

Tomasz Ząbkowski
Katedra Ekonometrii i Informatyki, SGGW
e-mail: tzabkowski@mors.sggw.waw.pl

PORÓWNANIE METOD TRAMO-SEATS I SIECI NEURONOWYCH WYKORZYSTYWANYCH DO PROGNOZOWANIA KRÓTKOOKRESOWEGO SZEREGÓW CZASOWYCH

Streszczenie: Artykuł prezentuje dwa podejścia prognozowania szeregu czasowego wykorzystania minut przez abonentów firmy telekomunikacyjnej. Do porównania zostały wykorzystane: metoda Tramo-Seats bazująca na metodologii ARIMA oraz różnego typu sztuczne sieci neuronowe. Metody te zostały w artykule gruntownie scharakteryzowane. Otrzymane w części eksperymentalnej wyniki dla prognoz krótkookresowych sugerują zasadność stosowania metody Tramo-Seats.

Słowa kluczowe: Tramo-Seats, sieci neuronowe, prognozowanie, szeregi czasowe.

WSTĘP

Prognozowanie jako działalność poznawcza i zmierzająca od wskazania najbardziej prawdopodobnych kierunków przebiegu zjawisk i zdarzeń społeczno-ekonomicznych jest coraz częściej nierozłącznym elementem, związanym z ludzką działalnością. Główną przyczyną takiego stanu rzeczy jest niepewność występująca często w sferze zjawisk ekonomicznych i w znacznym stopniu utrudniająca trafność podejmowania decyzji.

W praktyce gospodarczej, wszelkiego rodzaju prognozy są nieodzownym elementem działalności każdego przedsiębiorstwa i od ich trafności zależy efektywność zarządzania firmą [Dittmann 2002]. Spośród wielu prognoz, istotną rolę w zarządzaniu przedsiębiorstwem odgrywają prognozy sprzedaży. W niniejszej publikacji, rozważany będzie przykład prognozy sprzedaży, bądź precyzyjniej ujmując, wykorzystania ogólnej liczby minut przez klientów firmy telekomunikacyjnej. W związku z tym, że otoczenie i rynek usług telekomunikacyjnych jest bardzo dynamiczny, zakres prognoz dotyczących sprzedaży i wykorzystania minut przez abonentów ma charakter krótkookresowy, tj. do 6 miesięcy. Prognozowanie tego problemu wykorzystywane jest do działalności operacyjnej i służy do określania bieżących wydatków m.in. na reklamę, administrację oraz do testowania skutków wprowadzania zmian ceny. Wyznaczona prognoza jest również wykorzystywana w prognozowaniu finansowym, m.in. do określania wielkości środków finansowych niezbędnych do realizacji prognozowanej wielkości sprzedaży.

Wybór odpowiedniej metody prognozowania jest zagadnieniem bardzo ważnym i jednocześnie dość trudnym. Przy wyborze metod, spośród różnych ich właściwości, pod uwagę bierze się najczęściej horyzont prognozy, liczbę okresów wykorzystywanych do budowania prognozy, koszty stosowania metod, dokładność uzyskiwanych prognoz czy też prostotę i łatwość ich stosowania. Często dla danego problemu można wskazać więcej niż jedną metodę prognozowania.

W prezentowanej publikacji do prognozowania krótkookresowego na podstawie szeregu czasowego zostaną wykorzystane dwie metody, które może nie są najprostszymi i najczęściej wykorzystywanymi do prognozowania, ale przy wykorzystaniu mocy obliczeniowej komputera pozwalają na osiągnięcie bardzo dobrych prognoz przyszłych wartości szeregu czasowego. Metoda Tramo Seat stanowi obecnie jedną z najpopularniejszych i najczęściej stosowanych metod wygładzania, a następnie prognozowania szeregów czasowych. Natomiast sztuczne sieci neuronowe możemy określić jako technikę modelowania, zdolną do odwzorowywania nadzwyczaj złożonych funkcji. W szczególności sieci neuronowe mają charakter nieliniowy, co istotnie wzbogaca możliwości ich zastosowań do złożonych problemów.

