

WYKORZYSTANIE SZTUCZNYCH SIECI NEURONOWYCH W PROGNOZOWANIU

THE USE OF ARTIFICIAL NEURAL NETWORKS IN FORECASTING

Konrad BAJDA, Sebastian PIRÓG

Resume

Artykuł opisuje wykorzystanie sztucznych sieci neuronowych do prognozowania, na przykładzie meczów piłki nożnej, oraz predykcji cen energii elektrycznej na rynku dnia następnego. Celem projektu jest dokonanie analizy zdolności prognostycznych wybranych sztucznych modeli neuronowych.

Abstract

The article describes the use of artificial neural networks in predicting, for example, football games, and a prediction of electricity prices on the market the next day. The aim of the project is to analyze the predictive ability of selected artificial neural models.

EXORDIUM/WSTĘP

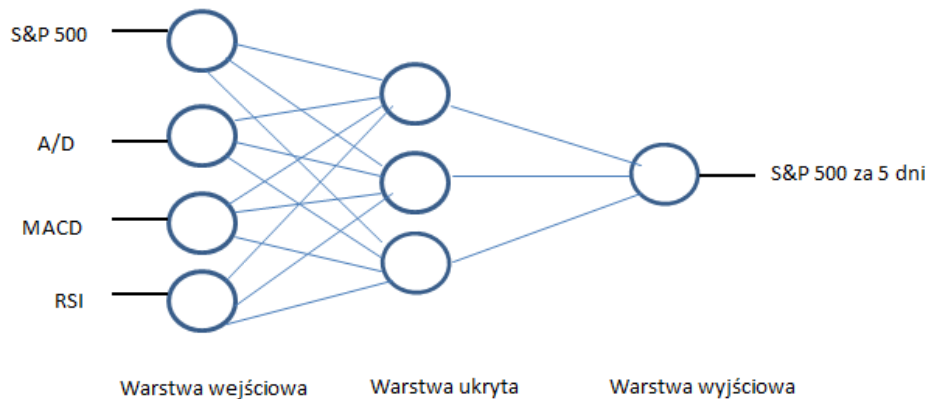
Prognozowanie (predykcja) jest niezwykle ważnym elementem, występującym w codziennym życiu człowieka. Głównym celem prognozowania jest podjęcie właściwej decyzji, lub zmniejszenie ryzyka przy dokonywanych wyborach. Niedawno do prognozowania zaczęły być używane sieci neuronowe. Są one bardzo uniwersalnym rozwiązaniem, dzięki któremu można osiągać dobre wyniki. Proces prognozowania jest procesem złożonym i wieloetapowym, co należy uwzględnić podczas projektowania neuronowego systemu predykcyjnego. Etapy te można przedstawić w sposób następujący:

- dobranie odpowiedniego problemu, dla którego będzie układana prognoza;
- gromadzenie danych, na których oparta będzie predykcja oraz ich analiza;
- przegląd metod, oraz dobranie najodpowiedniejszej metody dla wybranego problemu;
- sporządzenie modelu prognostycznego z wykorzystaniem wcześniej zgromadzonych danych;
- otrzymanie prognozy;
- ocena i porównanie prognozy z faktycznym stanem;

TEXT OF ARTICLE/TREŚĆ ARTYKUŁU

Sztuczne sieci neuronowe rozwijają się niezwykle dynamicznie co powoduje, wzrost zainteresowania tą dyscypliną naukową. Klasyczna jednokierunkowa sztuczna sieć neuronowa zbudowana jest z trzech warstw neuronów. Warstwa pierwsza nazywa się warstwą wejściową. W jej skład wchodzi tyle neuronów ile jest zmiennych wejściowych. Każdy neuron z warstwy wejściowej łączy się z wszystkimi neuronami z warstwy ukrytej.

Zdarza się, że warstw ukrytych jest więcej niż jedna – wówczas sieć składa się z więcej niż trzech warstw. Jeśli w skład obszaru ukrytego wchodzi więcej niż dwie warstwy neurony z drugiej warstwy łączą się z trzecią i tak dalej. Charakterystyczną warstwą jest ostatnia warstwa ukryta bowiem łączy się z warstwą wyjściową. Poniższy rysunek pokazuje model prostej trzywarstwowej sieci neuronowej prognozującej wartość indeksu S&P 500.



