

WYKORZYSTANIE SZTUCZNYCH SIECI NEURONOWYCH PRZEZ PRZEDSIĘBIORSTWA EKSPORTUJĄCE ORAZ IMPORTUJĄCE

1. Wstęp

Sztuczne sieci neuronowe (ANN – ang. *Artificial Neural Networks*) należą do coraz popularniejszej w ostatnich latach rodziny narzędzi z obszaru sztucznej inteligencji (AI – ang. *Artificial Intelligence*). Ich powstanie zwykło się datować na rok 1943, kiedy to powstał pierwszy matematyczny model neuronu (autorami pracy pt. *Logical calculus of ideas immanent in nervous activity* byli W.S. McCulloch i W. Pitts; więcej na ten temat odnaleźć można w [10]). Swoją popularność ANN zaczęły zyskiwać szczególnie w latach 90. ubiegłego stulecia oraz w pierwszej dekadzie obecnego wieku. Wzrost ten wiąże się z dynamicznym rozwojem elektroniki, szczególnie mikrokomputerów. Zważywszy, że ANN funkcjonują w przeważającej większości w postaci aplikacji będących symulatorami działania właściwej struktury, związek między rozwojem ANN a infrastruktury komputerowej trudno zanegować. Faktem jest, że obecnie z narzędzia tego można skorzystać przy użyciu niemal dowolnego mikrokomputera domowego. Moce obliczeniowe współczesnych komputerów umożliwiają już wygodną pracę z narzędziami z dziedziny AI bez konieczności dokonywania inwestycji w infrastrukturę komputerową. Wiele osób używa obecnie omawianych narzędzi w sposób nieświadomy. Warto zauważyć, że AI jest powszechnie stosowana w tak popularnych obszarach jak np. rozpoznawanie pisma ręcznego, rekonstrukcja danych. Opisana popularność i dostępność ANN stanowi o możliwości ich zastosowania w nawet stosunkowo niewielkich firmach. Niniejsze opracowanie stanowi opis możliwości użycia ANN w przypadku firmy, której działalność w istotnej mierze oparta jest o eksport lub import.

Jednym z podstawowych czynników warunkujących końcowy wynik finansowy przedsiębiorstwa działającego na rynku otwartym jest kurs walutowy. Ma on w oczywisty sposób wpływ na funkcjonowanie nie tylko przedsiębiorstw, które eksportują swoje dobra finalne za granicę. Należy zauważyć, że produkcja w Polsce charakteryzuje się dużym stopniem importochłonności (importochłonność absorpcji krajowej jest przy tym zazwyczaj mniejsza niż w przypadku eksportu – szczegółowe informacje na temat importochłonności odnaleźć można w [11]), oznacza to, że surowce i półprodukty w dużej części muszą być sprowadzane zza granicy. Nawet firmy, które – jak mogłoby się zdawać – nie wykorzystują elementów importowanych w swojej działalności i są od kursów walutowych niezależne, często także muszą, lub przynajmniej powinny brać je pod uwagę. Zauważyć należy, że istnienie bliższych lub dalszych substytutów pochodzących z importu (lub w produkcji, których użyte są elementy importowane) powoduje pojawienie się na rynku produktów konkurencyjnych. Poziom tej konkurencji w oczywisty sposób zależy od ceny

produktu, a ta w przypadku importu jest silnie uzależniona od poziomu kursu walutowego. Oczywiście jego znajomość nie jest tożsama z możliwością jego kształtowania, niemniej jednak pozyskanie informacji o przyszłym zachowaniu rynku daje możliwość wcześniejszego przygotowania i wdrożenia właściwej strategii.

W ostatnim czasie często słychać głosy, szczególnie w mediach, jakoby remedium dla ryzyka kursowego miałyby być przez nasze państwo przyjęcie euro. Warto w tym miejscu zauważyć, że takie działanie nie zawsze wpłynie pozytywnie na kwestie importowe. Duża część polskiego importu, także uwzględniając import nierejestrowany, pochodzi z krajów spoza Europy. Powszechnie wiadomo, że walutą najbardziej pożądaną przy tego typu płatnościach jest dolar amerykański. Istnieje zazwyczaj także możliwość dokonania płatności w euro, jednak niejednokrotnie zastosowany wówczas przelicznik jest ekonomicznie nieatrakcyjny. Oznacza to w praktyce konieczność dokonywania płatności w USD, a to z kolei wymusza zakup tej waluty i powstanie ryzyka kursowego. W obecnym momencie takie ryzyko zazwyczaj powinno być brane pod uwagę przy kursie USD/PLN.

