ZESZYTY NAUKOWE POLITECHNIKI ŚLĄSKIEJ 1995
Seria: ELEKTRONIKA z. 4 Nr kol. 1269

Leszek MARKIEWICZ
Witold SZAFARCZYK

Instytut Elektroniki
Politechnika Śląska

PRÓBA ADAPTACJI SIECI NEURONOWYCH DO DETEKCJI MOMENTU OWULACJI

Streszczenie. Praca jest sprawdzeniem możliwości przetwarzania przez sieć neuronową sygnałów biologicznych, pojawiających się podczas cyklu płciowego kobiety. Przedstawiono analizę możliwości wykorzystania sieci neuronowej do wyznaczenia momentu owulacji. Przeanalizowano różne struktury sieci i ich zachowanie podczas procesu uczenia się i rozpoznania na danych doświadczalnych.

SOME REMARKS CONCERNING APPLICATION OF NEURAL NETWORK MODEL FOR DETERMINATION OF OVULATION

Summary. In the paper a possibility of neural network processing of biological signals which occur during female sexual period was tested. An analysis of possiblilities of neural network application in ovulation moment determination was presented. Different network structures were observed and tested while learning process and during experimental data recognition.

DIE PROBE DER ADAPTATION FÜR DIE NEURONALNETZAUSBENDUNG ZU DER OVULATIONSBESTIMMUNG

Zusammenfassung. In diesen Artikel sind überprüft die Neuronalsnetzverarbeitungsmöglichkeiten für diese biologischen Singele, welche in der Frauensperiode erscheinen. Es ist analysiert die Möglichkeit für die Neuronalnetzausbentung zu der Bestimmung die Ovulationsmoment. Es sind asugewertet verschiedene Netzstrukturen und ihres Bewahrenin dem Vorgang des Lernenablauf und werend der Erkennung der empirischen Daten.

1. Wstęp

Wyznaczenie momentu owulacji jest niezbędne przy planowaniu rodziny. Zarówno w przypadku antykoncepcji, jak i przy trudnościach w zajściu w ciążę. Ocenia się, że ten ostatni przypadek dotyczy w mniejszym lub większym stopniu około 20% wszystkich małżeństw. Wyznaczenie momentu owulacji jest również konieczne przy sztucznym zapłodnieniu "in vitro".

Jest wiele metod pozwalających wyznaczyć moment owulacji np. USG, biopsja, laparoskopia, pomiar stężenia hormonów itd. Jedne z nich są dokładne, lecz wymagają kosztownej aparatury. Inne, tańsze, są z kolei zawodne, gdyż charakteryzują się małym stosunkiem sygnał-szum.

Połączenie kilku metod pomiarowych pozwala na minimalizację wpływu zakłóceń. Budowa algorytmu pozwalającego wyznaczyć moment owulacji na podstawie kilku symptomów jest zagadnieniem złożonym z uwagi na dużą zmienność parametrów sygnałowych. Należy stosować algorytmy detektorów adaptacyjnych. Jednym z rozwiązań jest zastosowanie sieci neuronowych.

2. Opis sygnałów wybranych do detekcji

Wszystkie zmiany, jakie wywołują w narządach obwodowych estrogeny i progesteron, mogą być wykorzystane do detekcji momentu owulacji. Pewne zjawiska i odczucia poprzedzają wystąpienie owulacji i związane są z obecnością estrogenów, inne związane z progesteronem pojawiają się po owulacji [1, 7].

