

Sztuczna inteligencja w MSP

WSTĘP

Pojęcie sztucznej inteligencji (AI) nie jest zagadnieniem nowym, jednakże to właśnie w ostatnich latach nastąpił istotny wzrost zainteresowania tą dziedziną wiedzy wykraczający poza rozważania akademickie. Zasadne staje się zatem pytanie, czy istotnie AI jest narzędziem wnoszącym „nową jakość” do funkcjonowania przedsiębiorstwa. O ile nowoczesne narzędzia analizy danych są od wielu lat obecne w dużych firmach i nikt nie podważa zasadności ich wykorzystania, o tyle przydatność AI w MSE często zostaje niezauważona. Należy zatem zastanowić się nad minimum dwiema kluczowymi kwestiami: w rozwiązywaniu jakich problemów możemy wspomagać się AI i jaki typ narzędzi wydaje się być optymalny w takim zastosowaniu.

Teoretycznie trudno wyobrazić sobie formę działalności gospodarczej, która nie mogłaby być wspomagana przez narzędzia AI. Często menedżerowie firm nie wiedzą bądź też nie uświadamiają sobie, że zasada funkcjonowania omawianych narzędzi wywodzi się wprost z natury i tak *de facto* stanowi próbę jej naśladowania. W zależności od rodzaju narzędzia możemy mówić o AI naśladującej funkcjonowanie biologicznego mózgu bądź też stanowiącej uproszczoną wersję występujących w przyrodzie ogólnych praw ewolucji według Darwina. Można zatem rozważyć stwierdzenie, że kwestionowanie faktu funkcjonowania AI stanowi zarówno próbę zaprzeczenia istnieniu inteligencji wśród organizmów żywych, jak i zmian zachodzących w przyrodzie.

Z oczywistych względów poziom komplikacji modelu jest nieporównywalnie mniejszy niż ma to miejsce wśród biologicznych organizmów. Należy jednak zwrócić uwagę, że tworząc model jesteśmy w stanie dokonać jego skrajnej specjalizacji w kierunku rozwiązywania jedynie zadanego problemu. Dzięki temu nawet potencjalnie stosunkowo mało „inteligentny” model jest w stanie zaoferować nam możliwość wygenerowania użytecznych wyników. Liczne różnice, które występują między omawianymi modelami a modelami biologicznymi, często stają się przyczynkiem do czynienia prób dyskwalifikowania AI. Wydaje się, że wspomniane różnice nie tylko nie świadczą o słabości narzędzia, a wręcz przeciwnie – stanowią o jego sile. Wspomniane różnice umożliwiają

nam dokonywanie analiz pod nieosiągalnym przez nas, ludzi, kątem. Taka analiza może dać nam wiele dodatkowych informacji, których nie uzyskamy od nawet najlepszych analityków.

Wśród wielu rodzajów AI wyróżnia się często dwie podstawowe podgrupy:

- sztuczne sieci neuronowe (ANN),
- narzędzia bazujące na zasadach ewolucji Darwina.

Istnieją również narzędzia hybrydowe łączące wymienione dwie podgrupy.

ANN W MSP

ANN, jak powszechnie wiadomo, są pewną strukturą stanowiącą siatkę połączonych ze sobą neuronów. Przesyłając między sobą sygnały potrafią one generować odpowiedź na zadawane pytania. Upraszczając można powiedzieć, że ANN wykorzystywane są do minimalizacji błędu zadanej funkcji celu. Wspomnianą funkcją w MSP może być np. błąd predykcji szeregu czasowego opisującego przyszłe przychody firmy, czy też jej koszty. W oczywisty sposób nie każda ANN jest w stanie dokonać właściwej prognozy. Proces poszukiwania odpowiedniego modelu jest zadaniem żmudnym, w wysokim stopniu wykraczającym poza zestaw reguł i bazującym na takich elementach jak intuicja i pomyślność osoby odpowiedzialnej za budowę modelu. Właśnie brak jednoznacznych zasad mówiących o sposobie dojścia do poprawnie funkcjonującego modelu stanowi w wielu wypadkach podstawową przeszkodę w zwiększeniu powszechności użycia tego narzędzie w przedsiębiorstwach. Warto w tym miejscu nadmienić, iż model, który uznać można za zadowalający najprawdopodobniej nie będzie optymalny. Inaczej ujmując, praktycznie zawsze istnieje możliwość stworzenia modelu o większej skuteczności. Kwestię poprawnej oceny jakości funkcjonowania modelu oraz, co równie ważne, możliwości jego praktycznego zastosowania uznać należy zatem za fundamentalną z punktu widzenia przedsiębiorstwa. Wielokrotnie postulowana przez autora metoda weryfikacji modeli poprzez efekt ich praktycznego zastosowania wydają się być najbardziej trafnym, i co ważniejsze, najbardziej pewnym sposobem oceny.