Rys.1 Trzywarstwowa sztuczna sieć neuronowa [źródło: ED Gatley, Sieci Neuronowe Prognozowanie Finansowe i Projektowanie Systemów Transakcyjnych]

Zaprezentowana wyżej sztuczna sieć neuronowa złożona jest z trzech warstw (wejściowej, ukrytej, wyjściowej). Jej zadanie to prognozowanie wartości indeksu S&P 500 na pięć dni do przodu. Wykorzystane zostały następujące dane: obecna wartość indeksu, relacja wzrostów do spadków (wskaźnik A/D), wskaźnik względnej siły RSI oraz MACD który bada zbieżność i rozbieżność średnich ruchomych. Jak widzimy każdy neuron z warstwy wejściowej łączy się z warstwą ukrytą te zaś z warstwą wyjściową. Siłę powiązań pomiędzy neuronami definiujemy jako wagi. To za ich pomocą określamy, która zmienna będzie miała największy wpływ na proces prognostyczny. Analogiczny system prognozujący został wykorzystany do predykcji wyników wydarzeń sportowych, jak i cen energii elektrycznej na towarowej giełdzie energii. Środowisko programistyczne zastosowane w tym celu to MATLAB firmy The MathWorks. Jest to program komputerowy służący do wykonywania symulacji komputerowych, obliczeń naukowych i inżynierskich. Wydajne prowadzenie obliczeń macierzowych, jak i łatwa wizualizacja wyników jest idealnym rozwiązaniem przy tworzeniu sztucznej sieci neuronowej. Podstawowym elementem przy tworzeniu sztucznej sieci neuronowej są dane wejściowe, które muszą być odpowiednio uporządkowane i zapisane w sposób reprezentatywny. Zgromadzone dane są podawane na wejściu sieci, a następnie przetwarzane, dzięki czemu uzyskujemy wyniki. Zarówno przy prognozowaniu wyników sportowych jak i w predykcji cen energii elektrycznej dane musiały być zapisane w sposób reprezentatywny.

| Wyniki drużyny gospodarzy z 5 ostatnich spotkań | | | | | | | | | | Wyniki drużyny gości z 5 ostatnich spotkań | | | | | | | | | | Ostatnie 3 pojedynki obu drużyn | | | | | |
|---|----|----|----|----|----------------------------|----|----|----|----|--|----|----|----|----|----------------------------|----|----|----|----|---------------------------------|---|--------|---|--------|---|
| z-bramki | | | | | zdobycie s-bramki stracone | | | | | z-bramki | | | | | zdobycie s-bramki stracone | | | | | meczn1 | | meczn2 | | meczn3 | |
| z1 | s1 | z2 | s2 | z3 | s3 | z4 | s4 | z5 | s5 | z1 | s1 | z2 | s2 | z3 | s3 | z4 | s4 | z5 | s5 | | | | | | |
| 1 | 0 | 3 | 1 | 0 | 0 | 6 | 0 | 2 | 2 | 1 | 1 | 1 | 2 | 1 | 1 | 1 | 0 | 2 | 0 | 1 | 0 | 0 | 0 | 2 | 1 |
| 4 | 2 | 0 | 2 | 0 | 0 | 1 | 2 | 2 | 0 | 2 | 2 | 1 | 1 | 1 | 1 | 0 | 0 | 3 | 0 | 3 | 0 | 0 | 1 | 1 | 0 |
| 5 | 5 | 0 | 4 | 0 | 1 | 2 | 3 | 3 | 0 | 1 | 1 | 1 | 1 | 0 | 1 | 0 | 3 | 0 | 0 | 2 | 0 | 1 | 1 | 1 | 1 |
| 0 | 1 | 1 | 1 | 1 | 1 | 1 | 6 | 1 | 0 | 3 | 0 | 1 | 3 | 2 | 4 | 0 | 1 | 0 | 1 | 2 | 2 | 0 | 0 | 0 | 3 |
| 3 | 2 | 4 | 0 | 1 | 2 | 0 | 1 | 2 | 1 | 1 | 2 | 2 | 0 | 0 | 0 | 1 | 0 | 0 | 1 | 2 | 1 | 2 | 2 | 2 | 3 |
| 1 | 0 | 4 | 1 | 1 | 0 | 1 | 1 | 1 | 0 | 2 | 2 | 1 | 2 | 2 | 1 | 6 | 1 | 0 | 3 | 2 | 1 | 3 | 0 | 3 | 2 |
| 0 | 3 | 1 | 2 | 3 | 2 | 0 | 0 | 0 | 2 | 5 | 5 | 2 | 1 | 0 | 1 | 1 | 1 | 3 | 0 | 1 | 1 | 0 | 1 | | |
| 0 | 0 | 2 | 0 | 0 | 0 | 3 | 2 | 0 | 0 | 1 | 0 | 2 | 1 | 2 | 2 | 1 | 0 | 2 | 2 | 3 | 0 | | | | |
| 2 | 1 | 2 | 1 | 2 | 2 | 1 | 0 | 2 | 0 | 2 | 2 | 0 | 2 | 0 | 0 | 0 | 1 | 2 | 1 | 2 | 1 | 0 | 0 | | |
| 2 | 3 | 2 | 0 | 0 | 1 | 1 | 0 | 0 | 0 | 0 | 1 | 2 | 1 | 0 | 0 | 0 | 6 | 1 | 1 | 4 | 0 | 3 | 1 | 2 | 1 |