METODA TRAMO SEATS

Metoda Tramo Seats stanowi obecnie jedną z najpopularniejszych i najczęściej stosowanych metod wygładzania szeregów czasowych. Metoda ta opracowana została przez V. Gómeza [Gomez i in. 1996] i A. Maravalla [Marvall 2000-2002] i jest coraz powszechniej stosowaną w szeroko pojętym zakresie wygładzania szeregów czasowych przez urzędy statystyczne, banki centralne i instytuty badawcze w Europie. Składa się z dwóch etapów Tramo i Seats. Pierwszy jest określany jako etap eliminacji wstępnej, w drugim dokonuje się właściwa dekompozycja i eliminowanie wpływów sezonowych.

Często rzeczywiste szeregi czasowe są trudne do modelowania, ponieważ zawierają bardzo nieregularne zdarzenia, których istota sprawia, że nie powinny być modelowane. Dlatego te obserwacje są usuwane, aby uniknąć zniekształceń w analizie szeregów. Dzięki procedurom wstępnym możliwe staje się "wyczyszczenie" szeregu z tych efektów, tzn. uzyskanie takich danych, jak gdyby te efekty nie miały miejsca. Szczególne znaczenie dla obydwu procedur ma identyfikacja modelu. Model powinien możliwie najlepiej opisywać badaną rzeczywistość i być uwiarygodniony przez testy statystyczne, dostępne w procedurach wyrównań.

Metoda Tramo/Seats jest metodą ściśle opartą na metodologii ARIMA wykorzystując ją nie tylko jako pomocnicze narzędzie prognozowania i wygładzania szeregu, lecz także jako podstawowe narzędzie właściwej dekompozycji do wydzielenia składowych szeregu.

TRAMO (Time series Regression with ARIMA noise, Missing values, and Outliers) jest metodą, a ściślej mówiąc programem do estymacji i prognozowania

modeli regresyjnych z brakującymi obserwacjami, błędami ARIMA, a także z różnego typu wartościami nietypowymi oraz deterministycznymi takimi jak obserwacje nietypowe, efekty kalendarzowe, święta ruchome. Istotną kwestią jest uwzględnienie tzw. efektu kalendarzowego (TD – trading day effect) powodującego różny rozkład dni roboczych w poszczególnych miesiącach. Efekt kalendarzowy może być opisany za pomocą jednej zmiennej klasyfikującej dni na robocze/nie robocze, bądź też na 6 zmiennych, które uchwytują oddzielne efekty dla każdego dnia tygodnia. Mając wektor y obserwacji szeregu czasowego:

$$y = [y(t_1), y(t_2), \dots, y(t_m)], \quad (1)$$

gdzie $0 < t_1 < \dots < t_m$, program dopasowuje model regresji, który w najprostszej postaci możemy zapisać następująco:

$$y(t) = z(t)b + x(t), \quad (2)$$

gdzie \mathbf{b} jest wektorem współczynników ω , α , i β , natomiast $\mathbf{z}(t)$ oznacza macierz z kolumnami zawierającymi zmienne opóźnione w szeregu, zmienne kalendarzowe oraz inne zmienne regresyjne i interwencyjne brane pod uwagę przy budowie modelu. Szczegółowy zapis modelu (2) może być opisany w poniższy sposób:

$$y_{(t)} = \sum_{i=1}^{n_{out}} \varpi_i \lambda_i(B) d_i(t) + \sum_{i=1}^{n_c} \alpha_i cal_i(t) + \sum_{i=1}^{n_{reg}} \beta_i reg_i(t) + x(t), \quad (3)$$

gdzie B oznacza operator opóźnienia, $d_i(t)$ jest zmienną zerojedynkową oznaczającą pozycję poszczególnych wartości nietypowej, $\lambda_i(B)$ jest wielomianem B oddającym dynamikę wartości, cal_i oznacza typ zmiennej kalendarzowej, reg_i oznacza zmienną objaśniającą bądź interwencyjną. Parametr ϖ_i to współczynnik zmiennej opisującej obserwacje nietypowe, α_i i β_i to odpowiednio współczynniki dla efektów kalendarzowych i interwencji. Z kolei symbole n_{out} , n_c , n_{reg} oznaczają całkowitą liczbę zmiennych w danym etapie.

