


Pomiar wartości kapitału społecznego z wykorzystaniem sztucznych sieci neuronowych

JULIA SIDERSKA



Julia Siderska

**POMIAR WARTOŚCI
KAPITAŁU SPOŁECZNEGO
Z WYKORZYSTANIEM
SZTUCZNYCH SIECI NEURONOWYCH**



OFICyna WYDAWNICZA POLITECHNIKI BIAŁOSTOCKIEJ
BIAŁYSTOK 2021

Recenzenci:
prof. dr hab. inż. Stanisław Skowron
prof. dr hab. inż. Stanisław Walukiewicz

Redaktor naukowy dyscypliny nauki o zarządzaniu i jakości:
prof. dr hab. inż. Joanicjusz Nazarko

Redakcja i korekta językowa:
Natalia Popławska

Skład, grafika:
Oficina Wydawnicza Politechniki Białostockiej

Okładka:
Marcin Dominów

Zdjęcie na okładce: GDJ
<https://pixabay.com/pl/vectors/m%c3%b3zg-umys%c5%82-my%c5%9b%c4%85cy-a-i-ai-2789698/>

© Copyright by Politechnika Białostocka, Białystok 2021

ISBN 978-83-67185-00-4 (eBook)
DOI: 10.24427/978-83-67185-00-4



Publikacja jest udostępniona na licencji
Creative Commons Uznanie autorstwa-Użycie niekomercyjne-Bez utworów zależnych 4.0
(CC BY-NC-ND 4.0).

Pełną treść licencji udostępniono na stronie
creativecommons.org/licenses/by-nc-nd/4.0/legalcode.pl.
Publikacja jest dostępna w Internecie na stronie Oficyny Wydawniczej PB.

Oficina Wydawnicza Politechniki Białostockiej
ul. Wiejska 45C, 15-351 Białystok
e-mail: oficina.wydawnicza@pb.edu.pl
www.pb.edu.pl

Spis treści

Wprowadzenie	5
1. Kapitał ludzki i społeczny	13
1.1. Kapitał ludzki	13
1.2. Kapitał społeczny	18
2. Zarządzanie wartością przedsiębiorstwa informatycznego	21
2.1. Założenia zarządzania przedsiębiorstwem przez wartość	21
2.2. Pomiar wartości kapitału społecznego	23
2.3. Zasada ortogonalności i równanie fundamentalne	24
3. Sztuczne sieci neuronowe	29
3.1. Istota sztucznej inteligencji i geneza sztucznych sieci neuronowych	29
3.2. Zastosowanie sztucznych sieci neuronowych w badaniach naukowych	33
3.3. Budowa i działanie sztucznego neuronu	36
3.4. Klasyfikacja i uczenie sieci neuronowych	42
4. Budowa modelu neuronowego	48
4.1. Założenia badawcze	48
4.2. Dobór zmiennych wejściowych	51
4.3. Zbiór uczący	54
4.4. Struktura i parametry sieci neuronowej	56
5. Trenowanie sieci i zastosowanie modelu neuronowego	62
5.1. Uczenie sieci neuronowej	62
5.2. Algorytm obliczeniowy	73
6. Wyniki eksperymentów	76
6.1. Aplikacja realizująca algorytm obliczeniowy	76
6.2. Możliwości aplikacyjne modelu	79
Podsumowanie	83
Aneks	87
Załącznik 1. Kod źródłowy autorskiego programu SOCAP Neural Network	87
Literatura	95
Spis tabel	100
Spis rysunków	101

Wprowadzenie

Bill Gates, założyciel i wieloletni szef Microsoft, największego przedsiębiorstwa informatycznego na świecie, powiedział:

Zabierz moich dwudziestu najlepszych ludzi, a Microsoft stanie się firmą o marginalnym znaczeniu¹.