Rys.2 Dane reprezentatywne wykorzystane do predykcji wydarzeń sportowych [źródło: www.livesports.pl]

Materiały wykorzystane w systemie prognozowania wyników meczy stanowią informacje pozyskane z serwisu internetowego www.livesports.pl. Zgromadzone dane to wyniki pięciu ostatnich meczów drużyny gospodarzy, pięciu ostatnich meczów drużyny gości oraz wyniki trzech bezpośrednich pojedynków obydwu drużyn. Wyniki pięciu ostatnich meczów drużyny świadczą o aktualnej formie drużyny, co jest bardzo ważnym elementem w prognozowaniu najbliższego meczu. Pojedynki bezpośrednie przedstawiają dotychczasowe rezultaty, jakie odnotowano w ostatnich meczach pomiędzy obiema drużynami. Zgromadzone dane będą podawane na wejście sieci.


| Data | Dzień tygodnia | Godzina | Cena | Wolumen | temperatura | zachmurzenie | wiatr |
|------------|----------------|---------|--------|---------|-------------|--------------|-------|
| 2013-01-01 | 3 | 1 | 91.65 | 824.20 | 1,6 | 6 | 15,0 |
| 2013-01-01 | 3 | 2 | 84.22 | 936.60 | 2,0 | 6 | 14,9 |
| 2013-01-01 | 3 | 3 | 78.72 | 922.00 | 2,1 | 6 | 14,3 |
| 2013-01-01 | 3 | 4 | 76.50 | 895.50 | 2,4 | 6 | 16,0 |
| 2013-01-01 | 3 | 5 | 75.63 | 1037.10 | 2,7 | 6 | 15,3 |
| 2013-01-01 | 3 | 6 | 76.49 | 989.60 | 2,6 | 5 | 16,8 |
| 2013-01-01 | 3 | 7 | 75.68 | 1033.50 | 2,8 | 6 | 14,9 |
| 2013-01-01 | 3 | 8 | 83.18 | 1176.70 | 3,1 | 6 | 13,8 |
| 2013-01-01 | 3 | 9 | 85.45 | 1069.70 | 4,0 | 6 | 16,5 |
| 2013-01-01 | 3 | 10 | 90.63 | 1063.60 | 4,3 | 6 | 17,3 |
| 2013-01-01 | 3 | 11 | 91.02 | 1108.40 | 4,5 | 6 | 16,2 |
| 2013-01-01 | 3 | 12 | 98.28 | 890.70 | 5,3 | 6 | 17,4 |
| 2013-01-01 | 3 | 13 | 99.95 | 848.60 | 5,7 | 6 | 18,6 |
| 2013-01-01 | 3 | 14 | 100.46 | 864.70 | 5,1 | 6 | 18,6 |
| 2013-01-01 | 3 | 15 | 100.10 | 867.40 | 4,4 | 6 | 16,2 |

Rys.3 Dane reprezentatywne wykorzystane do predykcji cen energii elektrycznej [źródło: www.tge.pl, www.cire.pl]

Dane do prognozowania cen energii zostały zestawione w tabelę (rys.3). Jak widać poszczególne kolumny zostały podzielone na gotowe do zaimportowania dane. Aby zmniejszyć rozmiar rekordów dane pogodowe zostały uśrednione. Średnia liczona była dla każdej godziny doby na podstawie sześciu miast aby zyskać efekt ogólnej pogody i jednocześnie zmniejszyć rozmiar danych wejściowych. Skonstruowany model miał na wejściu pięć zmiennych, natomiast na wyjściu jedną zmienną. Wszystkie te zmienne były mierzone dla każdej godziny doby handlowej. Do budowy modelu prognozującego cenę energii zastosowano perceptron wielowarstwowy MLP (Multi-Layered Perceptron). Zgromadzone dane obejmują okres od 01.01.2013 do 31.03.2013 i ich liczba to około 15000

przypadków. Proces budowy modelu opierał się na analizie danych. Zgromadzone dane zostały starannie wyselekcjonowane. Każda kolumna ma charakter reprezentatywny dla. W przypadku predykcji wyników sportowych na wejściu modelu neuronowego będzie 13 neuronów w warstwie wejściowej. Natomiast w prognozowaniu cen energii w warstwie wejściowej będzie ich 7. Ważnym aspektem prognozy na podstawie modeli neuronowych jest proces uczenia. W wyniku wielu symulacji, optymalnym zakresem danych wykorzystywanych do uczenia sieci było około 25% wszystkich zgromadzonych danych.

