

Analiza możliwości zastosowania sieci neuronowych do modelowania wartości kapitału społecznego w firmach IT

Julia Siderska

Politechnika Białostocka, Wydział Zarządzania, e-mail: j.siderska@pb.edu.pl

Streszczenie

Celem artykułu jest przeanalizowanie możliwości zastosowania sztucznej sieci neuronowej do modelowania wartości kapitału społecznego w przedsiębiorstwach z sektora IT. Dane do badań zostały zaczerpnięte z bilansów finansowych publikowanych przez firmę Prokom Software SA i Asseco Poland SA na koniec każdego kwartału w latach 2005-2009. Niezbędnych obliczeń wartości kapitału społecznego firm dokonano z wykorzystaniem równania fundamentalnego. Uczenie sztucznej sieci neuronowej przeprowadzono w generatorze *Statistica Neural Network 10.0*. Badania pozwoliły na opracowanie szkieletu modelu odzwierciedlającego zależności pomiędzy zmiennymi wejściowymi (objaśniającymi), a zmienną wyjściową (objaśnianą), czyli wartością kapitału społecznego.

Słowa kluczowe

sztuczna sieć neuronowa, uczenie sieci neuronowej, kapitał społeczny

Wstęp

Narzędzia sztucznej inteligencji, w tym przede wszystkim sztuczne sieci neuronowe, są coraz powszechniej stosowane nie tylko w obszarach nauk technicznych (rozpoznawanie obrazów, przetwarzanie sygnałów, sterowanie, optymalizacja), ale i w ekonomii oraz zarządzaniu. Modele sieci neuronowych są często wykorzystywane w predykcji zjawisk ekonomicznych, np. przy przewidywaniu trendów na giełdzie, prognozowaniu sprzedaży, cen, określaniu ryzyka związanego z udzieleniem kredytu. Sztuczne sieci neuronowe należą do metod analizy danych o bardzo dużych możliwościach aplikacyjnych i są coraz powszechniej stosowane alterna-

tywnie do tradycyjnych metod analitycznych, zapewniając bardziej rzetelne wyniki.

Zasadniczym celem pracy jest wstępna ocena możliwości zastosowania sztucznej sieci neuronowej do modelowania wartości kapitału społecznego wybranych firm informatycznych. Przedmiotem zainteresowań naukowych autorki jest szeroko rozumiany rynek teleinformatyczny w Polsce i na świecie. W artykule przedstawione zostały wyniki badań przeprowadzonych dla firmy Prokom Software SA oraz Asseco Poland SA.

Zadaniem badawczym jest opracowanie szkieletu modelu pozwalającego na odzwierciedlenie istniejących w rzeczywistości zależności pomiędzy zmiennymi wejściowymi (objaśniającymi) a zmienną wyjściową (objaśnianą), czyli wartością kapitału społecznego. Wiedza taka, dzięki zdolności sieci neuronowej do generalizacji danych, może być uogólniana na nowe przypadki, które nie były prezentowane sieci podczas procesu uczenia.

1. Przegląd literatury

Przeprowadzone badania mają charakter interdyscyplinarny - dotyczą zarówno analizy systemowej firm teleinformatycznych i analizy wartości kapitału społecznego tych przedsiębiorstw, jak i możliwości zastosowania metod sztucznej inteligencji, czyli narzędzi informatycznych do modelowania i szacowania aktywów niematerialnych, powszechnie uważanych za niemierzalne.

W literaturze przedmiotu dyskusja na temat kapitału ludzkiego i społecznego w naukach społecznych jest w ostatnich latach bardzo ożywiona. Z roku na rok przybywa publikacji na ten temat, a w części z nich proponuje się nowe definicje stosowanych pojęć. Pojęcie „kapitał ludzki” należy do kanonu słownictwa ekonomicznego od drugiej połowy XX wieku (Łukasiewicz, 2009), przede wszystkim za sprawą takich naukowców, jak: T.W. Schultz, J.Mincer czy G.S. Becker. Termin „kapitał społeczny” funkcjonuje w naukach społecznych od niespełna wieku. Rozpowszechniony został między innymi dzięki pracom F. Fukuyamy, który uważał, że *kapitał społeczny to zestaw wartości i norm etycznych wspólnych dla określonej grupy ludzi i umożliwiających im skuteczne współdziałanie* (Fukuyama, 2003). W tym opracowaniu termin kapitał ludzki rozumiany jest jako talent, doświadczenie, kompetencje pracowników. Z kolei kapitał społeczny definiowany jest jako wszystkie relacje formalne i nieformalne pomiędzy nimi, a więc zaufanie, umiejętność współpracy. Można to wyjaśnić na przykładzie firmy Microsoft, światowego lidera w sprzedaży oprogramowania. Microsoft zatrudnia tysiące wybitnych programistów, inżynierów oprogramowania, testerów wraz z ich wiedzą,