2. Model prognostyczny kursu walutowego

Pierwszym pytaniem, jakie powinno być zadane przy budowie modelu prognostycznego, jest ustalenie, co powinno być przewidywane. To pytanie może wydawać się zbędne, gdyż – przyjmując powyższe założenia – pożądaną wiedzę powinny stanowić przyszłe wartości kursu USD/PLN. Jak dowodzą badania ich prognoza jest często niewykonalna z wystarczającą precyzją. Kurs walutowy w kolejnych jednostkach czasu jest przykładem szeregu czasowego. Przewidywanie bezwzględnych wartości szeregu czasowego jest często obciążone dużym – nieakceptowalnym – błędem. Należy sobie zadać pytanie, jaka forma przewidywanego szeregu czasowego jest nie tylko przydatna z biznesowego punktu widzenia, ale także możliwa do modelowania. Jak pokazują liczne badania autora zarówno o charakterze empirycznym, jak i literaturowym, nawet proste modyfikacje pierwotnego szeregu czasowego umożliwiają wypracowanie zauważalnie lepszych jakościowo prognoz. Do takich modyfikacji zalicza się różnicę między kolejnymi wartościami szeregu czasowego, tempa wzrostu, współczynniki nachylenia krzywej regresji liniowej i wiele podobnych przekształceń.

Problem z wykorzystaniem wymienionych powyżej nowych szeregów czasowych jest jednak dość duży. Okazuje się często w praktyce, że ich wykorzystanie może nie doprowadzić do zadawalających i oczekiwanych rezultatów finansowych. Często stopień modyfikacji szeregu bazowego jest odwrotnie proporcjonalny do możliwości praktycznego

użycia nowopowstałej zmiennej. Dlatego tak ważne jest, by dokonywać oceny jakości funkcjonowania modelu przez pryzmat jego praktycznego użycia. Powszechnie w literaturze przedmiotu spotyka się modele prognostyczne, których ocena dokonana została jedynie poprzez funkcje błędu. Taka ocena nie zawsze jest wystarczająco precyzyjna. Jako przykład może posłużyć sytuacja, w której istotniejsza od prognozy bezwzględnej wartości kursu jest wiedza o zmianie trendu. Przyjmijmy istnienie dwóch modeli. Pierwszy z nich dokonuje zadowalającej prognozy kursu podczas trendu, natomiast nie posiada wysokiej skuteczności przewidywania zmian tego trendu. Punkty zwrotne nie stanowią zazwyczaj zbyt licznej grupy w szeregu czasowym, zatem błędy w ich prognozach nie wpłyną aż tak znacząco na mierniki błędu. Sieć taka może charakteryzować się stosunkowo niskimi wartościami tego miernika. Przypuśćmy teraz, że druga z sieci generuje pewne błędy (większe niż w poprzednim przykładzie) w przypadku prognozy elementów szeregu będących w trendzie, natomiast z dużym stopniem poprawności rozpoznaje przyszłe punkty zwrotne. Sieć ta może charakteryzować się gorszymi wynikami uzyskanymi poprzez obliczenie funkcji błędu, jednak w konkretnym zastosowaniu może być ona modelem zdecydowanie bardziej pożądanym.

Należy zatem przyjąć, że o ile taka możliwość istnieje, to dobrym rozwiązaniem jest sprawdzenie najlepszych modeli w zastosowaniach praktycznych i dopiero w oparciu o takie wyniki dokonanie wyboru optymalnego rozwiązania.