Aby jak najlepiej przetestować potencjał tkwiący w sztucznych sieci neuronowych postanowiono przetestować kilka rodzajów sieci neuronowych różniących się ilością neuronów oraz warstw ukrytych. Przetestowano sieć składającą się z czterech warstw ukrytych i 8 neuronów. W późniejszych etapach zwiększano stopniowo zarówno ilość neuronów jak i warstw ukrytych aby nie przeoczyć optymalnego rozwiązania. Sieć uczono metodą Levenberga-Marquardta. Algorytm Levenberga-Marquardta jest obecnie jednym z najczęściej stosowanych do uczenia sieci neuronowych jednokierunkowych, algorytmów optymalizacyjnych drugiego rzędu. Wynika to głównie z szybkiej zbieżności, oraz prostej implementacji.¹ Opiera się on na algorytmie rozwiązywania nieliniowego problemu najmniejszych kwadratów. Wartością, która była w pewien sposób ogranicznikiem czasowym uczenia sieci jest miara oczekiwanego błędu końcowego. W momencie, gdy miara ta osiągała oczekiwaną wartość wówczas uczenie sieci było kończone. Początkowo ustawiano go na wartość 0,1 lecz szybko zwiększono do 0.3 gdyż najlepiej warunkuje na proces uczenia.



Rys.4 Model sztucznej sieci neuronowej wraz z przebiegiem uczenia i parametrami [źródło: Bajda K, Piróg S Wykorzystanie sztucznych sieci neuronowych do prognozowania wyników sportowych - projekt systemu]

Końcową czynnością w działaniu sztucznej sieci neuronowej było uzyskanie prognozy. W zależności od zastosowanej metody uzyskano różne wyniki. W celu oszacowania skuteczności działania sieci, porównano otrzymane prognozy z rzeczywistymi danymi, a następnie oszacowano skuteczność predykcji sieci. Przy wykorzystaniu podstawowych miar statystycznych dokonano oceny trafności prognoz cen energii które przedstawia rys.5.

1. ¹Tadeusiewicz R., Sieci Neuronowe, 1993

| Ocena dopasowania | |
|---|-----------------|
| Miary statystyczne | MLP 5:30:13:1:1 |
| ME(ang.mean error)-błąd średni | 0,92 zł |
| MAE(ang. mean absolute error) bezwzględny błąd średni | 8,07 zł |
| MAPE(ang. mean absolute percent error) bezwzględny błąd procentowy) | 4,9% |
| maxAPE(ang.maximum absolute percent error)-maksymalny błąd procentowy | 38% |
| maxAE(ang.maximum absolute error)- maksymalny błąd średni | 52,88 zł |

Rys.5 Ocena dopasowania modelu [źródło: Piróg S. Projekt systemu finansowego wspomagającego podejmowanie decyzji inwestycyjnych na giełdzie energii]

Ocenę dopasowania modelu neuronowych do danych rzeczywistych przeprowadzono dla okresu budowy modeli od 01.01.20013 r. do 31.01.20013r. Analizując otrzymane wyniki można zauważyć, że przeciętne odchylenia prognoz cen energii od wartości rzeczywistych wynosi około 4.9% zmiennej prognozowanej . Można również zauważyć, że nie występuje systematyczne niedoszacowanie bądź przeszacowanie prognozy. Dostyc wysokie wartości maxAE i maxAPE świadczy o tym, że zdarzają się błędy znacznie przekraczające wartości przeciętne.

CONCLUSION/PODSUMOWANIE

W oparciu o uzyskane wyniki można stwierdzić, że sztuczne sieci neuronowe mogą stanowić narzędzie do prognozowania wydarzeń sportowych oraz predykcji cen energii elektrycznej na rynku dnia następnego. Praca ta jest ciekawym połączeniem, wydawać by się mogło odległych dziedzin, informatyki, sportu oraz ekonomii. Wykorzystanie sztucznych sieci neuronowych w prognozowaniu może w przyszłości przynieść wiele korzyści.

Literatura:

1. Tadeusiewicz R., Sieci Neuronowe, Akademicka Oficyna Wydawnicza PLJ, 2005
2. Gatley E, Sieci Neuronowe Prognozowanie Finansowe i Projektowanie Systemów Transakcyjnych, Wydawnictwo: WIG-Press
3. Kisielewicz A. Sztuczna inteligencja i logika, Wydawnictwo: WNT Wydawnictwa Naukowo-Techniczne
4. Rutkowski L. Metody i techniki sztucznej inteligencji, Wydawnictwo: PWN
5. www.tge.pl
6. www.cire.pl