Jego słowa, będące myślą przewodnią tej monografii, świadczą o przekonaniu, że o sukcesie przedsiębiorstwa informatycznego² decydują przede wszystkim jego pracownicy, ich talent, predyspozycje, ambicje, umiejętność pracy w zespołach itp., czyli cechy i czynniki stanowiące wartości niematerialne tych firm. Rozwijając powyższą tezę, należy dodać, że jeszcze bardziej istotne dla powodzenia działalności organizacji na rynku są relacje formalne i nieformalne pomiędzy pracownikami różnych szczebli, ich wzajemne zaufanie, współpraca, lojalność czy umiejętność twórczego rozwiązywania problemów i konfliktów. Wpływają one na tak zwaną kulturę organizacyjną, która jest wartością bezcenną, mającą kluczowe znaczenie w budowaniu pozytywnego wizerunku i przewagi konkurencyjnej na rynku. Potencjałem nowoczesnych przedsiębiorstw działających w branży IT (ang. *Information Technology*), które w tej monografii będą określane terminem przedsiębiorstw informatycznych (lub jego synonimami), jest zatem, obok technologii informatycznych, ich kapitał ludzki i społeczny. Są to czynniki istotnie determinujące wartość giełdową (rynkową) tych podmiotów.

W powszechnym przekonaniu technologie informacyjne są motorem napędowym nowoczesnej gospodarki, a odpowiednio wykorzystany potencjał pracowników przedsiębiorstw informatycznych może pobudzić rozwój jej wszystkich sektorów. Konkurencyjność firm z branży IT powinna być zatem oparta na wiedzy, talencie, zdolnościach i innych cechach ich pracowników, czyli na kapitale ludzkim i społecznym³. Dlatego w tej monografii badany jest kapitał społeczny organizacji informatycznych.

¹ P. Bochniarz, K. Gugała, *Budowanie i pomiar kapitału ludzkiego w firmie*, Poltex, Warszawa 2005, s. 33.

² W monografii pojęcie firma i przedsiębiorstwo są traktowane synonimicznie.

³ Y. Turovets, *Intangible assets and the efficiency of manufacturing firms in the age of digitalisation: the Russian case*, „Engineering Management in Production and Services” 13(1), 2021, s. 7–26.

W literaturze przedmiotu dyskusja na temat kapitału ludzkiego i społecznego jest od wielu lat bardzo ożywiona. Z roku na rok rośnie liczba publikacji traktujących o tym zagadnieniu, a w części z nich proponuje się nowe definicje stosowanych pojęć. Termin kapitał ludzki należy do kanonu słownictwa ekonomicznego od drugiej połowy XX wieku przede wszystkim dzięki badaniom takich naukowców, jak T.W. Schultz, J. Mincer oraz G.S. Becker⁴. W literaturze przedmiotu podejmowana jest polemika dotycząca różnic w znaczeniu takich pojęć, jak wartości niematerialne, kapitał intelektualny, kapitał ludzki, kapitał społeczny. Z uwagi na panujący w piśmiennictwie krajowym i zagranicznym chaos pojęciowy w obrębie tych terminów w monografii podjęto próbę ich zdefiniowania w sposób maksymalnie precyzyjny, z podaniem definicji.

Termin „kapitał” pochodzi od łacińskiego przymiotnika *capitale*, występującego razem z rzeczownikiem *caputo* (głowa), co oznaczało w średniowieczu kwotę główną, bez odsetek. Obecnie pojęcie to jest stosowane w znacznie szerszym kontekście, a można je rozumieć jako zasób, który daje albo potencjalnie może dawać zysk, pojmowany jako różnica pomiędzy nakładami a efektami. W pracy zostanie pokazane, że istnieją tylko cztery formy kapitału: kapitał finansowy, materialny, ludzki i społeczny, które łącznie bądź oddzielnie dają rzeczywisty lub umowny zysk i tworzą wartość firm⁵.

