

Artur SUKIENNIK*, Piotr KRUCZEK*, Jacek J. PIETRZYK*, Wiesław WAJS*,
Ryszard TADEUSIEWICZ*, Tadeusz PISARKIEWICZ*

AKADEMIA GÓRNICZO-HUTNICZA

Zastosowanie ciągłego pomiaru saturacji hemoglobiny tlenem w prognozowaniu przez sieć neuronową parametrów gazometrii krwi tętniczej

Streszczenie

W oparciu o bazę danych funkcjonującą od kilku lat w Oddziale Intensywnej Terapii Noworodka Polsko-Amerykańskiego Instytutu Pediatrii Collegium Medicum UJ w Krakowie stworzono sieć neuronową, której zadaniem jest prognozowanie parametrów gazometrii krwi tętniczej (pH, pCO₂, pO₂, HCO₃). Sieć przewidywała w oparciu o dostarczone dane wejściowe - uprzednie wartości gazometrii oraz nastawy respiratora i fakt podania surfaktantu. Sieć działając z krokiem 1,5 godz. prognozowała wartości gazometrii z błędem znacznie niższym niż przyjęty błąd maksymalny. Zastosowanie w praktyce tego typu systemu wymaga wydłużenia kroku działania sieci. W tym celu postanowiono wykorzystać ciągły pomiar saturacji hemoglobiny tlenem, którą to wartość wykorzystano jako kolejny parametr wejścia dla sieci neuronowej.

Pomiary przeprowadzone u kilku pacjentów posłużyły do uczenia sieci neuronowej. Dokładność uzyskiwanych prognoz sprawdzono na podstawie analizy danych pochodzących od dwóch pacjentów. Uzyskano satysfakcjonującą dokładność prognoz przy wydłużonym kroku.

Abstract

A neural network forecasting arterial blood gases values (pH, pCO₂, pO₂, HCO₃) was created based on Neonatal Information System working in Neonatal Intensive Care Unit, Polish-American Children's Hospital in Cracow. The network forecasted based on input parameters - previous blood gases values, respiratory settings and surfactant administration. The network worked with a step equal to 1,5 hours and forecasted blood gases values with an error well below maximal acceptable error. Practical application of this system requires elongation of the neural network step. To achieve this goal we used continuously monitored values of hemoglobin oxygen saturation as another input parameter.

Measurements performed in few cases were used to teach neural network. We checked accuracy of prognosis analyzing data from two patients. We achieved prognoses with good accuracy with prolonged step.

WPROWADZENIE

W Oddziale Intensywnej Terapii Noworodka Polsko-Amerykańskiego Instytutu Pediatrii Collegium Medicum Uniwersytetu Jagiellońskiego w Krakowie od wielu lat funkcjonuje komputerowa baza danych - Neonatal Information System (NIS), w której gromadzone są wszystkie dane hospitalizowanych dzieci. Aktualnie w bazie zgromadzone są informacje dotyczące ponad ośmiuset pacjentów.

U większości przyjmowanych do Oddziału noworodków występują zaburzenia oddychania. Stanowią one nie tylko wiodącą przyczynę hospitalizacji, ale także istotną przyczynę zgonów. Stopień nasilenia zaburzeń oddychania najlepiej wyraża gazometria krwi tętniczej, którą należy analizować w kontekście aktualnych nastawów respiratora (RR - częstość oddechów, FiO₂ - stężenie tlenu w mieszaninie oddechowej, PIP - ciśnienie szczytowe wdechu). Prognozowanie wartości gazometrii krwi tętniczej (pH, pO₂, pCO₂, HCO₃) byłoby bardzo przydatne w leczeniu dzieci z zaburzeniami oddychania, szczególnie w przypadku, gdy wartość prognozy byłaby zależna od działań leczniczych (nastawy respiratora, podanie leku, np. surfaktantu - czynnika obniżającego napięcie powierzchniowe w pęcherzykach płucnych).

Wartości gazometrii krwi tętniczej zależą od wielu czynników. Sieć neuronowa pozwala na modelowanie przebiegu różnych parametrów bez potrzeby analizy czynników wpływających na nie [1, 2, 3]. Czynniki te mogą mieć charakter: stały (urodzeniowa masa ciała, wiek płodowy, punktacja w skali Apgar, pęć), skokowy (nastawy respiratora, podawanie leków, obecność za-

* Mgr Artur SUKIENNIK

W 1990 r. ukończył studia na Wydziale Matematyki i Fizyki w zakresie Informatyki ze specjalnością: Oprogramowanie i Metody Informatyki na Uniwersytecie Jagiellońskim. W 1998 r. rozpoczął pracę nad wykorzystaniem sieci neuronowych jako narzędzia wspomagającego proces leczenia pacjentów ze szczególnym uwzględnieniem zagadnień prognozy wartości parametrów gazometrii krwi. Prace prowadzone są w Katedrze Automatyki AGH.