2.1. Dane wejściowe modelu

Problem doboru danych wejściowych stanowi kolejny istotny element budowy modelu prognostycznego. O ile wybór zmiennej wyjściowej podyktowany był możliwościami jej praktycznego użycia, a jednocześnie zdolnościami prognostycznymi modelu, o tyle dobór zestawu danych wejściowych stanowi pewną zagadkę. Wykorzystując teorię Kolomogorova wykazać można, że przy wykorzystaniu nieliniowych jednokierunkowych ANN o architekturze trójwarstwowej (o czterech warstwach), zbudowanych z n neuronów w warstwie wejściowej, $2n+1$ neuronów w warstwie ukrytej możliwe jest odtworzenie dowolnej funkcji ciągłej o n zmiennych [2, 7, 14]. Co prawda jej postać nie będzie jawnie podana, to jednak informacja ta stanowić może punkt wyjścia w procesie doboru zmiennych objaśniających. Pierwsze założenie jest dość oczywiste, dane wejściowe muszą mieć związek z danymi wyjściowymi. Niestety rodzaj tej zależności nie jest już tak oczywisty. Często, próbując przewidywać dane ekonomiczne, odnaleźć można odwołania do danych makroekonomicznych. Nie sposób zaprzeczyć, że istnieje związek między kursem walutowym, a takimi wielkościami jak bezrobocie czy inflacja. Zatem wykorzystanie tych danych w roli zmiennych wejściowych modelu wydaje się być czynnością wręcz oczywistą. W badaniach empirycznych przeprowadzonych przez autora wykazano, że wymienione wielkości nie są najbardziej istotnymi zmiennymi modelu, co więcej – czasami ich obecność przyczynia się wręcz do pogorszenia wyników symulacji. Gdzie zatem tkwi problem? Przede wszystkim wynika ona ze zmienności tych danych. Szacunkowe informacje o inflacji czy też bezrobociu nie zmieniają

się codziennie. Jeśli zatem za ich pomocą możliwe jest przewidywanie średnich kursów walutowych o okresie kilkumiesięcznym, to predykcja kursów walutowych na kolejne kilka, kilkanaście dni nie jest już możliwa.

Potrzebne są zatem takie zmienne wejściowe, które zmieniają się z częstotliwością zbliżoną do zmian danych wyjściowych modelu. W tym miejscu okazuje się zazwyczaj, że dane makroekonomiczne w dużej mierze trzeba będzie odrzucić. Pojawia się w tym momencie kolejne pytanie, czy wszystkie takie informacje są bezużyteczne. Oczywiście nie, niemniej jednak z zasady funkcjonowania ANN wynika, jedna ich – w pewnym sensie – wada: błędy wygenerowane przez pojedyncze neurony w procesie funkcjonowania ANN ulegają sumowaniu. Oznacza to, że czym więcej jest danych wejściowych, tym więcej jest neuronów, a czym więcej komórek nerwowych, tym więcej błędów. Wniosek jest zatem oczywisty: struktura ANN powinna być możliwie prosta, tak by błędów było możliwie mało. Zatem dane makroekonomiczne można zostawić w zbiorze danych wejściowych, jednak tylko w ograniczonym zakresie. Oczywiście wybór, które z nich są najbardziej istotne także nie jest prosty i zazwyczaj ma charakter badań empirycznych. Należy przy tym zauważyć, że wybór optymalny może różnić się w zależności od rodzaju kursu walutowego, który poddany jest analizie.

2.2. Analiza techniczna w modelach ANN prognozujących rynek walutowy

W ANN wykorzystuje się zatem zazwyczaj dane bezpośrednio pochodzące z danego rynku lub też ewentualnie rynków skorelowanych. Ich częstotliwość jest zazwyczaj identyczna lub zbliżona do częstotliwości prognozowanej zmiennej. Najprostszym przykładem tego typu danych są w przypadku kursów walutowych ich wartości sprzed danej liczby dni. Wprowadza się zatem na wejście sieci zazwyczaj kurs opóźniony o 1 dzień, o 2 dni itd. Liczba opóźnionych szeregów czasowych jest różna. Zazwyczaj nie przekracza ona jednak 10.

Ten rodzaj danych wejściowych niesie ze sobą również pewne zagrożenie. Zauważyć należy, że dane kursowe składają się nie tylko z informacji, które pokazują pewną tendencję zmiany kursu – dla uproszczenia można nazwać ją trendem. Kursy walutowe to również pewna składowa o charakterze, nazwijmy to, stochastycznym. Ta przypadkowość kursów nie może być w łatwy sposób wytłumaczona z użyciem danych, którymi dysponuje się, tworząc model. Często używa się mechanizmów filtrowania danych, tak by uwypuklić pewne tendencje kursu, zminimalizować składową losową, usunąć zbędny szum. Jednym z najprostszych przykładów takiego działania jest powszechne wykorzystanie w ANN średnich ruchomych (MA – ang. *Moving Average*). Ich obliczenie nie jest sprawą skomplikowaną, natomiast wybór właściwej średniej kroczącej przysparza już więcej wątpliwości. Na wstępie należy rozważyć dwie kluczowe kwestie – jaki typ MA należy zastosować oraz jakiej długości średnia powinna być użyta.