Model ARIMA, który jest dopasowywany dla $x(t)$ może zostać zapisany w postaci $(p, d, q)(p_s, d_s, q_s)$, gdzie zbiór trzech parametrów oznacza odpowiednio rząd autoregresji, rząd „różnicowania”, oraz wielkość opóźnienia średniej ruchomej dla kombinacji czynników sezonowych i niesezonowych [Gomez i in. 2001].

SEATS (Signal Extraction in ARIMA Time Series) jest z kolei szeregiem metod do dekompozycji szeregu czasowego na zestaw komponentów w procesie określanym jako AMB (ARIMA-model-based). Zwykle, jako kolejny krok po przejściu etapu Tramo, szereg, ale już pozbawiony efektów deterministycznych takich jak obserwacje nietypowe, efekty kalendarzowe, święta ruchome, jest


poddawany dekompozycji mającej na celu wyodrębnienie komponentów szeregu. Szereg po dekompozycji, w postaci addytywnej, możemy zapisać następująco:

$$Y(t) = T(t) + C(t) + S(t) + I(t), \quad (4)$$

gdzie $T(t)$ oznacza trend, $C(t)$ oznacza wahania cykliczne, $S(t)$ oznacza wahania sezonowe, natomiast $I(t)$ oznacza wahania przypadkowe.

SZTUCZNE SIECI NEURONOWE

W prezentowanej publikacji sztuczna sieć neuronowa rozumiana będzie jako technika obliczeniowa wzorowana na strukturze i sposobie działania układów nerwowych organizmów żywych. Sztuczna sieć neuronowa jest zespołem połączonych ze sobą elementów przetwarzających tzw. neuronów. Sztuczny neuron jako model swojego rzeczywistego odpowiednika jest przedstawiony na Rys.1.




Rys.1. Przykładowy schemat sztucznego neuronu. Źródło: opracowanie własne na podstawie [Najman i in., 2000].

Jego zasadniczym celem jest przetworzenie informacji wejściowej, dostarczanej w postaci wartości x_1, x_2, \dots, x_n , w wartość wyjściową y . Przyjmuje się, że zarówno wartości wprowadzane na wejścia neuronu, jak i uzyskiwana na jego wyjściu wartość wyjściowa, mają postać liczb rzeczywistych. Z każdym wejściem neuronu związany jest współczynnik zwany wagą. Współczynniki wagowe neuronu są podstawowymi parametrami wpływającymi na sposób funkcjonowania sztucznej komórki nerwowej. Przetwarzanie informacji przez sztuczny neuron składa się z dwóch etapów. Pierwszym z nich jest agregacja danych wejściowych, zaś drugim wyznaczenie wartości wyjściowej neuronu.

Agregacja danych wejściowych ma na celu przetworzenie wektora wejściowego $\mathbf{x} = (x_1, x_2, \dots, x_n)$ w pojedynczą wartość (zagregowaną wartość wejściową). Na rezultat tej transformacji w zasadniczy sposób wpływają wartości wag. Spośród wielu sposobów agregacji największą popularnością cieszy się wyznaczanie wartości zagregowanej poprzez zsumowanie iloczynów wartości wejściowych i odpowiadających im wag. Zwykle neurony wchodzące w skład sieci tworzą warstwy, z których pierwsza nosi nazwę warstwy wejściowej, ostatnia warstwy wyjściowej, zaś wszystkie warstwy znajdujące się pomiędzy nimi określane są jako warstwy ukryte. Wartości wejściowe sieci wprowadzane są na wejścia neuronów warstwy wejściowej. Następnie, poprzez istniejące połączenia,

