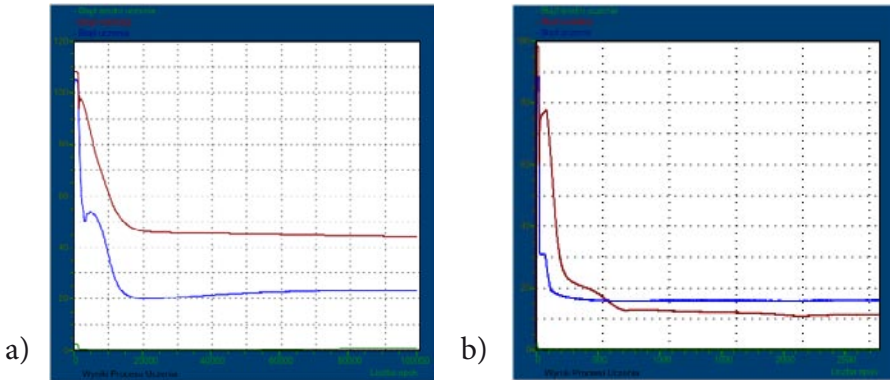


Ryc. 5. Model struktury perceptronu wielowarstwowego.

Fig. 5. Model of multilayer perceptron structure.

Dla zróżnicowania danych uczących (próbna 850 przypadków) dla wybranych neuronów w warstwie wejściowej wprowadzono szumy zgodnie z rozmyciem Gaussa. Uczenie przeprowadzono do górnej granicy 100 000 epok uczących. Dla struktur modelu podstawowego dobierano podstawowe parametry algorytmu uczącego: moment α i prędkość uczenia BPS w celu uzyskania zbieżności funkcji błędów uczącego. Wynik uznano za pozytywny w chwili uzyskania stabilnego minimum w granicach 20%.

Wyniki badań przedstawiono w postaci graficznej na rycinie 6. Konstrukcja systemu stanowi jedynie postać rozwojową. Po przeprowadzonych wstępnych analizach i konfrontacjach klinicznych możliwe było sformułowanie wniosków końcowych.



Ryc. 6. Wyniki procesu uczenia. Błędy walidacji i maksymalna prędkość uczenia dla: a) $\alpha=0,1$ oraz BPS=0,1; b) $\alpha=0,3$ oraz BPS=0,2.

Fig. 6. Results of the learning process. Validation errors and maximum learning time for: a) $\alpha=0.1$ and BPS=0.1; b) $\alpha=0.3$ and BPS=0.2.

DYSKUSJA

Druga połowa XX w. zapoczątkowała erę komputerowych systemów kontrolnych, pomiarowych i decyzyjnych. Zastosowania medyczne zaowocowały implementacją w urządzeniach cyfrowych do monitoringu stanu pacjenta, diagnostyce obrazowej i diagnostyce laboratoryjnej [1, 3, 8, 11]. W przedstawionym artykule autorzy skoncentrowali uwagę na systemach decyzyjnych, a w szczególności systemach decyzyjnych samouczących, proponowanych do zastosowania w diagnostyce rehabilitacyjno-ortopedycznej [8]. Przeprowadzono rozważania wokół fenomenologicznego ujęcia problemu diagnostyki jako nauki o sposobach rozpoznawania chorób na podstawie badania podmiotowego oraz badania przedmiotowego [4, 6, 7, 12, 13]. Na przesłankach wynikających z doświadczeń badawczych oraz tradycji analiz statystycznych, zaproponowano modele oraz struktury danych, wykorzystanych w realizacji problemu [2, 9, 10]. W pracy przedstawiono modele, wzorowane na systemach probabilistycznych [3, 9]. Nie było możliwe opisanie jednoznacznym modelem matematycznym przedmiotu badań – jednostki chorobowej. Tworzone są jedynie modele przybliżone, określone pewnym prawdopodobieństwem. Porządkowanie w grupach prawdopodobieństwa umożliwiło określenie wzorców. Prowadząc rozważania nad wzorcami oraz wynikami analiz statystycznych, zwrócono uwagę na problem identyfikacji [3, 5]. Uwagę skoncentrowano na komputerowym systemie decyzyjnym, który zespół skonstruował na bazie algorytmów sztucznych sieci neuronowych. Szczegółowo przedstawiono wszystkie podstawowe atuty tego rozwiązania. Z uwagi na kształt procesu decyzyjnego i diagnostycznego oraz z punktu widzenia zbioru danych, elementy stanowiące przesłankę w podejmowaniu decyzji określono wielowymiarową strukturą. Dla jej interpretacji wykorzystano struktury sieci neuronowych, które

dzięki sposobom przetwarzania informacji, odznaczają się możliwością generalizacji nabytej wiedzy, grupowania obiektów podobnych oraz możliwością odrzucania błędów przypadkowych. W odniesieniu do każdej struktury zestawiono właściwe, wynikające z doświadczeń przesłanki w celu przedstawienia oceny odpowiedzi [9]. Przedstawione wyniki badań stanowią dowód o zasadności budowy systemów decyzyjnych, stanowiących wspomaganie procesu diagnostycznego w medycynie.