Proste średnie ruchome (SMA – ang. *Simple Moving Average*) są w istocie średnimi arytmetycznymi, zatem posiadają wszystkie ich wady. Główną jest to, że każdy element wchodzący w skład takiej zmiennej oddziałuje na jej wartość

w identycznym stopniu. Nie zawsze jest to poprawne rozwiązanie. Wystarczy zauważyć, że nierzadko nowsze dane mają większy wpływ na obecną wartość przewidywanego kursu niż dane starsze (więcej o SMA odnaleźć można m.in. w [1, 5, 12]).

W celu rozwiązania tego problemu powszechnie używa się średnich typu wykładniczego (EMA – ang. *Exponential Moving Average*). W tym przypadku, wpływ zmiennej wejściowej na wartość średniej maleje wraz z czasem. Mówiąc inaczej, czym dana jest starsza, tym w mniejszym stopniu może wpływać na wartość EMA.

Jak dowodzą liczne badania, w tym także badania własne autora, w wielu przypadkach można zbudować daną wejściową o większym stopniu optymalności niż EMA, przy użyciu średnich ważonych (WMA – ang. *Weighted Moving Average*). W tym przypadku wagi mówiące o istotności danej informacji mogą być ustalane niemal dowolnie. Badania wykazały, że w przypadku predykcji kursów walutowych, zazwyczaj największy wpływ mają dane opóźnione od 2 do 4 dni. Dane starsze, co jest oczywiste, mają wpływ stosunkowo niewielki. Zaskakujący jest natomiast fakt, że wpływ najświeższych danych okazał się być także zauważalnie mniejszy od najlepszej. Powoduje to, że dobrze zbudowana zmienna typu WMA stanowi istotną daną wejściową modelu prognostycznego opartego o ANN (formuły definiujące średnie EMA oraz WMA znajdują się m.in. w [5, 12]).

Kolejną zasługującą na uwagę zmienną wejściową jest średnia ruchoma typu VIDYA (ang. *Variable Index Dynamic Average*). W dwóch wersjach – dłuższej i krótszej – zaprezentowana ona została już w roku 1992 na łamach magazynu „Technical Analysis of Stocks & Commodities” [3]. Obecnie dokonuje się często modyfikacji oryginalnych średnich, np. poprzez zastąpienie występującego w nich odchylenia standardowego przez filtr wertykalno-horyzontalny [1, s. 216-217].

Kolejną grupę niezwykle użytecznych zmiennych wejściowych stanowią różnego rodzaju oscylatory. Zarówno badania literaturowe, jak i własne autora, jednoznacznie potwierdzają, że szczególnie przydatne są dwa z nich: RSI oraz MACD, przy czym – jak pokazuje empiria – zasadne jest wprowadzanie pewnych modyfikacji w stosunku do ich oryginalnego kształtu – przede wszystkim zmiana długości średnich typu EMA użytych do obliczenia MACD oraz wygładzanie wskaźnika RSI, więcej informacji na temat oscylatorów znajduje się m.in. w [4, 5, 6, 13].

2.3. Prognoza kursu USD/PLN

Przy wykorzystaniu opisanych powyżej metod i narzędzi zbudowany został system prognozujący szereg czasowy w postaci kursu USD/PLN. Założono, że badania mają mieć charakter obiektywny, zatem priorytetem stała się eliminacja wszelkich elementów subiektywnych. Z tego powodu, w modelu zrezygnowano ze wszystkich zmiennych wejściowych, których wartości byłyby zależne od oceny człowieka. Dane zawsze pochodziły z oficjalnie dostępnych źródeł i miały charakter liczbowy. Na kolejnym etapie zostały one poddane transformacji, poprzez analizę techniczną. Analogiczny problem związany z obiektywizmem badań pojawił się przy wyborze metody oceny jakości

prognoz. Finalnie zdecydowano się na ewaluację otrzymanych wyników przy użyciu systemu transakcyjnego i metody ruchomego okna czasowego. System transakcyjny kupował oraz sprzedawał daną walutę, starając się wypracować w tym procesie maksymalne zyski. Należy przy tym zaznaczyć, że system ten poddany został maksymalnemu uproszczeniu. Przykładowo, zrezygnowano w nim z nawet tak podstawowych i typowych mechanizmów jak choćby zlecenia typu *stop-loss*. Nie należy jednak odbierać tego uproszczenia jako wady. Działanie takie miało na celu jednoznaczne wykazanie, że otrzymane wyniki końcowe związane są z jakością predykcji modelu ANN, a nie jedynie sprawnym działaniem systemu transakcyjnego. W oczywisty sposób rozbudowa tego systemu może przyczynić się do dalszego zwiększenia osiąganych zysków.