Ponieważ pod pojęciem ANN kryje się tak *de facto* wiele często skrajnie różnych architektur, na wstępie budowy modelu należy dokonać pewnego zawężenia architektur, które mają szanse sprawdzić się w danym zastosowaniu. W przypadku przewidywania szeregów czasowych należy w pierwszym kroku sprawdzić wyniki wygenerowane przez sieci rekurencyjne. Sieci te, jak wiadomo, charakteryzują się istnieniem połączeń zwrotnych, przesyłających sygnały z dalszych, licząc od wejścia, neuronów sieci do neuronów warstw wcześniejszych (lub też neuronów tej samej warstwy) [Tadeusiewicz 1998, s. 243]. Jeżeli przyjmiemy za słuszne założenie, że przeszłość ma wpływ na przyszłość, czyli

że z wartości archiwalnej szeregu czasowego jesteśmy w stanie odczytać informacje wpływające na przyszłą wartość tego szeregu, wówczas zastosowanie wspomnianej architektury wydaje się być jak najbardziej zasadne. W szczególności polecane są architektury z rodziny sieci Elmana oraz Jordana wraz z ich modyfikacjami, takimi jak np. rozszerzona sieć Elmana [Jasiński, 2003, s. 166–177]. Oczywiście wprowadzanie sygnałów archiwalnych prognozowanego szeregu jest możliwe również w przypadku wysoce popularnych sieci jednokierunkowych, jednakże, jak postuluje wielu autorów, w tym przypadku ich skuteczność jest często (choć nie zawsze) niższa.

Mimo iż tak skonstruowany model jest zazwyczaj w stanie wygenerować zyski, to jednak w większości przypadków nie jest on wyborem optymalnym, a co za tym idzie, szczególnie w przypadku jego praktycznego zastosowania w przedsiębiorstwie – poza czysto teoretycznymi badaniami, istnieje silna potrzeba przeprowadzenia procesu optymalizacji. W ostatnich latach jest ona często związana z zastosowaniem bazującej na dyskretnej transformacji falkowej analizy wieloczęstotliwościowej. Zabieg ten pociąga za sobą powstanie kolejnych wątpliwości co do wyboru parametrów wspomnianej analizy¹.

METODY BAZUJĄCE NA OPERATORACH GENETYCZNYCH (OG)

Do najbardziej popularnych metod z tej grupy zalicza się m.in. algorytmy genetyczne (AG) oraz struktury ewolucyjne (SE). Obie techniki bazują na zasadzie tworzenia pewnej populacji osobników, a następnie na ich zmianach przy użyciu operatorów genetycznych, jednak istnieją między nimi istotne różnice. Przede wszystkim w przypadku SE proces wyboru osobników najlepiej dopasowanych (do postawionego zadania) ma charakter deterministyczny. Oznacza to, że jedynie te osobniki, które są najlepsze mają szansę „przeżyć” i dostać się do nowego pokolenia. W przypadku AG zastosowano funkcję kary, która mimo iż obniża, w przypadku gorszych osobników, prawdopodobieństwo „przeżycia” to jednak stwarza szansę na ich przejście do następnego pokolenia. Ciekawostką jest fakt, że oba narzędzia powstały w podobnym czasie w różnych ośrodkach (AG w USA, SE w Niemczech) i mimo iż nie istniała wówczas (lata 60. ubiegłego wieku) dynamiczna wymiana myśli naukowej między tymi ośrodkami, są one w wysokim stopniu do siebie podobne.