Pojawienie się tych nowych czynników, wpływających na wartość giełdową przedsiębiorstw, spowodowało konieczność opracowania metod ich analizy i sposobów pomiaru ich wartości⁶. Badanie kapitału społecznego jest zatem ściśle związane z próbą odpowiedzi na pytanie: *ile wart jest kapitał społeczny firmy?* W monografii dokonano identyfikacji metod pozwalających na wyznaczanie wartości kapitału ludzkiego i społecznego firm. Narzędzi do szacowania wartości tych kapitałów jest wiele. Znaczna ich część bazuje na bilansach finansowych, publikowanych przez jednostki na koniec każdego kwartału. Do dziś nie ma jednak jednej, powszechnie akceptowalnej metody wyznaczania wartości kapitału ludzkiego i społecznego przedsiębiorstw, w tym firm informatycznych. Propozycja nowej metodyki oraz narzędzia informatycznego wykorzystującego obliczenia inteligentne do szacowania wartości kapitału społecznego przedsiębiorstw jest przedmiotem tej monografii.

W literaturze przedmiotu, jako najbardziej znane i najpowszechniej stosowane metody analizy wartości niematerialnych przedsiębiorstw wymienia się techniki: oparte na kapitalizacji rynkowej, kartach punktowych, bezpośrednim pomiarze kapitału społecznego (intelektualnego) itp⁷. Pomiaru aktywów niematerialnych w firmie

⁴ G. Łukasiewicz, *Kapitał ludzki organizacji: pomiar i sprawozdawczość*, Wydawnictwo Naukowe PWN, Warszawa 2009, s. 11.

⁵ S. Walukiewicz, *Kapitał ludzki*, Instytut Badań Systemowych PAN, Warszawa 2010, s. 24–25.

⁶ J. Dziwulski, S. Skowron, *Kapitał ludzki w perspektywie strategicznej i operacyjnej – aspekty metodologii badań*, „Studia i Prace Kolegium Zarządzania i Finansów” 2019, s. 35–48.

⁷ K.E. Sveiby, *The new organisational wealth. Managing and measuring knowledge – based assets*, Berret-Koehler Publishers Inc., San Francisco CA 1997, s. 195–200.

można dokonać, wykorzystując także niefinansowe modele, takie jak monitor aktywów niematerialnych K. Sveiby'ego⁸, zrównoważoną kartę wyników R. Kaplana i D. Nortona⁹ czy Nawigator Skandii L. Edvinssona¹⁰.

W monografii przyjęto założenie, że kapitał społeczny traktowany jest jak każdy inny kapitał przedsiębiorstwa (na przykład fizyczny czy finansowy), zatem szacowanie jego wartości jest niezbędnym elementem zarządzania w każdej nowoczesnej firmie, chociaż bardzo wielu autorów podkreśla trudności związane z wyceną kapitału społecznego.

Zaproponowane w literaturze narzędzia, zwłaszcza te bazujące na bilansach finansowych, powodują, że określanie wartości aktywów niematerialnych jest procesem pracochłonnym, czasochłonnym i budzi wiele metodologicznych zastrzeżeń. W związku z tym przedsiębiorstwa rzadko decydują się na rzetelne szacowanie wartości swojego kapitału społecznego. Ponadto z badań empirycznych autorki wynika, że korzystanie z opracowanych dotąd algorytmów obliczeniowych wprowadza kilka innych, istotnych trudności, do których należy zaliczyć przede wszystkim:

- potrzebę analizy wielu różnych źródeł równocześnie, na przykład bilansów finansowych przedsiębiorstw, sprawozdań giełdowych, wewnętrznych dokumentów firmy;
- konieczność wykonania pogłębionych badań i uwzględnienia specyfiki warunków gospodarki;
- brak możliwości określenia istotności poszczególnych zmiennych.