* Lek. med. Piotr KRUCZEK

W 1991 r. ukończył studia na Wydziale Lekarskim Akademii Medycznej w Krakowie. Od 1991 r. pracuje w I Klinice Chorób Dzieci Polsko-Amerykańskiego Instytutu Pediatrii Wydziału Lekarskiego Uniwersytetu Jagiellońskiego. W 1996 r. zdał egzamin specjalizacyjny I stopnia z pediatrii. Od 1998 r. rozpoczął współpracę nad zagadnieniami sieci neuronowych wykorzystywanych w procesie prognozy wartości parametrów gazometrii krwi.

* Prof. dr hab. Jacek J. PIETRZYK

Kierownik Katedry Pediatrii i Kliniki Chorób Dzieci Polsko-Amerykańskiego Instytutu Pediatrii CM. W swoim dorobku posiada ponad 300 prac naukowych. Prowadzi intensywną współpracę z ośrodkami zagranicznymi (National Institute of Child Health and Human Development, National Institutes of Health, Yale University, University of Wisconsin, CHOP University of Pennsylvania, Boston Children's Hospital Harvard University, Institute for Basic Research and Developmental Disabilities, Staten Island). Główny wykonawca Programów naukowych: 3 polsko-amerykańskie programy (NIH) funduszu M.Skłodowskiej-Curie, 4 programy finansowane przez KBN, 2 programy z INSERM (Paryż), 4 programy finansowane przez PAN i Ministerstwo Zdrowia. Członek Towarzystw Naukowych: Polskie Towarzystwo: Pediatryczne,

Endokrynologiczne, Immunologiczne, Komitet Rozwoju Człowieka PAN; zagranicznych: European Society for Pediatric Research (ESPR); Członek Rady Naukowej ESPR (1984-1990), Prezydent ESPR (1989).

* Dr hab. inż. Wiesław WAJS

Dr hab. inż. Wiesław Wajs profesor w AGH pracuje w Katedrze Automatyki od 1969 roku. opublikował ponad 100 prac naukowych, w tym 23 pozycje to skrypty uczelniane i książki. Kieruje pracą Laboratorium Systemów Sterowania Rozproszonych oraz Laboratorium Informatyki Medycznej w Katedrze Automatyki. Jest kierownikiem Studium Podyplomowego „Automatyka Elektroniczna”, a także Studium Podyplomowego „Systemy Sterowania Rozproszonych” w AGH w Krakowie.

* Prof. dr hab. inż. Ryszard TADEUSIEWICZ

Studiował na Wydziale Elektrycznym Akademii Górniczo-Hutniczej, który ukończył z wyróżnieniem w 1971 r. Już po uzyskaniu stopnia naukowego z automatyki studiował na Wydziale Lekarskim Akademii Medycznej w Krakowie oraz przeszedł gruntowne studia w dziedzinie metod matematycznych i informatycznych stosowanych w ekonomii. W 1991 r. otrzymał stopień profesora zwyczajnego nauk technicznych. Napisał i opublikował ponad 400 prac naukowych, a także kilkadziesiąt artykułów oraz kilka książek popularnonaukowych. Jest członkiem wielu polskich i międzynarodowych towarzystw naukowych, współzałożycielem Polskiego Towarzystwa Informatycznego. W 1990 r. został wybrany na członka Komitetu Badań Naukowych, gdzie m.in. zajmuje się opiniowaniem kandydatów do prestiżowej Nagrody Fundacji na rzecz Nauki Polskiej. W 1998 r. został członkiem korespondentem PAU, a w lutym tego roku międzynarodowe gremium naukowe nadało mu tytuł „Euroinżyniera”. Od 1998 rektor Akademii Górniczo-Hutniczej.

każenia) i ciągi, monitorowane przez urządzenia zewnętrzne (czynność serca, saturacja hemoglobiny tlenem, ciśnienie tętnicze krwi oraz parametry mechaniki oddychania - objętość oddechow, podatność płuc, opór w drogach oddechowych).

Ogólna koncepcja funkcjonowania sieci neuronowej w prognozowaniu wartości parametrów istotnych w procesie leczenia pacjenta przedstawia się następująco.

- Sieć w czasie rzeczywistym pobiera wartości parametrów wejścia z urządzeń zewnętrznych:
 - komputerowej bazy danych,
 - komputerów laboratoriów analitycznych,
 - urządzeń monitorujących stan pacjenta.
- Parametry te służą do uczenia sieci.
- Sieć na żądanie użytkownika generuje prognozę wartości gazometrii krwi tętnicznej. Prognoza ta powinna cechować się odpowiednią dokładnością.