talentem, umiejętnością programowania, co stanowi bardzo istotny zasób tego przedsiębiorstwa. Oprogramowanie powstaje dzięki wspólnej, twórczej pracy tych programistów. Kapitał ludzki każdego z nich, czyli ich wiedza informatyczna, talent, znajomość języków programowania, doświadczenie tworzą łącznie kapitał społeczny całej firmy. W tej pracy skupiono się wyłącznie na modelowaniu wartości kapitału społecznego.

Pojawienie się tych nowych czynników, wpływających na wartość giełdową przedsiębiorstw, spowodowało konieczność opracowania metod ich analizy i sposobów pomiaru ich wartości. Narzędzi do szacowania wartości niematerialnych, czyli kapitału ludzkiego i społecznego w firmach jest wiele. Znaczna ich część bazuje na bilansach finansowych publikowanych przez jednostki na koniec każdego kwartału. Jak dotąd nie opracowano jednak jednej, powszechnie akceptowalnej metody do wyznaczania wartości kapitału ludzkiego i społecznego w firmach.

Do najbardziej znanych i najpowszechniej stosowanych metod i technik analizy wartości przedsiębiorstwa należą: klasyczne mierniki oceny wartości (stopy zwrotu, mnożniki rynkowe, wskaźniki wykorzystania majątku), pieniężne mierniki analizy wartości (np. rachunek wolnych przepływów pieniężnych FCF) czy też ekonomiczno - rynkowe sposoby pomiarów wartości przedsiębiorstwa (np. ekonomiczna wartość dodana), (Gołębiowski, Szczepankowki 2007). Pomiaru aktywów niematerialnych w firmie można dokonać wykorzystując do tego celu także niefinansowe modele takie, jak: monitor aktywów niematerialnych K. Sveiby'ego; czy też zrównoważoną kartę wyników R. Kaplana i D. Nortona czy Nawigator Skandii L. Edvinssona (Edvinsson i Malone, 2001). Oszacowanie wartości kapitału społecznego z zastosowaniem opracowanych dotąd narzędzi, zwłaszcza tych bazujących na bilansach finansowych, jest zadaniem pracochłonnym i czasochłonnym. Dlatego też, zdaniem autorki, interesujące oraz ważne może być zastosowanie obliczeń inteligentnych do modelowania i analizy wartości aktywów niematerialnych firm.

Historyczną pracą, w której po raz pierwszy zaprezentowano matematyczny opis komórki nerwowej i powiązano go z problemem przetwarzania danych była praca S.W. McCulloch'a - amerykańskiego neurofizjologia i cybernetyka (McCulloch, 1943). Zauważono wówczas, że bardzo istotną własnością sieci neuronowych jest ich zdolność do równoległego przetwarzania informacji (w odróżnieniu od szeregowej pracy komputera), a za podstawową zaletę sieci uznano jej umiejętności uczenia się, co jest lepszą alternatywą w stosunku do tradycyjnego programowania (Tadeusiewicz, 1993).

Dokonując przeglądu literatury zauważono, że do tej pory nie zaproponowano modelu, wykorzystującego sztuczną sieć neuronową, do modelowania wartości kapitału społecznego firmy oraz analizy zmiennych istotnie wpływających na jego

wielkość. W niniejszej pracy podjęto próbę opracowania struktury sieci neuronowej do modelowania wartości kapitału społecznego firm informatycznych oraz pozwalającej na wskazanie i analizę zmiennych istotnie wpływających na jego wartość. Zaproponowany model umożliwi usprawnienie obliczeń oraz skróci czas niezbędny do dokonania takich szacunków.