wartości wyjściowe neuronów jednej warstwy przekazywane są na wejścia elementów przetwarzających kolejnej warstwy. Wartości uzyskane na wyjściach neuronów ostatniej warstwy są jednocześnie wartościami wyjściowymi sieci. Prawidłowo skonstruowana sieć neuronowa może służyć do rozwiązywania wielu typów zagadnień. Do najpopularniejszych zastosowań sieci należy zaliczyć budowane przy ich wykorzystaniu modele rozwiązujące problemy regresyjne, klasyfikacyjne oraz prognostyczne [Haykin 1994]. W problemach prognostycznych, a takim jest rozważany w tej publikacji problem prognozowania krótkookresowego, celem stosowania modeli neuronowych jest wyznaczenie przyszłej wartości szeregu czasowego. Sieć rozwiązująca zagadnienia tego typu korzysta z bieżących oraz przeszłych wartości tego samego szeregu [Najman i in. 2000]. Na Rys. 2. została przedstawiona struktura sieci neuronowej dla potrzeb prognozowania szeregu czasowego.



Rys. 2. Architektura sieci neuronowej do prognozowania szeregu czasowego. Źródło: opracowanie własne na podstawie [Najman i in., 2000].

Proces mający na celu określenie prawidłowych wartości parametrów sieci (wag, struktury sieci) to tzw. uczenie sieci, które jest niezbędnym elementem procesu konstrukcji modelu neuronowego. Proces uczenia realizowany jest przy wykorzystaniu dostępnych zestawów danych, które ilustrują przebieg badanych zjawisk dla wybranych obiektów i/lub przeszłych okresów czasu. W trakcie uczenia na wejścia sieci wprowadzane są zgromadzone wartości i obserwowane jest towarzyszące tej operacji zachowanie sieci. Jeżeli zachowanie sieci nie może zostać uznane za w pełni poprawne, to przeprowadzana jest modyfikacja parametrów sieci mająca na celu poprawę jej funkcjonowania. Sposób przeprowadzenia modyfikacji określany jest przez zastosowany algorytm uczenia sieci. Typowym przypadkiem uczenia sieci w problemach prognostycznych jest tzw. uczenie z nauczycielem, gdzie zbiór uczący zawiera zarówno wartości zmiennych wejściowych jak i odpowiadające im wartości zmiennej (lub zmiennych) wyjściowych. Idea uczenia z nauczycielem jest taka, że po wprowadzeniu poprzez neurony wejściowe wartości zmiennych wejściowych wyznaczana jest odpowiedź sieci. Uzyskana w ten sposób wartość porównywana

jest z rzeczywistą wartością przechowywaną w zbiorze uczącym. Jeśli porównywane wartości nie są równe, to parametry sieci (wagi) modyfikowane są w taki sposób, aby odpowiedź sieci upodobniła się do wartości rzeczywistej. Należy zwrócić uwagę, że wyznaczany w trakcie uczenia błąd uczenia nie może stanowić podstawy do oceny jakości sieci, gdyż jego wartość może zostać sprowadzona do dowolnie niskiego poziomu poprzez rozbudowę części ukrytej sieci. Zwiększanie liczby neuronów ukrytych ma również swoje wady - zwiększa liczbę parametrów sieci szacowanych w czasie uczenia, co często w istotny sposób wpływa na czas obliczeń. Jednakże najpoważniejszą konsekwencją stosowania zbyt rozbudowanych struktur sieciowych jest możliwość utraty przez sieć zdolności do uogólniania. Z uwagi na negatywny wpływ przeuczenia na funkcjonowanie sieci należy wzbogacić procedurę uczenia o mechanizm odpowiedzialny za wczesne wykrycie zaniku zdolności do generalizacji. Sygnały o przeuczeniu nie mogą być generowane w oparciu o miary jakości sieci wyznaczone na podstawie zbioru uczącego, gdyż te wskazują w takiej sytuacji na coraz lepsze dopasowanie sieci do danych. Podstawą do uzyskania informacji o przeuczeniu muszą być mierniki wyznaczone na podstawie danych nie prezentowanych w trakcie uczenia. Aby umożliwić takie działania dostępny zbiór danych dzielony jest na trzy części: zbiór uczący (prezentowany sieci w trakcie uczenia i służący do modyfikacji wartości parametrów), zbiór walidacyjny (pozwalający na monitorowanie procesu uczenia sieci) oraz zbiór testowy (służący do przeprowadzenia ostatecznej oceny uzyskanej sieci).