W pierwszym etapie naszej pracy opracowaliśmy budowę sieci neuronowej, sposób przetwarzania i wprowadzania do sieci danych o charakterze skokowym. Drugi etap będącym przedmiotem tej pracy polega na opracowaniu sposobu przetwarzania i wprowadzania do sieci danych o charakterze ciągłym. Saturacja hemoglobiny tlenem najlepiej spośród parametrów monitorowanych w sposób ciągły koreluje z wartościami gazometrii krwi tętnicznej, dlatego sposób wykorzystania tego parametru przez sieć neuronową opracowano w pierwszej kolejności.

SYSTEM WSPOMAGAJĄCY PODEJMOWANIE DECYZJI W TRAKCIE PROCESU LECZENIA PACJENTA

Jak już wspomniano system będzie koncentrował się na wspomaganie decyzyjnym w schorzeniach oddechowych pacjentów, a co za tym idzie będzie analizował kilkanaście parametrów związanych z gazometrią krwi. Działanie systemu będzie polegało na prognozie wartości gazometrii krwi dysponując ich aktualnym odczytem wartości oraz stanem parametrów opisujących zastosowane metody leczenia. Poprawna prognoza w znacznym stopniu umożliwi podjęcie decyzji o metodach dalszej terapii.

Dane wykorzystywane przez system

Dane pozyskiwane dla systemu można podzielić na dwie grupy: pierwszą stanowią ciągi wartości parametrów gazometrii krwi, otrzymane ze szpitalnej bazy danych w oparciu o dotychczasową obserwację pacjentów, drugą tworzą wartości parametrów będących odwzorowaniem ustawień aparatury medycznej lub reprezentacją faktu zastosowania odpowiednich leków. Pierwsza grupa danych będzie reprezentowana przez następujące parametry: pH parametr ogólnego stanu zdrowia pacjenta, pCO_2 parametr wymiany gazowej w płucach, pO_2 parametr wymiany tlenowej w płucach oraz HCO_3 wskaźnik metabolizmu tkanek. W drugiej grupie danych oprócz wartości parametrów uwzględnionych w opisanym doświadczeniu „Surfactant”, RR, FiO_2 , PIP wartości tych parametrów również zostaną pobrane ze szpitalnej bazy danych) znajdują się również rejestrowane ciągle w czasie rzeczywistym wartości parametrów związanych z urządzeniami monitorującymi lub respiratorami i będą to następujące wskaźniki:

- parametry mechaniki oddychania (objętość oddechow, podatność płuc, opór w drogach oddechowych) pobrane z urządzenia „BEAR graphic display”,
- odczyt tętna i saturacji krwi pobrane z pulsoksymetru „Novamatrix 500”,

- pozostałe parametry takie jak EKG (czynność serca), ciśnienie tętnicze inwazyjne rejestrowane przy użyciu takich urządzeń jak „CRITICON Dinamap TM Plus” lub „HP CMS 24 Omni Care – Neonatal”.

Projekt struktury systemu

Cały system podzielony będzie na kilka modułów realizujących niezależne funkcje. Niektóre z tych modułów będą pracowały w czasie rzeczywistym, pobierając dane dla systemu. Inne będą dokonywały obróbki pozyskanych danych na życzenie operatora systemu lub z uwzględnieniem zadanych odstępów czasowych (rys. 1).