Metoda okna czasowego polega na sprawdzeniu stanu portfela na początku inwestycji i na jej końcu, a następnie na obliczeniu zysku lub straty. W kolejnym etapie okno jest przesuwane o jeden element (w przeprowadzonych badaniach był to jeden dzień), a następnie ponowne obliczenie wyniku finansowego. Procedura ta powtarzana jest tak długo, aż okno „przebiegnie” po wszystkich elementach tzw. zbioru testowego, czyli tego zbioru danych, który służy do sprawdzenia jakości funkcjonowania modelu. Ostatnim etapem jest obliczenie zestawień o charakterze statystycznym, przede wszystkim średniego zysku lub straty, odchylenia standardowego, liczby okien czasowych zakończonych zyskiem oraz funkcji trendu.

Badania wykazały, że modele oparte o ANN charakteryzują się niezwykle wysokim odsetkiem rocznych okien czasowych o dodatnim wyniku finansowym. Dla sieci o architekturze jednokierunkowej wielowarstwowej wyniósł on 99,7%. Jeszcze bardziej imponujące wyniki wygenerowane zostały przez model bazujący na analizie wieloczęstotliwościowej (MRA – ang. *MultiResolution Analysis*); więcej na temat MRA oraz wykorzystywanej przez nią dyskretnej transformacji falkowej odnaleźć można m.in. w [8, 9]. Odsetek rocznych okien czasowych zakończonych zyskiem wyniósł co prawda także 99,7%, natomiast średnie zyski okazały się być wyższe niż w poprzednim modelu (6,21%) i wyniosły ponad 8,26%.

Kluczowymi okazały się być takie zmienne wejściowe jak wskaźnik RSI, MACD (5-34-7), SMA 8 i 15-dniowa, EMA 5-dniowa. Jako zmienną wyjściową wykorzystano tangens kąta nachylenia krzywej regresji liniowej, obliczonej na przedziale o 13 elementach. W przypadku modelu opartego o MRA wykorzystana została falka biortogonalna 6/8.

3. Podsumowanie

Reasumując, ANN umożliwiają dokonywanie stosunkowo precyzyjnej predykcji zachowania kursu walutowego. Należy zauważyć, że o ile w przeprowadzonych badaniach otrzymane zyski oscylowały w okolicach tych, które można uzyskać przy użyciu innych metod prognostycznych, to już prawdopodobieństwo wygenerowania dodatniego wyniku finansowego przy założeniu min. rocznego horyzontu inwestycji jest wyjątkowo wysokie.

Warto nadmienić, że użycie ANN w przedsiębiorstwie, także tym prowadzącym wymianę z zagranicą nie musi ograniczać

się jedynie do przewidywania kursów walutowych. Technika ta z powodzeniem może zostać wykorzystana do przewidywania innych danych o charakterze szeregów czasowych. Przykładowo, wymienić tu można tak istotne elementy funkcjonowania przedsiębiorstwa jak chociażby przychody czy koszty. ANN mogą znaleźć zastosowanie również bezpośrednio w optymalizacji procesu produkcji. Ilość możliwości ich użycia, jak pokazuje literatura przedmiotu, jest bardzo szeroka. Oczekiwać należy, że najbliższe lata przyniosą dalszy wzrost popularności ANN w praktycznych zastosowaniach biznesowych.