Do badań nad wykorzystaniem sieci neuronowej przyjęto zestaw danych dostępnych do samoobserwacji zaproponowany przez "Natural Family Planning Centre" [2]. Zawiera on następujące dane:

- Dane statystyczne potrzebne przy określeniu dni płodnych w metodzie kalendarzykowej:
  Najdłuższy cykl w ostatnich 6-2 miesiącach,
  Najkrótszy cykl w ostatnich 6-2 miesiącach.
- Dane dotyczące podstawowej temperatury ciała w trakcie całego cyklu.
- Dane dotyczące śluzu zawierają:
  Odczucie - kobieta określa ilość śluzu podając odczucie w formie słownej, np. sucho, wilgotno.
  Wygląd - określany jest na podstawie badania organoleptycznego, np. mętny, przeźroczysty, rozciągliwy.
- Dane charakteryzujące stan szyjki uzyskiwane są na podstawie samobadania. Określana jest:
  Pozycja szyjki - wysoka czy niska.
  Rozwarcie ujścia zewnętrznego szyjki.
  Twardość.

- Odczucia związane z cyklem płciowym.
  Ból owulacyjny - nie zawsze wyczuwalny może być mylony z innymi dolegliwościami.
  Napięcie w piersiach - pojawia się u niektórych kobiet jako reakcja na progesteron.
- Cechy te mogą być obarczone dużym błędem, zwłaszcza gdy badania dokonuje sama pacjentka. Jedyną obiektywną cechą uzyskiwaną podczas codziennych badań jest podstawowa temperatura ciała. Wpływa na nią jednak bardzo wiele czynników - stany zapalne w organizmie, długość i sposób pomiaru, tryb życia, osobnicza reakcja układu regulacji temperatury na obecność hormonów płciowych.

W rezultacie otrzymujemy małoliczne, obarczone błędami subiektywnymi, zaszumione dane. W dodatku dla każdej kobiety stopień nasilenia objawów oraz zależność czasowa między momentem owulacji a wystąpieniem reakcji narządów obwodowych jest cechą indywidualną.

Próby budowania wzorca - normy kliniczno-diagnostycznej na podstawie uśrednionych danych prowadzą do utraty pewnych istotnych cech pomocnych w wyznaczaniu dnia owulacji. Skąpość danych, zakłócenia oraz losowość zjawiska owulacji w pewnym obszarze czasowym cyklu wymagają stosowania odpowiednich metod ich obróbki.

Proces przetwarzania informacji musi uwzględnić: wybór cech niosących największą ilość informacji, sposób filtracji danych, sposób posługiwania się większą liczbą mało wiarygodnych danych, budowę klasyfikatora, a w szczególności możliwość jego adaptacji do indywidualnych cech przebiegu.

3. Wykorzystanie sieci neuronowych

Modele sieci neuronowych utworzone z wielu nieliniowych elementów przetwarzających, wzorowanych na biologicznych neuronach mogą realizować funkcje klasyfikatora. Klasyfikator taki przystosowywuje się do przetwarzanych danych, tworząc bardziej generalne rejony decyzyjne. Modele sieci realizując klasyfikację bardzo przypominają klasyfikator semantyczny, gdzie funkcje mają charakter nieliniowy. Uznając zalety sieci neuropodobnych podjęto próbę zastosowania ich do określania momentu owulacji [3].

Klasyfikator oparty na sieci neuronowej zaproponowany do rozwiązania postawionego problemu posiadał od 24 do 50 neuronów w warstwach ukrytych. Stosowano sieci jedno- i dwuwarstwowe. Zastosowano model neuronów z sigmoidalną funkcją wyjścia, uczonych uogólnioną regułą delta, obejmującą progi neuronów (Bias).

Do prób wzięto dane jednej pacjentki zebrane w przeciągu roku. Dane były gromadzone na kartach "Natural Family Planning Centre". Następnie zostały przeanalizowane przez lekarza, który "ex post" określił dla każdego cyklu dzień owulacji. Wskazane przez lekarza dnie przyjęto za rzeczywisty dzień owulacji. Otrzymano w ten sposób przebieg zmian obserwowanych parametrów u zdrowej, prawidłowo miesiączkującej kobiety wraz z określonym dniem owulacji.