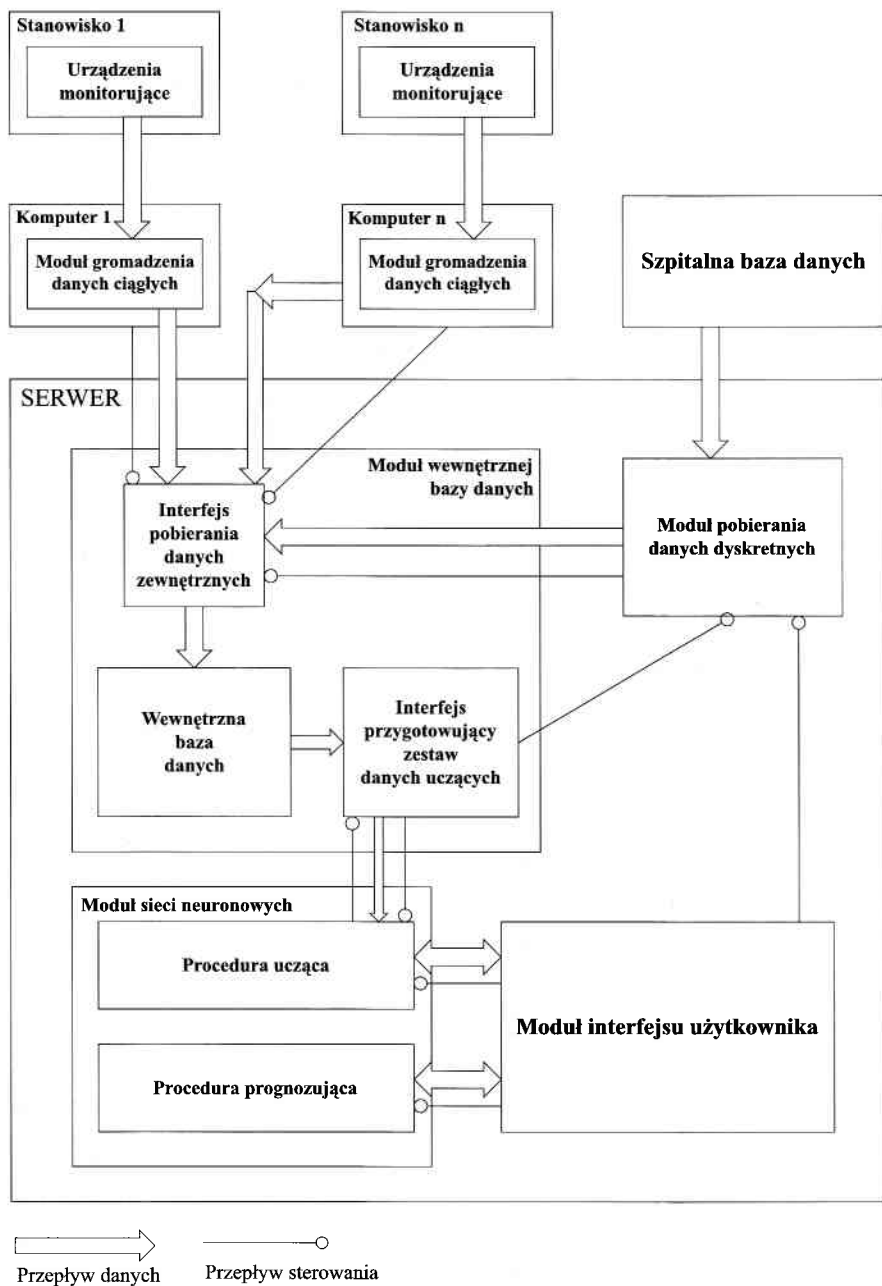
Moduł przygotowywania danych ciągłych

W związku z tym, że każdy pacjent, którego dane medyczne będą uwzględnione w systemie, posiada własne urządzenia monitorujące, moduł przygotowywania danych ciągłych będzie się składał z kilku lub kilkunastu (w zależności od liczby pacjentów) instancji programu zajmującego się pobieraniem danych od każdego z pacjentów. Każdy z tych programów będzie zainstalowany na osobnych komputerach, do których będą podłączone urządzenia monitorujące. Algorytm działania takiego programu, w dużym przybliżeniu, będzie wyglądał następująco:

- wartości odczytane z urządzeń zewnętrznych, z częstotliwością 1 s, będą za pośrednictwem złączeń RS 232 przekazywane do komputera,
- w dalszej kolejności mechanizm podwójnego buforowania (w pierwszym buforze pamięci gromadzone są dane, po jego wypełnieniu informacja kopiowana jest do drugiego bufora, w tym samym czasie pierwszy bufor jest czyszczony i przygotowywany do przyjęcia kolejnych porcji informacji natomiast informacja zawarta w drugim buforze może zostać przetworzona) zapewni płynne przetwarzanie odczytanych wartości (dla potrzeb systemu przedział czasowy w trakcie, którego gromadzone będą dane w pierwszym buforze pamięci zostanie ustawiony na 10 min.), wartości każdego parametru będą rejestrowane i przetwarzane osobno, dane zgromadzone w drugim buforze pamięciowym będą poddane obróbce, która umożliwi ich dalsze wykorzystanie przez system, będzie ona polegała na aproksymacji wielomianowej zarejestrowanych wartości; taka operacja umożliwi w dalszej kolejności zapamiętanie pobranych wartości w wewnętrznej bazie danych w postaci współczynników wielomianów,
- po przetworzeniu wartości tworzony będzie rekord danych zawierający następującą informację: identyfikator pacjenta, początkowa wartość czasowego przedziału pobierania informacji (data oraz dokładny czas rozpoczęcia wypełniania pierwszego bufora pamięciowego) oraz jego długość (dla potrzeb systemu będzie ona wynosić 10 min.), stopień wielomianu, którym aproksymowano ciąg wartości oraz współczynniki wielomianów wszystkich aproksymowanych parametrów,
- tak utworzony pakiet informacji będzie w dalszej kolejności za pośrednictwem sieci komputerowej (np. system NOVVELL) przekazywany do komputera, gdzie znajduje się główna część systemu, zawierająca również wewnętrzną bazę danych; uruchamiany będzie program interfejsu, który zapamięta w bazie danych otrzymaną informację.