2. Metoda badań

2.1. Charakterystyka problemu badawczego

Niezbędnych obliczeń wartości kapitału społecznego dokonano za pomocą równania fundamentalnego sformułowanego przez Walukiewicza w 2006 roku. Jako zmienne wejściowe przyjęto siedem wielkości charakterystycznych: wartość księgową, wartość giełdowa, liczba akcji, cena akcji, zatrudnienie, aktywa razem oraz zobowiązania. Zmienna wyjściowa reprezentuje wartość kapitału społecznego. Zbiór danych uczących obejmuje informacje dotyczące 23 kwartałów dwóch firm teleinformatycznych - Prokom Software SA oraz Asseco Poland SA. Dane do badań zaczerpnięto z bilansów księgowych publikowanych na koniec każdego kwartału.

Do symulacji wykorzystano generator *Statistica Neural Networks 10.0*. Dla uproszczenia wybrano zmienne wejściowe o charakterze ilościowym. W przypadku konieczności wprowadzenia zmiennej jakościowej, konieczne byłoby przekształcenie jej wartości do postaci numerycznej, czyli dogodnej do przetworzenia przez sieć neuronową (np. przy zastosowaniu metody *jeden-z-N*, w której każdej wartości zmiennej przyporządkowuje się wektor wartości binarnych).


Wstępna ocena możliwości zastosowania sztucznych sieci neuronowych do analizy i modelowania wartości kapitału społecznego możliwa będzie dzięki wykorzystaniu sieci neuronowej jako instrumentu do rozwiązywania problemu regresyjnego. Założono, że zależności pomiędzy zmiennymi mają charakter nieliniowy, zatem zastosowanie do analizy klasycznych modeli liniowych nie ma uzasadnienia. Tradycyjna regresja liniowa, służąca estymowaniu wartości oczekiwanej zmiennej objaśnianej, wykorzystana może być tylko do analizowania danych powiązanych liniowo. W artykule postawiono hipotezę, że sztuczne sieci neuronowe rozwiązują problem nieliniowości danych istotnie wpływających na wartość kapitału społecznego firm teleinformatycznych.

Na proces budowy modelu regresyjnego składają się następujące etapy:

- określenie charakteru zmiennych;
- wybór typu i określenie struktury sieci neuronowej;

- uczenie sieci neuronowej;
- ocena modelu sieci.

Model powinien odzwierciedlać istniejące w rzeczywistości powiązania pomiędzy zestawem zmiennych wejściowych (objaśniających), a zestawem zmiennych objaśnianych (wyjściowych). W większości przypadków (metod) przyjmuje się istnienie pojedynczej zmiennej objaśnianej przedstawionej na rys. 1.



Rys. 1. Uproszczony schemat przetwarzania sygnałów wejściowych przez sztuczną sieć neuronową

Źródło: opracowanie własne.

Celem badania jest także nauczenie sieci wzorców zależności, które mogłyby być w przyszłości generalizowane, czyli uogólniane na nowe przypadki, które nie były prezentowane sieci podczas jej trenowania.

2.2. Budowa modelu regresyjnego

W warstwie wejściowej analizowanej sieci jest 7 neuronów, gdyż założono, że taka jest liczba zmiennych wejściowych wpływających na zmienną wyjściową. Modelowanie wartości kapitału społecznego jest problemem regresyjnym, stąd na wyjściu znajduje się tylko jeden neuron, charakteryzujący zmienną objaśnianą.

Analizie poddane zostały następujące zmienne wejściowe (objaśniające):

- liczba akcji - zmienna ilościowa [szt.];
- cena akcji - zmienna ilościowa [PLN];
- wartość giełdowa - zmienna ilościowa [PLN], obliczona jako iloczyn liczby akcji będących w obrocie i ceny jednej akcji na zamknięciu kwartału;
- wartość księgową - zmienna ilościowa [PLN], obliczona jako różnica pomiędzy sumą wszystkich aktywów, a sumą zobowiązań;
- aktywa - zmienna ilościowa [PLN];
- zobowiązania - zmienna ilościowa [PLN];
- zatrudnienie - zmienna ilościowa [szt.], rozumiana jako liczba pracowników w całej Grupie Kapitałowej.

Zmienna objaśniana (wyjściowa), czyli wartość kapitału społecznego, została obliczona na podstawie danych finansowych zawartych w bilansach księgowych publikowanych przez obie analizowane firmy na koniec każdego kwartału w okre-

sie 2005 - 2009. Do obliczeń zastosowano równanie fundamentalne (Walukiewicz, 2006). Istota równania fundamentalnego oraz szczegółowa procedura wyznaczania wartości kapitału społecznego firmy Prokom Software SA z zastosowaniem tego narzędzia została obszernie opisana w pracy (Siderska, 2011).