Dodatkowo należy podkreślić, że aby możliwe było zaimplementowanie tych algorytmów, wskaźnik rentowności aktywów ROA (ang. *return on assets*) przedsiębiorstwa powinien mieć wartość powyżej średniej w sektorze. W literaturze przedmiotu nie zaproponowano również narzędzi pozwalających na oszacowanie wartości niematerialnych uwzględniających specyfikę firm informatycznych. A jest to bardzo szczególna gałąź gospodarki, która rozwija się od wielu lat bardzo dynamicznie. W sektorze IT pracują ludzie kreatywni, charakteryzujący się dużym kapitałem ludzkim (talent, kreatywność itp.), którzy wspólnie budują wysoką wartość kapitału społecznego zarówno poszczególnych przedsiębiorstw, jak i całej branży informatycznej. W związku z tym narzędzie do szacowania wartości kapitału społecznego firm IT powinno być bezsprzecznie poświęcone tylko tej branży. Wśród wymienionych wad opracowanych dotąd algorytmów obliczeniowych najistotniejszą, z punktu widzenia autorki, barierą jest brak możliwości oceny istotności poszczególnych zmiennych, wpływających na wartość kapitału społecznego.

⁸ Tamże.

⁹ R.S. Kaplan, D.P. Norton, *Using the Balanced Scorecard as a Strategic Management System*, „Harvard Business Review” 1996, s. 35–61.

¹⁰ L. Edvinsson, M.S. Malone, *Intellectual Capital. The Proven Way to Establish your Company's Real Value by Measuring its Hidden Brainpower*, Harper Business, London 1997; wyd. pol. *Kapitał intelektualny. Poznaj prawdziwą wartość swojego przedsiębiorstwa, odnajdując jego ukryte korzenie*, Wydawnictwo Naukowe PWN, Warszawa 2001, s. 56.

Zidentyfikowane ograniczenia stanowiły przesłanki do podjęcia rozważań nad propozycją nowego narzędzia, które mogłoby być stosowane do tego typu pomiarów. W tej monografii autorka zaproponowała zastosowanie obliczeń inteligentnych (sztucznych sieci neuronowych) do analizy i szacowania wartości kapitału społecznego. Przedstawiona w tejże pracy metodyka pomiaru wartości kapitału społecznego przedsiębiorstw informatycznych pozwala także na ocenę istotności poszczególnych zmiennych, wpływających na wartość kapitału społecznego.

Historyczną pracą, w której po raz pierwszy zaprezentowano matematyczny opis komórki nerwowej i powiązano go z problemem przetwarzania danych, był artykuł S.W. McCullocha – amerykańskiego neurofizjologa i cybernetyka¹¹. 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 alternatywą w stosunku do tradycyjnego programowania¹². 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, na przykład w przewidywaniu trendów na giełdzie, prognozowaniu sprzedaży, cen, określaniu ryzyka związanego z udzieleniem kredytu itp. Sztuczne sieci neuronowe należą do metod analizy danych o bardzo dużych możliwościach aplikacyjnych i są w związku z tym coraz powszechniej stosowane alternatywnie do tradycyjnych metod analitycznych, zapewniając równie rzetelne wyniki.

W monografii przeprowadzono studia literaturowe systematyzujące wiedzę zarówno na temat narzędzi i metod wyznaczania wartości kapitału społecznego, jak i możliwości zaimplementowania metod szeroko rozumianej sztucznej inteligencji do tego typu obliczeń i analiz. Dokonując przeglądu literatury, zauważono, że do tej pory nie zaproponowano modelu, wykorzystującego sztuczną sieć neuronową, do szacowania wartości kapitału społecznego firmy informatycznej oraz do identyfikacji i analizy zmiennych istotnie wpływających na jego wartość. W literaturze, według wiedzy autorki, opublikowano niewiele prac, które odnoszą się do zastosowania sieci neuronowych do analizy wartości niematerialnych. Przykładem może być praca *A research on value of individual human capital of high-tech enterprises based on the BP neural network algorithm*¹³. W artykule tym omówiono propozycję wykorzystania modelu sieci neuronowej i algorytmu wstecznej propagacji błędu do oceny wartości kapitału ludzkiego inżynierów przedsiębiorstw produkcyjnych. Praca ta potwierdza istotność

¹¹ W.S. McCulloch, *A Logical Calculus of the Ideas Immanent in Nervous Activity*, „Bulletin of Mathematical Biophysics” 5, 1943, s. 115–133.