Moduł pobierania dyskretnych danych ze szpitalnej bazy danych

Część informacji gromadzona w trakcie pobytu pacjenta na leczeniu jest kilka razy dziennie (przeważnie raz lub dwukrotnie) rejestrowana przez personel medyczny i zapamiętywana



Rys. 1. Model systemu prognozy wartości parametrów gazometrii krwi

w szpitalnej bazie danych. Metody przetwarzania tej informacji będą podobne do metod pozyskiwania danych ciągłych. Procedura, której zadaniem będzie odzyskanie danych gazometrii krwi i ustawień respiratora dla konkretnego pacjenta, będzie posiadała następującą funkcjonalność:

- W oparciu o numer identyfikacyjny pacjenta odczytywane są dotychczas zarejestrowane wartości parametrów gazometrii krwi, parametrów ustawień respiratora oraz parametru określającego podanie leku Surfactant. Będą to te same parametry, które utworzyły zbiór danych wejściowych dla sieci neuronowej (rozdz. „prognoza dyskretnych...”). Wartości tych wskaźników będą przetwarzane tak, jak to było opisane wcześniej; dyskretne wartości parametrów gazometrii krwi będą aproksymowane wielomianowo i otrzymane współczynniki

wielomianów posłużą do zapamiętania przebiegu wartości tych parametrów; niestety wartości wskaźników ustawień respiratora nie można przedstawić posługując się funkcją, której wzór mógłby posłużyć jako element „kompresujący” informację i umożliwiający jej zapamiętanie w bazie danych. Dlatego informacja związana z tymi parametrami będzie przekopiowana ze szpitalnej bazy danych do wewnętrznej bazy systemu.

- W ostateczności utworzony będzie rekord zawierający dane o numerze identyfikacyjnym pacjenta, początkowej i końcowej dacie rejestracji wartości (początek i koniec przedziału aproksymacji), stopień wielomianu, jego współczynniki dla poszczególnych, aproksymowanych parametrów oraz dodatkowy, podrzędny rekord zawierający kolejne odczyty (datę, godzinę i wartość) ustawień respiratora i podania leku Surfactant. W takiej postaci informacja będzie zapamiętana w wewnętrznej bazie danych.

Ze względu na fakt, że informacja ta jest gromadzona z dużym stopniem dyskretyzacji (kilkanaście godzin), nie zachodzi potrzeba, aby procedury tego modułu były uruchamiane częściej niż raz na tydzień w miarę pojawiania się nowych danych. Ponieważ dane te pobierane są z zewnętrznego źródła (szpitalna baza danych), istnieje również potrzeba stworzenia interfejsu, który znając strukturę bazy danych, będzie w stanie odczytać żadaną informację. Będzie to procedura ściśle związana z opisywanym modułem, stanowiąca jego integralną część.

Moduł wewnętrznej bazy danych

Zadaniem tego modułu będzie zapamiętywanie otrzymywanych wartości w bazie danych, która będzie źródłem informacji niezbędnej do uczenia sieci neuronowych. Będzie on zawierał procedury interfejsowe umożliwiające odbiór nadchodzących danych z zewnętrznych komputerów, rejestrujących dane ciągłe oraz pobieranie informacji przygotowawczej przez moduł przetwarzania danych dyskretnych. Moduł bazy danych będzie wyposażony także w interfejs umożliwiający przygotowanie zestawu danych dla potrzeb uczenia sieci neuronowych. Powinna to być procedura uruchamiana na zlecenie modułu sieci neuronowych, a posiadająca następującą funkcjonalność:

- Przygotowanie spójnego zbioru danych zawierającego ciągłe wartości wszystkich rozpatrywanych parametrów. Spójność ma polegać na generowaniu informacji z tego samego przedziału czasowego. Ponieważ część wartości zbieranych

jest w sposób ciągły a pozostałe dane pozyskiwane są w sposób dyskretny, zachodzi obawa, że mógłby wystąpić brak aktualnych danych ze szpitalnej bazy danych. Wówczas uruchamiana będzie procedura z modułu przetwarzającego dane dyskretnie, która uaktualni wartości odpowiednich parametrów.

- Wykorzystując rekordy informacji procedura ta będzie tworzyć ciągi wartości, używając reprezentacji wielomianowej opisywanych parametrów. W celu poprawienia procesu uczenia sieci neuronowej, wszystkie wartości z tych ciągów będą znormalizowane, tak by zawierały się w przedziale wartości (0, 1).
- Jednym z parametrów przekazywanym do tej procedury będzie wartość reprezentująca krok prognozy wartości. W oparciu o tę wartość procedura utworzy zbiory danych wejściowych i wyjściowych, niezbędnych do procesu uczenia sieci neuronowej. W zbiorze danych wejściowych znajdują się wszystkie omawiane parametry. Natomiast zbiór danych wyjściowych będzie utworzony przez wartości czterech parametrów gazometrii krwi.