Dla uogólnienia sposobu postępowania dane z karty zostały wprowadzone do bazy danych zbudowanej w języku dBase. Umożliwiło to przeprowadzenie analizy statystycznej otrzymanych wyników. Analizę tę przeprowadzono przy użyciu programu Statgraph oraz prostą możliwość przesuwania ciągów danych dla ich "scentrowania" ze względu na dzień owulacji. Ułatwiło to również przeprowadzenie zmian przypisania liczb odpowiednim zmiennym lingwistycznym, takim jak odczucia, wygląd itp.

Wszystkie sygnały wejściowe przed podaniem na sieć zostały znormalizowane do zakresu 0-1. Zapewniło to porównanie wyników przy stosowaniu zbiorów uczących z różnymi zestawami danych. Na podstawie tych danych stworzono zbiory uczące sieć neuronową. Zbiory te posiadały informację o dniu cyklu oraz temperaturze, odczuciu śluzu, rozwarciu szyjki z trzech dni wstecz. W ten sposób uwzględniono trend zmian wybranych parametrów. Wynikiem klasyfikacji było określenie:

- fazy cyklu, odpowiedzi PRZED i PO,
- dnia owulacji, odpowiedź DZISIAJ,
- potwierdzenia owulacji, odpowiedź WCZORAJ,
- zbliżania się owulacji, odpowiedź JUTRO.

Odpowiadało to pięciu wyjściom sieci. Zaproponowany podział nawiązywał do przyjętych odpowiedzi detektorów konstruowanych w innych pracach [4, 6]. Założono dwie metody budowy zbiorów uczących:

a. Sieć adaptuje się do danych z trzech kolejnych miesięcy w celu dokonania diagnozy w następnym miesiącu.
b. Budowany jest wzorzec

Zweryfikowanymi danymi (wyeliminowano rekordy z zakłóceniami) uczono sieć z jedną warstwą neuronów ukrytych i 40 neuronami w tej warstwie. Liczba neuronów ukrytych wynosiła więc około 50% liczby rekorów w zbiorze uczącym.

Brak oscylacji sumarycznego błędu liczonego po całym zbiorze, a więc efektywne uczenie, osiągnięto dla współczynnika uczenia (LRate) z zakresu 0.1-0.05. Przy korzystaniu ze zbiorów zawierających dane z trzech kolejnych miesięcy udało się nauczyć 100% przypadków. Proces uczenia prowadzono do momentu, gdy błąd maksymalny ustabilizował się. Błąd liczono jako:

$$\delta = \sqrt{\frac{1}{n}\sum_{j=1}^{n}\left(t_j - o_j\right)^2},$$

gdzie:

n - liczba neuronów wyjściowych,

t_j - cel uczenia j-tego wyjścia,

o_j - odpowiedź sieci na j-tym wyjściu.

Aby zachować porównanie, sumaryczny błąd liczony po całym zbiorze uczącym zdefiniowano jako:

$$\Delta = \sqrt{\frac{1}{k}\sum_{l=1}^{k}\delta_l^2},$$

gdzie:

k - liczba obrazów w zbiorze uczącym,

δ_l - błąd obliczony dla i-tego obrazu.

Wykonano także zbiory uczące o tej samej strukturze, ale z danymi uśrednionymi z całego roku. Zbiór AV1516.DBF zawierał dane uśrednione oddzielnie dla miesięcy, w których dzień owulacji przypadał w 11 oraz 12 dniu cyklu.

Wyeliminowano dane z pozostałych miesięcy. Zbiór GLOBAV.DBF zawierał uśrednione dane ze wszystkich miesięcy, ale przed uśrednieniem przebiegi zostały zcentrowane tak, aby dzień owulacji przypadał zawsze 12 dnia cyklu (wartość oczekiwana wystąpienia owulacji).

4. Wniki eksperymentów

Wyniki testowania otrzymanych detektorów zawarto w tabeli 1.