¹² R. Tadeusiewicz, *Sieci neuronowe*, Akademicka Oficyna Wydawnicza, Warszawa 1993, s. 8.

¹³ X.-F. Li, P. Zhang, *A research on value of individual human capital of high-tech enterprises based on the BP neural network algorithm*, 19th International Conference on Industrial Engineering and Engineering Management: Assistive Technology of Industrial Engineering, Springer-Verlag Berlin Heidelberg 2013, s. 71–79.


i aktualność tej tematyki, wskazuje jednak, że problematyka jest słabo rozpoznana w literaturze światowej. Ponadto artykuł ten traktuje tylko o kapitale ludzkim pojedynczych pracowników, a nie kapitale społecznym całego przedsiębiorstwa. W polskiej literaturze przedmiotu, według wiedzy autorki, brakuje oryginalnych, polemicznych publikacji w tym zakresie. Zastosowanie narzędzi sztucznej inteligencji nie było dotychczas opisywane w kontekście szacowania wartości kapitału społecznego przedsiębiorstw informatycznych i identyfikacji zmiennych istotnie determinujących taką wartość. W tej monografii podjęto próbę wypełnienia tej luki oraz zaproponowania struktury sieci neuronowej do szacowania kapitału społecznego firm informatycznych, pozwalającej na wskazanie i analizę zmiennych istotnie wpływających na jego wartość.

Z analizy piśmiennictwa wynika, że szacowanie wartości kapitału społecznego każdego przedsiębiorstwa jest procesem bardzo trudnym i żmudnym. Zaproponowana sztuczna sieć neuronowa pozwoli na skrócenie czasu potrzebnego na dokonanie obliczeń. Być może przekona to kierownictwo firm informatycznych do uwzględniania wartości kapitału społecznego, ich najważniejszego i najcenniejszego zasobu, w publikowanych przez nich co kwartał bilansach finansowych. Pomijanie w sprawozdaniach księgowych tego składnika jest dużym błędem. Już dziś w raportach finansowych publikowanych przez wszystkie zagraniczne przedsiębiorstwa, nie tylko z sektora informatycznego, zawarta jest informacja o wartości aktywów niematerialnych, marki firmy (ang. *goodwill*) i inne. Ponadto jest to bardzo cenna informacja dla inwestorów. Kształtuje się zatem wyraźna tendencja, która będzie rozwijana w przyszłości. Rekomendacje autorki powinny wspomóc i przyspieszyć rozwój tego trendu.

Zaproponowana metodyka badawcza jest nowa, dlatego należało zweryfikować jej poprawność przez zestawienie wyników uzyskanych przy jej użyciu z wynikami otrzymanymi za pomocą innego narzędzia, a mianowicie równania fundamentalnego¹⁴. W monografii dokonano porównania wyników uzyskanych za pomocą tych dwóch metod.

Charakter podjętej problematyki, przedmiot badań, a także zakres pracy oraz możliwości pozyskania informacji zdeterminowały dobór metod badawczych. Do realizacji założonych celów monografii wykorzystano elementy następujących metod: metoda analizy i krytyki piśmiennictwa, metody matematyczne i statystyczne, metoda analizy i konstrukcji logicznej, metoda badania dokumentów oraz metoda eksperymentu. Metodykę, jaką przyjęto do osiągnięcia celów badawczych, przedstawiono na rysunku 1. W rozdziale szóstym przedstawiono wyniki oszacowań wartości kapitału społecznego firm Microsoft oraz IBM z zastosowaniem równania fundamentalnego oraz zaproponowanej przez autorkę struktury sztucznej sieci neuronowej.