Dane dotyczące poszczególnych kwartałów zawarto w jednym wierszu. W tabeli 1 przedstawiono przykładowe dane dla firmy Asseco Poland SA charakteryzujące siedem zmiennych wejściowych oraz wartość zmiennej wyjściowej (kapitału społecznego) w pierwszym kwartale 2009 roku.

Tabela 1. Wartości danych wejściowych i kapitału społecznego w firmie Asseco w I kwartale 2009 roku

Liczba akcji	Cena akcji [PLN]	Wartość giełdowa [tys. PLN]	Wartość księgowa [tys. PLN]	Aktywa razem [tys. PLN]	Zobowiązania [tys. PLN]	Zatrudnienie	Kapitał społeczny [tys. PLN]
x1	x2	x3	x4	x5	x6	x7	
77 565 530	62,95	4 882 750	3 517 463	4 153 060	635 597	8 066	1 891 896

Źródło: opracowanie własne.

Warto podkreślić, że Asseco Poland SA to największa spółka informatyczna notowana na Giełdzie Papierów Wartościowych w Warszawie, specjalizująca się w produkcji i rozwoju oprogramowania oraz kompleksowych systemów informatycznych dla większości sektorów gospodarki. W prestiżowym rankingu stu największych europejskich firm informatycznych „Truffle 100” w 2012 Asseco Poland SA znalazło się na 7 pozycji z przychodami ze sprzedaży software’u na poziomie 866,2 mln PLN (Ranking Truffle 2012). Firma Prokom Software SA, założona przez Ryszarda Krauzego, zajmującą się m. in. informatyzacją ZUS-u, została w 2008 roku połączona z Asseco Poland SA poprzez przeniesienie całego majątku. Była to jedna z największych fuzji krajowych firm. Spółki, których papiery wartościowe są dopuszczone do obrotu na rynku regulowanym na GPW mają obowiązek publikowania na koniec każdego kwartału sprawozdań finansowych sporządzonych zgodnie z Międzynarodowymi Standardami Sprawozdawczości Finansowej (MSSF).

Celem badawczym jest zbudowanie sieci zdolnej do generalizacji, czyli do oddawania charakteru zależności. Sieć powinna dobrze działać na zbiorze danych, który nie był poddany uczeniu. Aby zwiększyć zdolność sieci do takiego uogólniania danych zbiorów uczący podzielono na:

- zbiór testowy (monitorowanie procesu uczenia epoka po epoce), do którego trafiło 70% wszystkich przypadków;

- zbiór walidacyjny (ocena sieci po zakończeniu uczenia), do którego trafiło 15% wszystkich przypadków;
- zbiór uczący (oszacowanie wag), do którego trafiło 15% wszystkich przypadków.

2.3. Uczenie sieci neuronowej

Niewątpliwie zasadniczym czynnikiem determinującym działanie sieci jest jej uczenie, a nie sama jej struktura. Głównym sposobem korzystania z sieci neuronowej jest tworzenie modeli, czyli sformalizowanej struktury, odwzorowującej pewien proces, czy zjawisko. Sieć neuronowa może być znakomitym modelem dowolnego systemu. Proces uczenia jest procesem iteracyjnym, powtarzanym wielokrotnie, krok po kroku, którego zasadniczym celem jest optymalizacja parametrów sieci, tj. współczynników wagowych. Każda ze zmiennych wprowadzanych na wejściu sieci początkowo dostaje losowo przydzieloną wagę, czyli siłę jej wpływu na wartość zmiennej wyjściowej. Wartości współczynników wagowych ustalane są w procesie uczenia, co stanowi właśnie źródło wiedzy, inteligencji neuronu. Im większa jest wartość wagi, tym dana zmienna jest istotniejsza (Lula i in., 2007).

W analizowanym przypadku zastosowano uczenie z nauczycielem (z nadzorem). Ten rodzaj trenowania wyróżnia się tym, że sieci podawane są przykłady poprawnego działania, które powinny być przez nią naśladowane. Należy wskazać zatem, oprócz sygnałów wejściowych, również pożądane (oczekiwane) na nie odpowiedzi, czyli sygnał wyjściowy. Sieć jest uczona poprzez wiedzę na temat wartości kapitału społecznego konkretnego przedsiębiorstwa (Lula i in., 2007).