PORÓWNANIE MODELI

Do celów porównawczych został wykorzystany szereg czasowy obrazujący miesięczne wykorzystanie ilości minut przez abonentów firmy telekomunikacyjnej. Celem doświadczenia było zbudowanie prognozy krótkoterminowej na najbliższe 6 miesięcy, które w jak najlepszym stopniu odzwierciedli prawdziwy przebieg zjawiska. Tak zbudowana prognoza ma służyć do prognozowania finansowego obejmującego oszacowanie wpływów gotówkowych, zależnych od ilości wykorzystanych minut. W związku z tym akceptowalny błąd prognozy musi być niewielki. Błąd predykcji był mierzony za pomocą średniego bezwzględnego procentowego błędu (MAPE), który jest często stosowaną miarą w tego typu prognozach. Błąd ten możemy zapisać w następującej formie:


$$\text{MAPE} = \frac{1}{N} \cdot \sum_{i=1}^N |\varepsilon_i| / s_i, \quad (5)$$

gdzie s_i -wartość rzeczywista, a ε_i wartość reszty.


Do dyspozycji był szereg czasowy, zawierający dane miesięczne za okres od stycznia 1999 do kwietnia 2005. Szereg posiada 76 obserwacji i jego przebieg jest przedstawiony na Rys. 3. Dość charakterystyczną cechą tego szeregu jest to, że w miesiącu lutym, na przestrzeni badanego okresu, występuje znaczny spadek

ilości wykorzystanych minut. Jednocześnie, na przestrzeni lat, dynamika wzrostu uległa zmianie, z niemalże potęgowych przyrostów na początku badanego okresu do wahań porównywalnych do białego szumu w ostatnim okresie.

W przypadku metody Tramo-Seats do budowy modelu zostały wykorzystane obserwacje 1-70, natomiast obserwacje 71-76 stanowiły część szeregu, na którym był mierzony błąd prognozy. Zgodnie z procedurą opisaną we wcześniejszym rozdziale podczas eliminacji wstępnej obejmującej m.in. eliminację wartości odstających w szeregu oraz po wyeliminowaniu efektów kalendarzowych został zidentyfikowany model ARIMA z następującymi parametrami $(0, 2, 1)(0, 1, 1)$. Obliczenia zostały wykonane przy użyciu pakietu Demetra, wersja 2.04, dostępnego m.in. na stronach Eurostat. Na Rys. 4. przedstawiona została prognoza szeregu dla oszacowanego modelu metodą Tramo-Seats.



Rys. 3. Szereg czasowy wykorzystania minut.
Źródło: opracowanie własne



Rys. 4. Prognoza szeregu metodą T/S
Źródło: opracowanie własne

Nieco inaczej został przeprowadzony eksperyment dla sieci neuronowych. W tym wypadku obserwacje 1-60 stanowiły zbiór uczący, obserwacje 61-70 stanowiły zbiór walidacyjny, a obserwacje 71-76 służyły do mierzenia błędu prognozy. W przypadku sieci neuronowych zostało wygenerowanych losowo 100 sieci o architekturze MLP i RBF, z czego 6 najlepszych modeli zostało wybranych do porównania z modelem otrzymanym w procesie modelowania za pomocą Tramo-Seats. Jako zmienne wejściowe w budowanych modelach posłużyły przeszłe wartości tego samego szeregu. Przykładowo – struktura w Modelu 1 oznacza, że model zawiera 5 zmiennych wejściowych $[Y(t), Y(t-1), Y(t-2), Y(t-3), Y(t-4)]$, 24 neurony w warstwie ukrytej, oraz w warstwie wyjściowej otrzymujemy wynik w postaci $Y(t+1)$. Sieci neuronowe zostały wygenerowane w pakiecie Statistica, wersja 6.1, Sieci Neuronowe. Sumaryczne zestawienie wyników prezentuje Tabela 1.

Tab. 1. Zestawienie otrzymanych wyników porównywanych modeli.