WNIOSKI

1. Podjęte przez perceptron wielowarstwowy zadanie klasyfikacji wykazuje tendencje minimalizacji błędu uczenia i walidacji.
2. Przeprowadzona procedura klasyfikacji dowodzi, że ukształtowanie danych wejściowych oraz unormowanie wektora odpowiedzi pozwala na budowę systemu rozmytego do prognozowania wyników leczenia na podstawie zdobytej wiedzy.
3. System wykazuje tendencję generalizowania nabytej wiedzy i umożliwia analizę przypadków różniących się od podanych w zbiorze uczącym.
4. Wyniki badań utworzyły podstawę sformułowania tezy o zasadności budowy systemów rozmytych do wspomagania diagnostyki medycznej.
5. Dla kompetentnego lekarza system samouczący może pełnić jedynie funkcję doradczą, na podstawie zgromadzonej informacji tworzy reguły stanowiące wygodne narzędzie informacyjne.

Podziękowania

Zespół autorów wyraża podziękowania Prof. dr. hab. n. med. Markowi Józwiakowi z Uniwersytetu Medycznego w Poznaniu za uwagi kliniczne w przygotowaniu artykułu.

PIŚMIENNICTWO

1. Aczel D.A.: *Statystyka w zarządzaniu*. Wydawnictwo Naukowe PWN, Warszawa, 2000.
2. Buciński A., Bączek T., Kowalski I.M.: *Clinical data analysis with the use of artificial neural networks of treatment evaluation in adolescent idiopathic scoliosis*. Adv. Clin. Exp. Med., 2004; (13) 4: 623–629.
3. Buciński A., Kowalski I.M., Zarzycki D., Bączek T., Nasal A., Kaliszan R.: *Principal component analysis of patient variables as an objective method of treatment evaluation in adolescent idiopathic scoliosis*. Adv. Clin. Exp. Med., 2002; (11)1: 61–68.
4. Chen P.Q.: *Management of scoliosis*. J. Formos. Med. Assoc., 2003; 102 (11): 751–761.
5. Cichosz P.: *Systemy uczące się*. Wydawnictwa Naukowo-Techniczne, Warszawa, 2000.
6. Hopf C., Sandt E., Heine J.: *The progression of untreated idiopathic scoliosis in the x-ray image*. Rofo. Fortschr. Geb. Rontgenstr. Nukleardmed., 1989; 151(3): 311–316.
7. Khan K.S., Kunz R., Kleijnen J., Antes G.: *Systematic reviews to support evidence – based medicine: how to review and apply findings of healthcare research*. Royal Society of Medicine Press, London 2004.
8. Kowalski I.M., Giżewski T., Radomska-Wilczewska A., Lewandowski R.: *Model systemu samouczącego w diagnostyce rehabilitacyjno-ortopedycznej*. Post. Rehabil., 2008; (supl. 7): 43.

9. Kowalski I.M.: *Ocena doświadczalna i kliniczna elektrostymulacji mięśni jako terapii wspomagającej w leczeniu niskostopniowej skoliozy idiopatycznej*. Praca habilitacyjna. Uniwersytet Jagielloński, Kraków, 2007.
10. Kowalski I.M., Zarzycki D.: *Postępy w leczeniu zachowawczym skoliozy idiopatycznej metodą elektrostymulacji*. Post. Rehabil. 2002; 16(3): 33–34.
11. Ossowski S.: *Sieci Neuronowe do przetwarzania informacji*. Oficyna Wydawnicza Politechniki Warszawskiej. Warszawa, 2000.
12. Weinstein S.L., Dolan L.A., Spratt K.F., Peterson K.K., Spoonamore M.J., Ponseti I.V.: *Health and function of patients with untreated idiopathic scoliosis: A 50-year natural history study*. JAMA., 2003; 289: 559–567.
13. Weiss H.R., Negrin S., Rigo M., Kotwicki T., Hawes M.C., Grives T.B., Maruyama T., Landauer F.: *Indications for conservative management of scoliosis (guidelines)*. Scoliosis, 2006: 1–5.