Fundamentalne znaczenie w procesie trenowania sieci ma zatem taki dobór współczynników wagowych poszczególnych zmiennych wejściowych, aby błędy na wyjściu były jak najmniejsze. Sieć ustawia wagi zerowe dla nieistotnych zmiennych wejściowych. Uczenie sieci jest więc procesem mającym na celu estymację optymalnych wartości wag.

Przetwarzanie informacji przez sieć neuronową oraz powodzenie tego procesu jest uzależnione od struktury sieci, która do rozwiązywania różnych problemów powinna być za każdym razem dobierana indywidualnie i na nowo. Można się przy tym oprzeć na intuicji i doświadczeniu lub bazować na procedurach automatycznych.

Do budowy modelu przyjęto założenia:

- zależności zaobserwowane w zbiorze danych będą miały taki sam charakter podczas późniejszego stosowania sieci,
- w modelu zawarto zmienne wpływające na analizowane zjawisko.


Parametry sieci, czyli wartości wag i wartości progowe neuronów, dobrano w sposób pozwalający na minimalizację funkcji błędu sieci. W tym celu zastosowano odpowiedni algorytm uczenia, który umożliwił automatyczną modyfikację wspomnianej wartości, w oparciu o dane wejściowe i odpowiadające im prawidłowe rozwiązania.

Trenowanie zbudowanego modelu sieci przeprowadzono metodą wstecznej propagacji błędów (ang. *backpropagation*), będącą najczęściej stosowanym i jednym z najskuteczniejszych algorytmów uczenia wielowarstwowej sieci neuronowej. Jego istota opierała się na minimalizacji sumy kwadratów błędów uczenia sieci. Błędy, powstałe na wyjściu sieci, są propagowane w kierunku odwrotnym niż przechodzenie sygnałów przez sieć, czyli od warstwy wyjściowej do wejściowej (Rutkowska i in., 1997).

3. Wyniki badań

Przed wyborem ostatecznej budowy sieci neuronowej testowano wiele modeli różniących się liczbą neuronów w warstwie ukrytej, rodzajami funkcji aktywacji, algorytmami uczenia. Analizowany problem nie jest na tyle skomplikowany, by do jego rozwiązania konieczne było zastosowanie dwóch warstw ukrytych. Poza tym generator STATISTICA umożliwia zaimplementowanie tylko jednej warstwy ukrytej, zatem ten parametr nie podlegał analizom. Dobór liczby neuronów w warstwie ukrytej jest istotną kwestią - ich nadmiar może spowodować, że sieć nauczy się zależności na pamięć, ich niedobór z kolei może pozbawić sieć zdolności do uczenia się. Ostatecznie jako funkcje aktywacji zastosowano: tangens hiperboliczny w warstwie ukrytej oraz funkcję liniową w warstwie wyjściowej. Taki wybór nie pozwolił na stratę przez sieć zdolności predykcji, poprawił natomiast jej zdolność do ekstrapolacji wyników.

W wyniku przeprowadzonego procesu uczenia otrzymano model sieci neuronowej typu MLP 7-3-1 (Multi-Layer Perceptron, zwany perceptronem wielowarstwowym). Opracowany model posiada strukturę złożoną z siedmiu neuronów w warstwie wejściowej, trzech neuronów w warstwie ukrytej oraz jednego neuronu w warstwie wyjściowej (rys. 3). Pojedynczy neuron na wyjściu sieci odzwierciedla wartość kapitału społecznego.



Rys 3. Model zbudowanej sieci MLP 7-3-1

Źródło: opracowanie własne.

Modelowaną sieć charakteryzują następujące parametry jakości:

- 0,98 - dla zbioru uczącego;
- 0,99 - dla zbioru testowego;
- 0,98 - dla zbioru walidacyjnego.

Jakości te wyrażone są za pomocą współczynników korelacji Pearsona pomiędzy wartościami oczekiwanymi a prognozą sieci, zatem korelacja liniowa jest rzędu 98% w zbiorze uczącym. Oceną jakości sieci jest jej zdolność do generalizacji, zatem tą miarą jest jakość na próbie walidacyjnej, czyli na danych nowych, które nie były poddane procesowi uczenia. Podsumowanie parametrów otrzymanego trójwarstwowego perceptronu zaprezentowano w tabeli 2.

Tabela 2. Parametry charakteryzujące zbudowaną sieć neuronową

Nazwa sieci	Funkcja aktywacji (neurony ukryte)	Funkcja aktywacji (neurony wyjściowe)	Błąd sieci	Algorytm uczenia
MLP 7-3-1	Tangesoidalna	Liniowa	Suma kwadratów (SOS)	BFGS (oparty na metodzie gradientowej drugiego rzędu)

Źródło: opracowanie własne.