Tabela 1

Zestawienie procentowej liczby poprawnych diagnoz dla różnych metod konstrukcji zbiorów uczących

Diagnoza	Zbiory z 3 miesięcy Tcxxyy.MTX (a)	Zbiór uśredniony GLOBAV32.MTX (b)	Zbiór uśredniony AV1516.MTX (a)
PRZED	87%	88%	83%
JUTRO	16.5%	18%	36%
DZISIAJ	33%	64%	27%
WCZORAJ	66%	73%	91%
PO	89%	91%	94%
OGÓŁEM	81%	85%	84%

Otrzymane rezultaty świadczą na korzyść metody uśredniania. Jednak testy prowadzone na danych z całego roku pokazały, że zebrane rzetelnie dane z trzech miesięcy przy typowym przebiegu cyklu mogą przyczynić się do powstania dobrego klasyfikatora (tabela 2). Wyraźnie widać, że uśrednianie powoduje utratę istotnych cech pomocnych przy detekcji dnia owulacji.

Tabela 2

Zestawienie procentowej liczby poprawnych diagnoz dla zbiorów z trzech miesięcy testowanych danymi z całego roku

Miesiące	Procent poprawnych diagnoz				
	PRZED	JUTRO	DZISIAJ	WCZORAJ	PO
1, 2, 3	97%	27%	55%	73%	60%
2, 3, 4	90%	0 %	9%	45%	90%
3, 4, 5	86%	36%	36%	45%	91%
4, 5, 6	81%	36%	55%	36%	100%
5, 6, 7	81%	36%	64%	82%	97%
6, 7, 8	83%	27%	45%	45%	99%
7, 8, 9	86%	27%	27%	82%	96%
8, 9, 10	91%	27%	82%	91%	91%
9, 10, 11	86%	27%	45%	64%	92%

Obserwacje z przeprowadzonego eksperymentu pozwalają wyciągnąć wniosek, że sieć nauczona wynikami uśrednionymi jest mało skuteczna w przypadku danych znacznie odbiegających od średnich. Natomiast uczona danymi nietypowymi zachowuje się jak niepewnie dla danych typowych, zgodnych z danymi wynikającymi z uśrednienia. Zachowuje się jak ekspert wykrywający bardzo skomplikowane przypadki, a mający trudności przy diagnozie prostych schorzeń.

W celu porównania skuteczności klasyfikacji przez sieci z jedną i dwoma warstwami ukrytymi przeprowadzono nastepujący eksperyment. Nauczono dwie struktury w podobnych warunkach jednakowymi danymi. Wybrano zbiór uczący GLOBAV.DBF zawierający uśrednione dane. Struktura jednowarstwowa miała 32 neurony, a dwuwarstwowa 20 i 10, czyli w sumie 30.

Proces uczenia prowadzono dla każdej ze struktur 2000 cykli. Następnie przeprowadzono testy klasyfikacji na danych z całego roku. Wyniki zawarte są w tabeli 3.

Tabela 3

Zestawienie poprawnej liczby diagnoz dla sieci z jedną i dwoma warstwami ukrytymi

Diagnoza	Dwie warstwy	Jedna warstwa
PRZED	89%	88%
JUTRO	18%	18%
DZISIAJ	18%	64%
WCZORAJ	65%	73%
PO	91%	91%

Sieć z dwoma warstwami neuronów ukrytych jest bardziej selektywna podczas klasyfikacji, więc występowało więcej przypadków nierozpoznanych wokół dnia owulacji. Szczególnie pojawiało się to podczas przetwarzania danych z miesięcy, w których dzień owulacji odbiegał od przeciętnej. Struktura jednowarstwowa prowadzi do powstania bardziej rozmytych obszarów decyzyjnych i potrafi klasyfikować zakłócone dane kosztem precyzji.