Podstawowymi OG w obu technikach są: mutacja oraz selekcja. Podobnie jak w żywych organizmach pierwsza z nich polega na zmianie wartości jednego z genów, zaś druga na „rozcięciu” łańcuchów DNA dwóch osobników i zamia-

¹ Możliwości wykorzystania MRA do optymalizacji modeli ANN zostały opisane m.in. w [Jasiński, 2004].

nie ich fragmentów ze sobą. Obecnie często spotyka się rozwiązania będące syntezą obu opisanych metod, np. tzw. algorytm genetyczny hodowcy, w skrócie zwany BGA – ang. *Breeder Genetic Algorithm*².

Warto w tym miejscu nadmienić, że zarówno AG, jak i SE mogą występować jako samodzielne narzędzie służące do rozwiązywania problemów (w tym także z szeroko pojętej ekonomii), jak również być wykorzystywane jako techniki współpracujące z innymi metodami sztucznej inteligencji (np. z ANN). [Rutkowska, Piliński, Rutkowski, 1999, s. 251].

Szczególnie ostatnie z zastosowań stało się w ostatnim czasie popularne. Dzięki wykorzystaniu AG lub SE można efektywnie skrócić czas potrzebny do zbudowania poprawnie funkcjonującego modelu opartego o ANN. Zazwyczaj omówione narzędzia wykorzystuje się w procesie doboru optymalnych parametrów sieci, takich jak: rodzaj sieci, jej struktura, algorytm nauki, parametry treningu, odpowiedni zestaw danych wejściowych itp. [Jasiński, 2009, s. 65].

PRZYKŁADY WYKORZYSTANIA AI W MSP

SI jest obecnie wykorzystywana m.in. do³ [Jasiński, 2008, s. 86]:

- przewidywania indeksów giełdowych oraz budowania systemów transakcyjnych bazujących na nich,
- prognozowania kursów walutowych oraz także budowania systemów transakcyjnych bazujących na wspomnianych kursach,
- przewidywania cen opcji,
- przewidywania przepływów pieniężnych w przedsiębiorstwie (np. przychodów, kosztów),
- prognozowania wysokości inflacji,
- predykcji zapotrzebowania na wynajem nieruchomości,
- szacowania przyszłych cen nieruchomości.

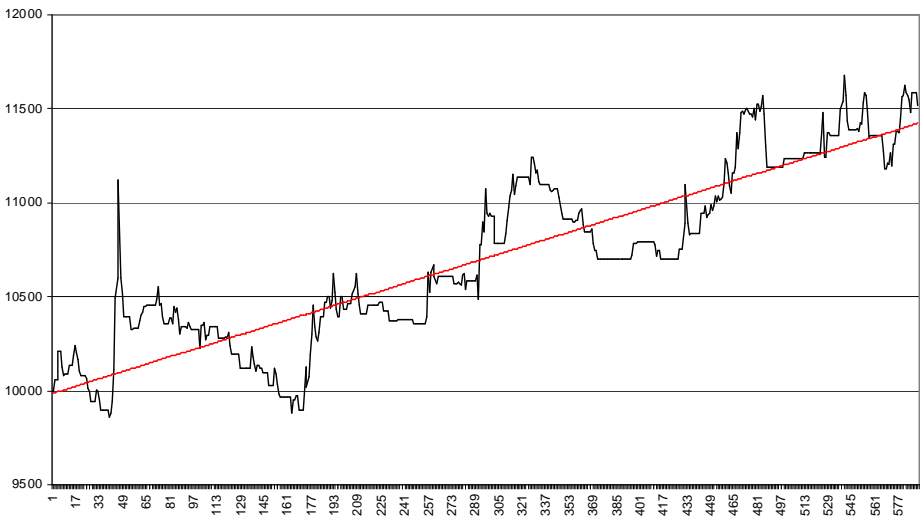
Wymienione powyżej zastosowania wydają się być niezwykle przydatne w szczególności z punktu widzenia MSP.

Jako przykład podać można wyniki osiągnięte przez autora przy prognozowaniu szeregów czasowych w postaci kursu walutowego USD/PLN. Ocena uzyskanych wyników została dokonana poprzez efekt ich praktycznego zastosowania. Służył do tego prosty system transakcyjny (bez jakichkolwiek mecha-

² Algorytm BGA opisany został m.in. w [Falco D., Cioppa A.D., Natale P., Tarantino E., Artificial Neural Networks Optimization by means of Evolutionary Algorithms, *Soft Computing in Engineering Design and Manufacturing*, Chawdhry P.K., Roy R. and Pant R.K., 1998, s. 3–12].