Dane pozwalające na porównanie wyników wartości kapitału społecznego oszacowanego za pomocą równania fundamentalnego oraz z wykorzystaniem zbudowanego modelu, czyli sztucznej sieci neuronowej MLP 7-3-1 zebrano w tabeli 3. Do tego celu zastosowano funkcję: *przewidywania dla nowych danych*. Dane te nie

znajdowały się w zbiorze uczącym, zatem nie były poddane trenowaniu. Wielkość kapitału społecznego została podana przez nauczoną zależność sieć neuronową (ostatnia kolumna). Takie oszacowanie możliwe było dzięki zdolności zbudowanego modelu do generalizacji danych.

Tabela 3. Wartość kapitału społecznego w firmie Asseco w I kwartale 2010 roku

Liczba akcji	Cena akcji [PLN]	Wartość giełdowa [tys. PLN]	Wartość księgowa [tys. PLN]	Aktywa razem [tys. PLN]	Zobowiązania [tys. PLN]	Zatrudnienie	Kapitał społeczny [tys. PLN] ^a	Kapitał społeczny [tys. PLN] (MLP 7-3-1)
x1	x2	x3	x4	x5	x6	x7	y	Y
77 565 530	56,8	4 405 722	3 629 250	4 360 132	730 882	7 990	2 275 764	1 819 458

^a - równanie fundamentalne

Źródło: opracowanie własne.

Jak pokazano w tabeli 3, wartość kapitału społecznego, wyznaczona z zastosowaniem zbudowanego modelu sieci neuronowej MLP 7-3-1, jest mniejsza o około 20% w stosunku do wartości obliczonej za pomocą równania fundamentalnego. Różnica jest dosyć istotna, więc zasadne jest podjęcie próby poprawy jakości sieci. Kolejne badania dotyczyć będą porównania otrzymanych wyników dla sieci MLP z wynikami dla sieci o radialnych funkcjach bazowych (RBF). Zbiór uczący zostanie rozszerzony o nowe przypadki, czyli dane wejściowe z okresu 2010-2012, co być może poprawi zdolność sieci do generalizacji danych.

4. Dyskusja wyników

Istotną charakterystyką zbudowanej sieci neuronowej jest także globalna analiza wrażliwości, za pomocą której można *post factum* ocenić słuszność wyboru poszczególnych zmiennych oraz określić w jaki sposób zmieni się jakość modelu po wyłączeniu jednej ze zmiennych. Wyniki analizy wrażliwości interpretuje się w ten sposób, że gdy jej wartość dla danej zmiennej wynosi ponad 1, to usunięcie tej zmiennej ze zbioru uczącego może spowodować pogorszenie jakości modelu i odwrotnie: wartości powyżej 1 informują nas, że usunięcie tej zmiennej może pogorszyć jakość modelu. Globalna analiza wrażliwości dla wybranych zmiennych (w próbie uczącej) jest następująca: wartość giełdowa (9,65), liczba akcji (6,41), zobowiązania (3,0). Żadna z analizowanych zmiennych nie uzyskała wartości glo-

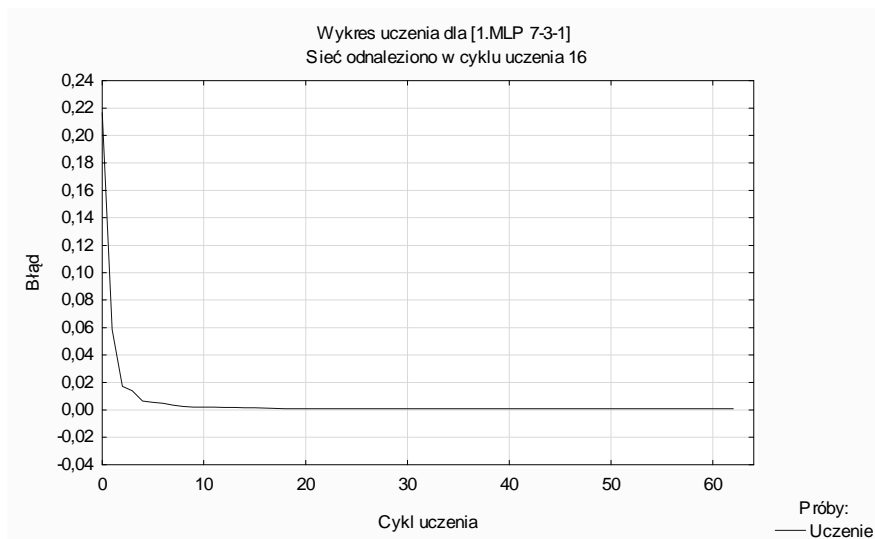
balnej analizy wrażliwości poniżej 1, co sugeruje dosyć istotny wpływ każdej z nich na zmienną wyjściową, czyli wartość kapitału społecznego. Tabela 4 zawiera podsumowanie wartości globalnej analizy wrażliwości dla wszystkich siedmiu badanych zmiennych. Jak widać zmienną, która w najistotniejszy sposób wpływa na wartość kapitału społecznego badanych firm jest wartość giełdowa.