Moduł sieci neuronowych

Moduł ten będzie zawierał dwie procedury. Pierwszą z nich będzie funkcja tworząca i ucząca sieć neuronową. Druga, uruchamiana na zlecenie operatora, będzie odpowiedzialna za prognozowanie wartości parametrów gazometrii krwi w oparciu o dostarczone dane. Procedura ucząca po określeniu okresu, w oparciu o który dokonywane będzie uczenie sieci, wyśle zapytanie do procedury przygotowującej zbiory danych uczących, w którym określi również krok prognozy (w dotychczasowych badaniach krok ten wynosił 1.5, optymalna wartość tego parametru zależy od decyzji lekarskiej, powinna wynosić kilka lub kilkanaście dni w zależności od podjętych środków leczenia i musi być pobrana z interfejsu użytkownika). Po otrzymaniu danych przystąpi ona do uczenia sieci neuronowej. Druga procedura, w oparciu o aktualne dane z wewnętrznej bazy danych i wartości parametrów leczenia pozyskanych z interfejsu użytkownika przeprowadzi prognozę wartości parametrów gazometrii krwi, używając nauczonej wcześniej sieci neuronowej.

Przewiduje się, że sieć neuronowa tworzona i wykorzystywana w tym systemie będzie miała strukturę zbliżoną do tej, która została omówiona (rozdz. „Prognoza dyskretnych...”). Uczenie sieci nie będzie odbywać się w czasie rzeczywistym. Może ono być przeprowadzone raz w tygodniu po uaktualnieniu danych dyskretnych, lub na życzenie operatora systemu. Ze względu na fakt, że im więcej danych zawiera wewnętrzna baza danych, tym proces uczenia będzie trwał dłużej, jednym z problemów, który musi być rozstrzygnięty jest ustalenie optymalnego okresu przerwy między kolejnymi procesami uczenia, tak by proces ten nie trwał zbyt długo oraz by ilość informacji uczącej była na tyle duża, by sieć neuronowa była w stanie prognozować wartości parametrów gazometrii krwi w zadowalający sposób.

Moduł interfejsu użytkownika

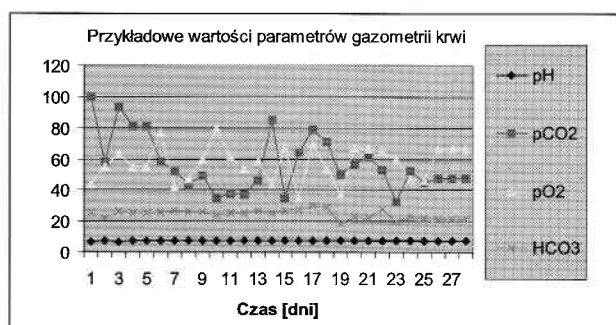

Powinien zapewniać następujące funkcje:

- sterowanie procesem pobierania danych dyskretnych ze szpitalnej bazy danych - w każdej chwili użytkownik powinien mieć możliwość uruchomienia procedury przetwarzającej te dane z ewentualnym powiadomieniem o efektywności takiego działania (dane te mogły być pobrane niedawno),
- kontrola nad funkcją uczącą sieć neuronową – od użytkownika zależy z jakim krokiem sieć neuronowa będzie prognozować wartości parametrów gazometrii krwi (czas po którym będzie widoczny efekt działania zastosowanych środków leczenia może być różny),
- uruchomienie modułu prognozującego wartości wskaźników gazometrii krwi – użytkownik powinien mieć możliwość symulacji stosowanych środków leczenia w oparciu o podawane wartości odpowiednich parametrów wejściowych (ustawienia respiratora, podawanie leku Surfactant),
- wyświetlenie prognozowanych wartości.