5. Wnioski końcowe

Dużym mankamentem symulacji sieci neuronowych za pomocą komputera jest czas, jaki jest potrzebny do nauczenia klasyfikatora. Rozwój technologii, opracowanie efektywniejszych algorytmów uczenia, a przede wszystkim zaimplementowanie sieci w strukturach VLSI i równoległy sposób przetwarzania z pewnością rozwiążą ten problem.

Jednak założenia postawione na wstępie, a więc budowa detektora, który by się możliwie najlepiej przystosowywał do indywidualnych cech przebiegu, pracował w trybie "on line", był odporny na niewielkie błędy podczas oceny parametrów i uwzględniał ich fizjologiczne wahania, zostały spełnione. Zdecydowanie najgorzej wyglądała detekcja JUTRO (predykcja dnia owulacji). Odnotowano od 0% do 36% poprawnych diagnoz. Należy jednak pamiętać, że nawet lekarz dysponując tymi samymi danymi co klasyfikator nie potrafi w sposób pewniejszy przewidzieć wystąpienie owulacji. W tym przypadku wyniki eksperymentu zgodne są z danymi doświadczalnymi zawartymi zarówno we współczynniku Pearla, jak i ocenie ekspertów analizujących skuteczność poszczególnych metod [4, 5].

Literatura

[1] W. Fijalkowski: Naturalny rytm płodności. PZWL, Warszawa 1976,
[2] A.M. Flynn: Birningham Maternity Hospital, wyd. Maj 1989.
[3] Lippmann: An introduction to computing with neural nets. IEEE ASSP MAGAZINE April 1987.
[4] L. Markiewicz: Some algorithms of determination of ovulation. Biosignal. Brno 1990.
[5] L. Markiewicz i inni: An example of Building the Alghorithms Used for Making Diagnosis in medicine. Wiedeń 1991.
[6] Prace dyplomowe prowadzone w latach 1989-1991 w Zakładzie Elektroniki Biomedycznej Instytutu Elektroniki Politechniki Śląskiej pod kierunkiem L. Markiewicza.
[7] P. Skałba, M. Rozmus: Endokrynologia ginekologiczna - skrypt dla studentów i lekarzy specjalizujących się w położnictwie i ginekologii. Wydawnictwo ŚlAM, Katowice 1984.

Recenzent: Prof. dr hab. Marek **KURZYŃSKI**

Wpłynęło do Redakcji: 22.02.1994 r.

Abstract

A determination of an ovulation moment is an intricate problem. Difficulties are caused by a high noise level as well as by the fact that some signals are of linguistic nature. Standard noise filtering algorithms and patterns of detection are inappropriate because of permanent change of the signal morphology resulted from great environmental and time influence on a woman's organism. Therefore detectors which are constructed should have a feature of annual and long-term parameters adaptation.

A detector based on neural networks which "learn" from one period to another are proposed.

A set of typical data recommended by "Natural Family Planning Centre" was used as aresearch material. The real data were gathered in dBase standard and were normalized in such a way that all them, including linguistic (modeled by membership function), were contained in the interval from 0 to 1. New collections of learning data sets were constructed on the data. The new sets were obtained eiher by finding an average of signals of several varied periods or by excluding data of periods considerably different from the average as well as an ovulation day signal center.

Five outputs, two and one layer neural networks were used for detector's construction. The goal of the network classification was to number a signal's phase into the one of 5 following groups: before ovulation, tomorrow ovulation, today, yesterday and after ovulation.

The results of the experiment show influence of a network structure and learing data sets choice on the quality of classification.

As it appears from the study, from the point of view of minimalization of an error, the network learning process should last about 2000 periods, which takes a long time and involves use of a high frequency clock equipment. An application of dedicated elements in which networks were implemented in VLSI structures may soften this demand. The two-layer network is better for women for little period variability. Single layer network is to be used with great dispersions of a period duration. A stability of period also influences a learning data choice.

The results of the study show that neural networks can be applied to an ovulation moment determination, particularly because of adaptavity of networks during a learning process.