Tabela 4. Wartości globalnej analizy wrażliwości dla analizowanych zmiennych

	Liczba akcji	Cena akcji	Wartość giełdowa	Wartość księgowa	Aktywa razem	Zobowiązania	Zatrudnienie
Globalna analiza wrażliwości	6,41	1,13	9,65	1,40	1,14	3,0	1,37

Źródło: opracowanie własne.

Dokonano także graficznej prezentacji i analizy wyników sieci. Pomocnym raportem jest wykres przedstawiający wartości zmiennej zależnej w odniesieniu do przewidywań sieci (rys. 4). Z wykresu wywnioskowano, iż sieć jest dosyć dobrze dopasowana do analizowanego problemu. Wykres nie wykazuje znaczących błędów w działaniu sieci.



Rys. 4. Wykres błędów uczenia w próbie uczącej

Źródło: opracowanie własne.

Potrzeba było 16 epok uczenia (szesnastokrotna prezentacja wszystkich elementów zbioru uczącego), aby proces uczenia osiągnął zbieżność, czyli, aby błąd dla próby uczącej osiągnął swoje minimum. Każdy kolejny cykl uczenia nie zmienił poziomu błędu sieci. Ponadto zauważmy, że kształt wykresu błędu dla próby uczącej jest prawidłowy - błąd gwałtownie maleje na początku, potem łagodnie zmierza do zera.

Zbudowany model jest modelem nieparametrycznym, w którym współczynniki wagowe wyznaczone przez sieć podczas estymacji nie podlegają interpretacji (przy regresji każdy współczynnik β ma swoją interpretację).

Podsumowanie

Zbudowany model, dzięki zdolności sieci do generalizowania (uogólniania) danych, może znaleźć zastosowanie do predykcji wartości kapitału społecznego firmy dla danych całkowicie nowych, które nie należały do zbioru uczącego podczas procesu uczenia. Po wprowadzeniu nowych wielkości charakteryzujących siedem zmiennych wejściowych sieć podaje wartość wyjściową, czyli prognozowaną wartość kapitału społecznego, która przewidziana zostanie na podstawie nauczonych wcześniej zależności. Wyniki symulacji obliczeń wartości kapitału społecznego dla nowych danych (I kwartał 2010 roku) zostały przedstawione w tabeli 3.

Analizie poddano dane dotyczące dwóch polskich przedsiębiorstw z branży IT, czyli Prokom Software SA, do 2008 roku największej spółki informatycznej w Polsce oraz Asseco Poland SA - lidera na rynku IT w Polsce. Sieci neuronowe wykazują się dużą zdolnością do generalizacji danych, czyli potrafią uogólniać wyniki na nowe dane, które nie znajdowały się w zbiorze uczącym, na którym sieć była trenowana. Można zatem przypuszczać, że zbudowany model będzie użyteczny do analizy i modelowania wartości kapitału społecznego przedsiębiorstw działających w innych sektorach gospodarki.

Kolejne badania dotyczyć będą analizy możliwości zastosowania zbudowanego modelu sieci neuronowej dla największych na świecie przedsiębiorstw z branży technologii informacyjnych: Microsoft, IBM, Oracle, Novell. Przedmiotem zainteresowań autorki jest także rynek oprogramowania *open source*, zatem podobne badania przeprowadzone zostaną dla firmy Red Hat - światowego lidera w dostarczaniu rozwiązań otwartych do biznesu, producenta jednej z najbardziej znanych dystrybucji otwartego systemu operacyjnego - Red Hat Linux.