PROGNOZA DYSKRETNYCH WARTOŚCI PARAMETRÓW GAZOMETRII KRWI

Dotychczasowe badania przeprowadzane z wykorzystaniem algorytmów sieci neuronowych były realizowane w oparciu o informację uzyskaną ze szpitalnej bazy danych (6). W celu stworzenia sieci neuronowej przewidującej odczyty wskaźników gazometrii krwi pacjenta, posłużono się odczytami ośmiu parametrów, których wartości odwzorowywały przebieg czterech, wybranych parametrów gazometrii krwi (pH – ogólny stan zdrowia pacjenta, pCO_2 – wymiana gazowa w płucach, pO_2 – wymiana tlenu w płucach, HCO_3 – wskaźnik metabolizmu tkanek) oraz czterech parametrów opisujących zastosowane metody leczenia (Surfactant – informacja o podaniu leku „Surfactant”, RR – ilość oddechów z respiratora, FiO_2 – stężenie tlenu w mieszaninie oddechowej, PiP – ciśnienie szczytowe wdechu) (rys.2). Wartości wymienionych parametrów były pobrane ze szpitalnej bazy danych i utworzyły zbiór danych, który był przedstawiony na wejściu sieci neuronowej (pierwsza warstwa sieci neuronowej). Rejestracja wartości wspomnianych parametrów odbywała się kilka razy w ciągu dnia przez cały okres obserwacji pacjenta. Ponieważ ilość posiadanej informacji oraz jej charakter wpływały negatywnie na proces uczenia sieci, przebiegi wartości tych wskaźników poddano obróbce, w celu uzyskania lepszych wyników w trakcie nauki sieci neuronowej.

Ciągi wartości parametrów zgromadzonych w pierwszej grupie danych wejściowych (parametry gazometrii krwi) poddano aproksymacji wielomianowej (4, 5). Dzięki temu uzyskano możliwość generacji dodatkowych wartości dla tych wskaźników (częstość pobierania informacji odpowiadająca kilku pomiarom w ciągu dnia była niewystarczająca) z dowolnych kroków dys-

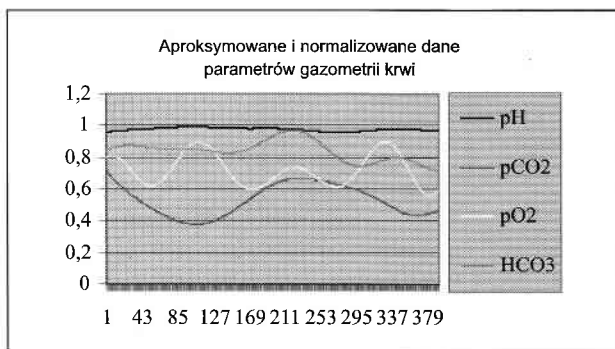


Rys. 2. Przebiegi wartości parametrów gazometrii krwi i parametrów terapii medycznej zarejestrowane w trakcie kilkudniowej obserwacji pacjenta

kretyzacji. Dzięki takiemu zabiegowi wygładzono przebiegi wartości wspomnianych parametrów. Niestety zastosowany algorytm liniowej aproksymacji spowodował pojawienie się znacznych odchyłań (wartości dążące do nieskończoności) na początku i na końcu rejestrowanego ciągu aproksymowanych wartości. W celu zachowania realnych wartości parametrów usunięto 15% informacji (z początku i końca) z uzyskanego ciągu danych. Wartości z tak uzyskanych przebiegów utworzyły ciągi danych, których wartości były pobierane z krokiem dyskretyzacji 0,05 co odpowiadało okresowi 1,5 godziny (1 odpowiadało okresowi jednego dnia).

Drugą grupę danych wejściowych tworzyły wartości wskaźników mających duży wpływ na poziom parametrów gazometrii krwi, a które były określone jako parametry zastosowanej terapii medycznej. Wartości pierwszego z nich (Surfactant) stanowiły ciąg informacji binarnej, tzn. wartość 1 odpowiadała sytuacji w której zanotowano fakt podania leku Surfactant, natomiast 0 odpowiadało sytuacji przeciwnej. Wartości pozostałych wskaźników odpowiadały ustawieniom aparatury medycznej i w związku z tym nie mogły zostać poddane aproksymacji wielomianowej. W celu uzyskania większej ilości danych (tak by ich częstotliwość wynosiła mniej więcej 1,5-godzinny) wygenerowano dodatkowe wartości tych parametrów posługując się funkcjami „schodkowymi”, które reprezentowały przebiegi wartości wskaźników odległego leczenia.

W ostateczności otrzymano osiem ciągów danych odpowiadających kolejnym parametrom wejściowym, których wartości były pobrane z częstością 1,5 godziny. W celu poprawy wyników procesu uczenia sieci neuronowej, każdy z tych ciągów poddano normalizacji, tak by każda wartość była wzięta z przedziału (0, 1). W tak ostatecznej formie dane te były przedstawione na wejściu do sieci neuronowej (rys. 3).