¹⁴ S. Walukiewicz, *Zasada ortogonalności i przykłady jej zastosowań* [w:] T. Trzaskalik (red.), *Modelowanie preferencji a ryzyko* '09, Katowice 2010, s. 279–302.



RYSUNEK 0.1. **Metodyka badań przyjęta w monografii**

ŹRÓDŁO: Opracowanie własne.

Przegląd literatury i krytyczna analiza piśmiennictwa były konieczne, aby rozpoznać stan wiedzy na temat roli kapitału społecznego w przedsiębiorstwach informatycznych oraz usystematyzować wiedzę na temat metod i narzędzi pozwalających na szacowanie jego wartości. Prace studialne zostały przeprowadzone z uwzględnieniem kluczowych pozycji książkowych i artykułów naukowych z tego zakresu. Działania te miały na celu wykazanie oryginalności podjętego w badaniach problemu oraz identyfikację luki badawczej w zagadnieniu kapitału społecznego. Metoda analizy i konstrukcji logicznej oraz metoda analizy dokumentów pozwoliły na systemową analizę rynku informatycznego w Polsce oraz na świecie. Analiza została przeprowadzona z zastosowaniem zasady: od ogółu do szczegółu, to znaczy w pierwszej

kolejności analizie poddano cały rynek informatyczny, następnie jeden z jego segmentów, to jest rynek oprogramowania. W dalszej kolejności dokonano identyfikacji przedsiębiorstw prowadzących działalność na szeroko rozumianym rynku IT oraz analizy wartości niematerialnych wybranych firm, czyli kapitału społecznego tworzego przez programistów, inżynierów oprogramowania, testerów, analityków i innych pracowników tych organizacji.

Za pomocą metod matematycznych, to jest równania fundamentalnego, dokonano oszacowania wartości kapitału społecznego wybranych przedsiębiorstw informatycznych, będącego zmienną wyjściową w zaproponowanym modelu sieci neuronowej. Metoda ta umożliwiała także pomiar wartości zmiennych wejściowych analizowanych przedsiębiorstw, stanowiących zbiór uczący niezbędny do trenowania opracowanej sztucznej sieci neuronowej. Obliczenia te wykonywane były przy użyciu arkusza kalkulacyjnego MS Excel. Metody symulacji komputerowych pozwoliły na zaprojektowanie modelu sieci neuronowej oraz wybór ostatecznej jego struktury, która gwarantuje najlepsze wyniki jakości walidacyjnej wybranej sieci. Weryfikację opracowanego modelu sztucznej sieci neuronowej przeprowadzono przy użyciu pakietu statystycznego STATISTICA (moduł Automatyczne Sieci Neuronowe). Wybór zastosowanej metodyki i narzędzi badawczych wynikał z problematyki i przedmiotu badań oraz zakresu monografii, a także możliwości pozyskania i przetworzenia informacji.

Monografia składa się z wprowadzenia, sześciu rozdziałów, podsumowania, aneksu zawierającego kod źródłowy autorskiego programu SOCAP Neural Network, spisu literatury oraz spisu tabel i rysunków.

W rozdziale pierwszym omówiono istotę oraz rolę wartości niematerialnych przedsiębiorstw informatycznych. Zaprezentowano genezę oraz twórców pojęcia kapitał ludzki i kapitał społeczny – najcenniejszych zasobów każdej firmy IT.

W rozdziale drugim omówiono założenia zarządzania przedsiębiorstwem przez wartość oraz metody i narzędzia do szacowania wartości kapitału społecznego, które dotychczas zostały zaproponowane w literaturze. Dodatkowo w tej części monografii zaprezentowano zasadę ortogonalności oraz wyjaśniono równanie fundamentalne, które stanowi uzasadnienie zaproponowanej metodyki i narzędzia do szacowania wartości kapitału społecznego firmy.