Obszary zastosowań sieci neuronowych ulegają rozszerzaniu, ponieważ mogą być one z powodzeniem używane wszędzie tam, gdzie do rozwiązania są problemy

wymagające przetwarzania i analizy danych, ich predykcji, czy klasyfikacji. Popularność i powodzenie stosowania sieci neuronowych spowodowane jest ich licznymi zaletami. Spośród wszystkich niewątpliwie najważniejszą jest, zdaniem autorki, ich zdolność do odwzorowywania bardzo złożonych, nieliniowych zależności pomiędzy sygnałami wejściowymi, a sygnałem wyjściowym. Sieć neuronowa to model oparty na danych, a nie na wiedzy analityka, zatem przystępując do pracy nad budową modelu sieci neuronowej nie trzeba znać charakteru zależności pomiędzy danymi znajdującymi się w zbiorze uczącym. Nie bez znaczenia jest również fakt, że sieci neuronowe pozwalają na przetwarzanie danych rozmytych, a nawet niekompletnych w sposób równoległy i rozproszony. Proces uczenia sieci jest też stosunkowo szybki i prosty. Zastosowanie sieci neuronowej do rozwiązywania problemu regresyjnego może być zatem metodą zastępczą, alternatywą, np. dla regresji wielorakiej.

Literatura

1. Edvinsson L., Malone M.S. (2001), *Kapitał intelektualny. Poznaj prawdziwą wartość swojego przedsiębiorstwa odnajdując jego ukryte korzenie*, Wydawnictwo Naukowe PWN, Warszawa
2. Fukuyama F. (2003), *Kapitał społeczny*, w: Harrison L.E., Huntington S. P. (red.), *Kultura ma znaczenie*, Zysk i S-ka, Kraków
3. Gołębiowski G., Szczepankowki P. (2007), *Analiza wartości przedsiębiorstwa*, Difin, Warszawa
4. Lula P., Paliwoda - Pękosz G., Tadeusiewicz R. (2007), *Metody sztucznej inteligencji i ich zastosowania w ekonomii i zarządzaniu*, Akademicka Ekonomiczna, Kraków
5. Łukasiewicz G. (2009), *Kapitał ludzki organizacji. Pomiar i sprawozdawczość*, PWN, Warszawa
6. McCulloch W.S. (1943), *A Logical Calculus of the Ideas Immanent in Nervous Activity*, Bulletin of Mathematical Biophysics 5
7. Ranking Truffle 100, <http://www.truffle100.com/2012/ranking.php>, [18.01.2013]
8. Rutkowska D., Piliński M., Rutkowski L. (1997), *Sztuczne sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, Wydawnictwo Naukowe PWN, Warszawa
9. Siderska J. (2011), *Wstępna ocena roli wartości niematerialnych w firmie Prokom*, w: Hołubiec J. (red.), *Techniki informacyjne - teoria i zastosowania*, t. 1, Instytut Badań Systemowych PAN, Warszawa
10. Tadeusiewicz R. (1993), *Sieci neuronowe*, Akademicka Oficyna Wydawnicza, Warszawa

11. Vachik S. D., Dutta K. (2011), *Comparison of Regression model, Feed-forward Neural Network and Radial Basis Neural Network for Software Development Effort Estimation*, ACM SIGSOFT Software Engineering Notes 36 (5)
12. Walukiewicz S. (2006), *Systems analysis of social capital at the firm level*, Working Paper WP-1-2006, System Research Institute of the Polish Academy of Science, Warsaw
13. Walukiewicz S. (2007), *Four forms of capital and proximity*, Working Paper WP-3-2007, System Research Institute of the Polish Academy of Science, Warsaw
14. Walukiewicz S. (2010), *Kapitał ludzki*, Instytut Badań Systemowych PAN, Warszawa

Analysis of the possibilities of using artificial neural networks to model social capital values in IT companies

Abstract

The purpose of this article is to analyze the possibility of using an artificial neural network to model the value of social capital in companies from IT market. Training data were collected and calculated on the basis of financial report published quarterly by Prokom Software SA and Asseco Poland SA. The values of social capital in those companies were calculated by Fundamental Equation. The artificial neural network had been trained in STATISTICA Automated Neural Network 10.0 (SANN). The research contributed to developing the draft of the model for estimating the relationships among seven input variables and output variable, i.e. the value of social capital.

Keywords

artificial neural network, neural network training, social capital