³ Przykładowy zastosowania SI odnaleźć można m.in. w: [Worzala, Lenk, Silva 1995, Yao, Li, Tan, 2000, Lula 1999, Witkowska 2002, Kumar, Sinha, Tomar, Adhikari 1999, Li, Li 1996, Dunis 2001, Tan 1999].

nizmów mających na celu ograniczenie ewentualnych strat). Następnie sprawdzono stan portfela inwestora na początku oraz na końcu procesu inwestycyjnego (1 rok). Celem obliczenia danych statystycznych dotyczących szans osiągnięcia zysków zastosowano tzw. metodą okna czasowego. Polegała ona na przesunięciu wspomnianego już rocznego okresu inwestycji o jeden dzień do przodu i sprawdzeniu uzyskanych wyników. Następnie obliczona została liczba opisanych okien czasowych, które zakończone zostały zyskiem. Omówiona technika weryfikacji uzyskanych wyników ma tą podstawową zaletę, że nie wymaga od badacza użycia jakichkolwiek subiektywnych metod oceny. Cały proces ma charakter obiektywny i nie wymaga w żadnym momencie ingerencji człowieka.




Rysunek 1. Stan portfela inwestycji w kolejnych dniach dla strategii bazującej na ANN prognozujących zmienną wyjściową w postaci tangensa kąta nachylenia krzywej regresji liniowej obliczonej w oparciu o próbę o 13 elementach

Źródło: opracowanie własne.

Rysunek 1 przedstawia stan portfela inwestora przy wykorzystaniu ANN prognozujących zmienną wyjściową w postaci tangensa kąta nachylenia krzywej regresji liniowej obliczonej w oparciu o próbę o 13 elementach. Obliczona wartość umieszczona była w środku przedziału (w elemencie nr 7). Jako szereg pierwotny wykorzystano kurs USD/PLN. Linia czerwoną zaznaczono regresję liniową oszacowaną na podstawie całego zbioru testowego (590 jednostek czasu). Początkowy stan portfela wynosił 10 000 PLN. Stan portfela w ostatnim dniu okresu testowego wyniósł 11 520,56 PLN, średni zysk przy użyciu omówionego rocznego okna czasowego wyniósł 621,28 PLN, przy odchyleniu standardowym 208,56.

Sieć ta okazała się być jedną z najlepszych pod względem procentowego udziału okien czasowych osiągających wartości dodatnie, wyniósł on aż 99,7%.

Jeszcze lepsze wyniki osiągnięte zostały przy wykorzystaniu wspomnianej wcześniej techniki dekompozycji szeregu czasowego na składowe podczęstotliwościowe za pomocą DWT. Na rysunku 2 przedstawiono stan inwestycji dla modelu bazującego na falce biortogonalnej 6/8 oraz dekompozycji szóstego stopnia (na siedem składowych).



Rysunek 2. Stan portfela inwestycji w kolejnych dniach dla strategii bazującej na ANN opartych o MRA wykorzystującej falę biortogonalną 6/8

Źródło: opracowanie własne.

Opisany model osiągnął 25,1% zysku dla całego zbioru testowego (590 próbek). Średni zysk dla rocznego okna i kapitału początkowego inwestycji równego 10 000 PLN wyniósł 826,03 PLN przy odchyleniu standardowym równym 302,52. Na uwagę zasługuje fakt, że tak jak poprzednio, aż dla 99,7% okien czasowych zanotowano zyski.

PODSUMOWANIE

Należy zauważyć, że wykorzystywane obecnie narzędzia AI umożliwiają nawet w przypadku firm sektora MSP pozyskanie informacji przydatnych w funkcjonowaniu tychże przedsiębiorstw. Przypuszczać należy, że wciąż jesz-

cze stosunkowo niska popularność omawianych narzędzi na rynku polskim stwarza realną szansę na osiągnięcie przewagi konkurencyjnej związanej z pozyskaniem dodatkowych informacji. Jak zostało to pokazane na przykładzie badań rynku walutowego, wygenerowane wyniki mogą odznaczać się niezwykle wysokim stopniem ich wiarygodności, co w przypadku większości mechanizmów analizy technicznej nie jest zjawiskiem częstym. Stosunkowo niewysokie zyski mogą zostać zdecydowanie zwiększone poprzez zastosowanie dodatkowych mechanizmów wspomagających, takich jak np. bardziej zaawansowany system transakcyjny. W niniejszej pracy nie zostały one użyte celem przedstawienia jednoznacznej, niczym niezaburzonej, zależności między AI a osiągniętymi wynikami. Osiągnięte rezultaty traktować należy jako rozwojowe. Możliwości poprawy wyników spodziewać się należy w obszarze doboru danych wejściowych omawianych modeli.