Literatura:

- [1] Achelis S. B.: *Analiza Techniczna od A do Z*. LT&P, Warszawa 1998.
- [2] Arsie I., Pianese C., Rizzo G.: *Enhancement of Control Oriented Engine Models Using Neural Network, Theory and Practice of Control and Systems*. Proceedings of the 6th IEEE Mediterranean Conference, Alghero, Sardinia, Italy 9-11 June 1998, 1999.
- [3] Chande T. S.: *Adapting Moving Averages To Market Volatility*. „Technical Analysis of Stocks & Commodities” V.10:3, 1992, p. 108-114.
- [4] Ehlers J. F.: *The RSI Smoothed*. „Technical Analysis of Stocks & Commodities” V.20:10, 2002, p. 58-61.
- [5] Elder A.: *Zawód inwestor giełdowy*, Oficyna Ekonomiczna, Dom Wydawniczy ABC, Warszawa 2012.
- [6] Gately E.: *Cena i czas. Zarys metod analizy technicznej*. WIG-Press, Warszawa 1999.
- [7] Jackson T. O.: *Handbook of Neural Computation Part, relase 97/1*. The Institute of Physics Publishing Ltd and Oxford University Press, 1997. Dostępny: <http://www.iop.org/Books/CIL/HNC> (19.03.2003), Part B4.2.
- [8] Jasiński T.: *The choice of a proper output variable in a forecasting model based on ANN*, [w:] Szablewski A.T., Jasiński T. (red.): *Different dimensions of microeconomic competitiveness*, Wydawnictwo Politechniki Łódzkiej, Łódź 2008, s. 93-102.
- [9] Jasiński T.: *Zastosowanie dyskretnej transformaty falkowej do poprawy wyników uzyskiwanych przez sztuczne sieci neuronowe*, [w:] *Studia i prace Kolegium Zarządzania i Finansów. Zeszyt naukowy 48*, Szkoła Główna Handlowa w Warszawie, Warszawa 2004, s. 23-32.
- [10] Kiełtyka L. (red.): *Inteligentny System Prognozowania. Zasady funkcjonowania. Zastosowania*, Wydawnictwo Politechniki Częstochowskiej, Częstochowa 2000.
- [11] Łaski K., Osiatyński J., Zięba J.: *Mnożnik wydatków państwowych i szacunki jego wielkości dla Polski*, [w:] *Materiały i studia, Zeszyt nr 246*. Narodowy Bank Polski, Warszawa 2010.
- [12] REUTERS, *Analiza techniczna. Wprowadzenie*. Oficyna Ekonomiczna, Dom Wydawniczy ABC, Kraków 2001.
- [13] Tarczyński W.: *Rynki kapitałowe. Metody ilościowe*. Vol. I, Agencja Wydawniczo-Poligraficzna „PLA-CET”, Warszawa 2001.
- [14] Trafalis T.B.: *Neural and radial basis function networks – Lecture 12*. School of Industrial Engineering University of Oklahoma, Norman 2000.

THE USAGE OF ARTIFICIAL NEURAL NETWORKS BY EXPORT AND IMPORT ENTERPRISES

Key words:

artificial neural networks, exchange rate, trading systems.

Abstract:

The paper raises issues of the use of artificial intelligence in the enterprise. The focus was on the possibility of using artificial neural networks to accurately predict the behavior of the time series relevant to the economic activities based on the export and import. In particular, the paper describes the practical possibilities for time series forecasting such as foreign exchange rates.

Researches focused on predicting of slope of linear regression, to determinate the direction of exchange rate changes. Artificial neural networks, tested during researches, included two types of models. First one was a simple neural network model, containing only a one network. Second one was a more complex model containing at least a few networks. These networks were used for predicting a part of output variable.

To obtained mentioned parts during researches was used multiresolution analysis based on discrete wavelet transform. During researches a lot of versions of multiresolution analysis were tested. Finally, as the best one, was chosen the discrete wavelet transform based on the biorthogonal 6/8 wavelet.

The paper describes also a type of model input variables, considering a frequency of their changes. It shows advantages and disadvantages of macroeconomic data and technical analysis.

The article describes main and the most useful types of moving averages, such as simple moving average, exponential moving average, weighted moving average and VI-DYA (Variable Index Dynamic Average). The paper mentions other type of input variable, especially such indicators as RSI and MACD and their modifications.

The final evaluation of the models was carried out based on a simple trading system. Thus was confirmed the usefulness of the results in practical applications. During the analysis of the obtained results, was used the method of sliding window.

Dr inż. Tomasz JASIŃSKI

Instytut Nauk Społecznych i Zarządzania Technologiemi
Wydział Organizacji i Zarządzania
Politechnika Łódzka
tomasz.jasinski@p.lodz.pl