Rys. 3. Przykład aproksymowanych i znormalizowanych przebiegów wartości parametrów gazometrii krwi

Celem prowadzonych badań było wykazanie, że sieć neuronowa byłaby w stanie nauczyć się przewidywać wartości parametrów gazometrii krwi w następnym kroku (w pierwszej fazie badań krok ten wynosił 1,5 godziny). W związku z tym zbiór danych wyjściowych służący do nauki sieci neuronowej, zawierał ciągi wartości czterech wymienionych parametrów gazometrii krwi, których wartości były zarejestrowane z 1,5 godzinnym opóźnieniem w stosunku do danych wejściowych. Ciągi tak uzyskanej informacji, również poddano aproksymacji wielomianowej i normalizacji w ten sam sposób, jak to uczyniono z danymi wejściowymi. Otrzymano cztery zbiory znormalizowanych i aproksymowanych wartości odpowiadające czterem wskaźnikom gazometrii krwi.

Utworzono cztery sieci neuronowe, które miały generować prognozowane wartości osobno dla każdego z czterech wskaźników gazometrii krwi. Każda z tych sieci była złożona z trzech warstw. Pierwszą warstwę sieci neuronowej tworzyło

osiem nieliniowych neuronów (z tansigmoidalną funkcją przejścia) odpowiadających za rozpoznanie danych wejściowych. Druga warstwa neuronalna była również zbudowana z nieliniowych neuronów, ich liczba była dobrana arbitralnie. Trzecią, ostatnią warstwę tworzył jeden neuron liniowy, który generował prognozowaną wartość dla jednego z czterech parametrów gazometrii krwi.

Otrzymano bardzo obiecujące wyniki. Po 17 iteracjach procesu uczenia błędy uczenia (SSE – suma kwadratów błędów rozpoznawania wartości) poszczególnych sieci były następujące:

- sieć prognozująca wartość pH - SSE » 0,0019,
- sieć prognozująca wartość pCO₂ - SSE » 0,62,
- sieć prognozująca wartość pO₂ - SSE » 2,33,
- sieć prognozująca wartość HCO₃ - SSE » 0,70.

Podczas oceny uzyskanych wyników przyjęto następujące kryteria dotyczące błędów prognozy:

- dla parametru pH wartość błędu prognozy powinna mieścić się w granicach $\pm 0,1$,
- błąd prognozy parametru pCO₂ powinien mieścić się w przedziale ± 10 mmHg,
- wartość parametru pO₂ powinna być prognozowana z błędem mieszczącym się w granicach ± 10 mmHg,
- błąd prognozy wartości parametru HCO₃ powinien mieścić się w granicach ± 3 mmol/l.

Przykładowe wyniki prognoz wartości parametrów gazometrii krwi można zobaczyć na rys. 4.

(p. str. 29)









DYSKUSJA

Przedstawione wyniki uzyskane po wprowadzeniu wybranych parametrów z komputerowej bazy jako danych wejściowych do sieci neuronowej zachęciły nas do wprowadzenia na wejściu oprócz zmiennych skokowych także zmiennych ciągłych. Opracowanie sposobu wykorzystania parametrów obu typów dla uczenia sieci neuronowej otwiera możliwość wprowadzania na wejściu dowolnych parametrów. Uzyskane wyniki są na tyle zachęcające, że pokusiliśmy się o stworzenie modelu funkcjonowania systemu przewidującego wartości gazometrii krwi, działającego w oparciu o algorytmy sieci neuronowej. Jego zastosowanie wymaga jednak rozwiązania wielu problemów (np. poprawa metod aproksymacji, automatyzacja pobierania danych ciągłych). Osobnym i bardzo ważnym zagadnieniem jest ocena przydatności tego typu narzędzia pomocniczego w praktyce klinicznej.

Uzyskanie dobrych rezultatów i pozytywna ocena przydatności klinicznej otwiera możliwość zastosowania sieci neuronowej do przewidywania wartości innych parametrów istotnych w leczeniu, np. wyniku posiewu krwi i innych badań mikrobiologicznych, wystąpienia pewnych powikłań itd.

Literatura

- [1] R. TADEUSIEWICZ: Sieci Neuronowe. Akademicka Oficyna Wydawnicza RM, Warszawa 1993.
- [2] M. CAUDILL, C. BUTLER: Understanding Neural Networks: Computer Exploration, Vol1 and 2. Cambridge, MA, The MIT Press 1992.
- [3] H. DEMUTH, M. BEALE: Neural Networks Toolbox, User's Guide. The MathWorks Inc., 1994.
- [4] J. i M. JANKOWSCY: Przegląd metod i algorytmów numerycznych. WNT, Warszawa 1988.
- [5] Ā. BJÖRK, G. DAHLQUIST: Metody numeryczne. PWN, Warszawa 1983.
- [6] P. KRUCZEK, JACEK J. PIETRZYK, A. SUKIENNIK, W. WAJS: Blood gases prognosis by neural network algorithms. Problems of Evolution in Real and Virtual Systems", Kraków, December, 2-4, 1998.



Rys. 4. Wyniki prognozy wartości parametrów gazometrii krwi