Model	1	2	3	4	5	6	7
Struktura	MLP 5:24:1	MLP 6:3:1	MLP 6:13:1	RBF 9:14:1	RBF 9:17:1	RBF 9:15:1	Tramo- Seat
Błąd MAPE	4,70%	4,49%	4,84%	3,72%	3,99%	3,90%	3,44%

Źródło: Obliczenia własne

Analizując wyniki w tabeli można stwierdzić, że prognoza zbudowana przy wykorzystaniu metodologii Tramo-Seat pozwala osiągnąć najmniejszy błąd, tj. 3,44%, nieco gorzej wypadają sieci neuronowe o strukturze RBF, gdzie błąd jest rzędu 3,72%-3,99%, a najmniej trafnie prognozują zjawisko sieci typu MLP.

PODSUMOWANIE

Otrzymane wyniki pozwalają sądzić, że za pomocą metody Tramo-Seats, w tym konkretnym przypadku, możemy uzyskać lepsze wyniki do prognozowania szeregu czasowego wielkości wykorzystywanych minut w firmie telekomunikacyjnej. Metoda ta pozwoliła na wykrycie pewnych charakterystyk badanego szeregu czasowego, które decydują o jego powtarzalności, w zależności od miesiąca i ilości dni roboczych w nim występujących. Przekłada się to na lepsze rozpoznanie poszczególnych komponentów szeregu, co w następstwie skutkuje uzyskaniem trafniejszych prognoz. W przypadku wykorzystania sieci neuronowych, można zauważyć, że większą trafność prognoz uzyskamy stosując sieci o radialnych funkcjach bazowych (RBF), które to służą najczęściej do nieliniowej aproksymacji zmiennych numerycznych. Z różnych twierdzeń [Poggio i Girosi, 1990] wynika, że taka sieć może służyć jako uniwersalny aproksymator i przybliżyć z dowolną dokładnością dowolną funkcję ciągłą określoną na dziedzinie wielozmiennej. Z kolei sieci MLP wykorzystane podczas eksperymentu niezbyt trafnie prognozowały badane zjawisko.

LITERATURA

- Dittmann P. (2002) Metody prognozowania sprzedaży w przedsiębiorstwie Wyd. AE, Wrocław
- Gomez, V., Marvall, A. (2001) Seasonal Adjustment and Signal Extraction in Economic Time Series, Ch.8 in Pena D., Tiao G.C. and Tsay, R.S. (eds.) A Course in Time Series Analysis, New York: J. Wiley and Sons.
- Gomez, V., Marvall, A. (1996) Programs TRAMO (Time series Regression with Arima noise, Missing observations, and Outliers) and SEATS (Signal Extraction in Arima Time Series). Instructions for the User, Working Paper 9628, Banco de Espana.
- Haykin S. (1994) Neural networks: a comprehensive foundation, Macmillan, New York

- Najman Migdał K., Najman K. (2000) Zastosowanie sieci neuronowych na WGPW, Rynek Kapitałowy – Skuteczne Inwestowanie, Wydawnictwo Naukowe Uniwersytetu Szczecińskiego, tom II, str. 433-454,
- Najman Migdał K., Najman K. (2000) Sieci neuronowe – wykorzystanie do prognozowania WIG, Profesjonalny Inwestor, nr 8/2000, str. 10-18,
- Marvall A. (2000) An application of TRAMO and SEATS, in Annali di Statistica, special issue on Seasonal Adjustment Procedures. Experiences and Perspectives, 20, p. 271-344.
- Marvall A. (2002), An application of TRAMO-SEATS: Automatic Procedure and Sectoral Aggregation. The Japanese Foreign Trade Series, Working Paper 0207, Research Department, Banco de Espana.
- Poggio, T.; Girosi, F. (1990) Networks for approximation and learning, Proceedings of the IEEE, Volume 78, Issue 9, Page(s):1481 – 149.

Comparison of Tramo-Seats and Artificial Neural Networks for time series forecasting

Summary: The paper presents the methods for time series forecasting. The case was to forecast an airtime usage of telecom customers. The methods chosen for comparison were ARIMA based Tramo-Seats and artificial neural networks. The results obtained in practical experiment suggest using Tramo-Seats for short time forecasting in this specific problem.

Key words: Tramo-Seats, artificial neural networks, forecasting, time series.