LITERATURA

- Dunis C.L., 2001, *Prognozowanie rynków finansowych*, Oficyna Ekonomiczna, Dom Wydawniczy ABC.
- Jasiński T., 2008, *Improving the company competitiveness through artificial neural networks tools* [w:] A.T. Szablewski, T. Jasiński, *Different dimensions of microeconomic competitiveness*, Wydawnictwo Politechniki Łódzkiej, Łódź, s. 82–92.
- Jasiński T., 2003, *Przegląd architektur sztucznych sieci neuronowych wykorzystywanych w ekonomii do przewidywania szeregów czasowych*, Studia i Prace Kolegium Zarządzania i Finansów, SGH, zeszyt naukowy 35, s. 166–177.
- Jasiński T., 2009, *Wykorzystanie sztucznej inteligencji w prognozowaniu zjawisk ekonomicznych*, Prace Naukowe Katedry Nauk Ekonomicznych, t. VIII, Politechnika Gdańska, Gdańsk, s. 63–72.
- Jasiński T., 2004, *Zastosowanie dyskretnej transformaty falkowej do poprawy wyników uzyskiwanych przez sztuczne sieci neuronowe*, Studia i Prace Kolegium Zarządzania i Finansów, SGH, z. nauk. 48.
- Kumar A., Sinha A., Tomar N., Adhikari A., 1999, *Forecasting House Rental Levels: Analytical Rent Model versus Neural Network*, Journal of Urban Planning & Development, Vol. 125 Issue 1, s. 55–57.
- Kwaśnicka H., 2002, *Obliczenia ewolucyjne*, Prace Naukowe Wydziałowego Zakładu Informatyki Politechniki Wrocławskiej, Zeszyt Sztuczna Inteligencja nr 1.
- Li H., Li V., 1996, *Forecasting house rental levels: Analytical rent model versus neural network*, Journal of Urban Planning & Development, Vol. 122 Issue 4, s. 118–127.
- Lula P., 1999, *Jednokierunkowe sieci neuronowe w modelowaniu zjawisk ekonomicznych*, Wydawnictwo Akademii Ekonomicznej w Krakowie.
- Rutkowska D., Piliński M., Rutkowski L., 1999, *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, Wydawnictwo Naukowe PWN, Warszawa.

- Tadeusiewicz R., 1998, *Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami*, Akademicka Oficyna Wydawnicza PLJ.
- Tan C.N.W., 1999, *A Hybrid Financial Trading System Incorporating Chaos Theory*, [w:] *Statistical and Artificial Intelligence/Soft Computing Methods*, Invited Paper – Queensland Finance Conference.
- Witkowska D., 2002, *Sztuczne sieci neuronowe i metody statystyczne. Wybrane zagadnienia finansowe*, C.H. BECK.
- Worzala E., Lenk M., Silva A., 1995, *An exploration of neural networks and its application to real estate valuation. The Journal of Real Estate Research 10*, s. 185–201.
- Yao J., Li Y., Tan C.L., 2000, *Option price forecasting using neural networks* [w:] *Omega 28*, s. 455–466.

Streszczenie

Praca opisuje możliwości zastosowania sztucznej inteligencji w przedsiębiorstwach sektora MSP. Szczególny nacisk położony został na sztuczne sieci neuronowe, algorytmy genetyczne oraz struktury ewolucyjne. Opisane zostały m.in. takie mechanizmy wspomagające omówione narzędzia, jak np. dyskretna transformata falkowa, czy też analiza danych przy użyciu okna czasowego.

Artificial Intelligence in SME

Summary

The paper describes an ability to employ artificial intelligence in enterprises of SME sector. The paper focuses on artificial neural networks, genetics algorithms and evolutionary strategies. There are described the mechanisms supporting the aforementioned techniques, such as a discreet wavelet transform or a data analysis by the employment of a sliding window.