W rozdziale trzecim skoncentrowano się na istocie sztucznej inteligencji i omówiono genezę rozwoju badań oraz wzrostu zainteresowania świata nauki i biznesu tą tematyką. Ponadto przedstawiono rys historyczny sieci neuronowych oraz wskazano prekursorów, którzy wnieśli istotny wkład w rozwój tych zagadnień. Przedstawiono również budowę i własności pojedynczego sztucznego neuronu oraz sposób przetwarzania informacji wejściowych w sieci neuronowej.

Rozdział czwarty zawiera opis procesu budowy modelu neuronowego. W tej części monografii omówiono założenia badawcze i środowisko do prowadzenia eksperymentów. Dodatkowo wyjaśniono sposób doboru zmiennych wejściowych do modelu, omówiono zbiór uczący oraz strukturę i parametry sieci neuronowej.

W rozdziale piątym sformułowano model teoretyczny, a następnie zastosowano go do budowy szkieletu perceptronu wielowarstwowego oraz zaprezentowano model sieci neuronowej. W tej części pracy przedstawiono także szczegóły dotyczące trenowania opracowanej sieci neuronowej. Aby nadać także użyteczny charakter zaproponowanemu przez autorkę rozwiązaniu, w rozdziale szóstym zaprezentowano założenia aplikacji realizującej algorytm obliczeniowy. Dodatkowo z uwagi na to, że zaproponowana metodyka badawcza jest nowa, istniała konieczność zweryfikowania jej poprawności poprzez zestawienie wyników uzyskanych przy jej użyciu z wynikami otrzymanymi za pomocą innego narzędzia – równania fundamentalnego. Zaprezentowano także wyniki badań symulacyjnych i eksperymentalnych, przeprowadzonych z wykorzystaniem zaproponowanego modelu sieci neuronowej dla wybranych przedsiębiorstw, takich jak Microsoft, SAP, Red Hat, Asseco i IBM.

Do monografii załączony jest kod autorskiego programu SOCAP Neural Network, napisanego w języku C++, umożliwiającego szybkie oszacowanie wartości kapitału społecznego przedsiębiorstw informatycznych.

1. Kapitał ludzki i społeczny

Najbardziej wartościowym zasobem każdego przedsiębiorstwa informatycznego są jego pracownicy: analitycy, projektanci, programiści, testerzy, inżynierowie oprogramowania i inni wysokiej klasy specjaliści opracowujący najnowsze rozwiązania informatyczne. Jest to bezsprzecznie kluczowy zasób każdej firmy prowadzącej działalność w szeroko rozumianej branży IT, zwłaszcza w sektorze oprogramowania. To właśnie pracownicy tworzą kapitał społeczny takiej organizacji. Kapitał społeczny przedsiębiorstwa jest niezwykle istotny, gdyż to właśnie pasja, zaangażowanie i zapał programistów rozwijających i budujących oprogramowanie decydują w dużej mierze o sukcesie aplikacji opracowywanych w branży IT. Proces tworzenia oprogramowania jest zatem procesem twórczym. Kapitał ludzki każdego z programistów, rozumiany jako jego talent, wiedza, doświadczenie, umiejętność programowania – to baza do budowy kapitału społecznego całego przedsiębiorstwa. Te zasoby oceniane są przez każde przedsiębiorstwo z branży informatycznej jako najcenniejsze, a zatem właściwy i rzetelny pomiar wartości takich aktywów powinien być jednym z istotnych celów badawczych szeroko rozumianego zarządzania nowoczesną firmą informatyczną.

W tym rozdziale omówiona zostanie geneza terminów „kapitał ludzki” i „kapitał społeczny” oraz podane zostaną ich definicje. Określenia kapitał ludzki oraz kapitał społeczny były używane od stuleci. W większości publikacji naukowych autorzy podają swoje definicje tych terminów, podkreślając najczęściej, że są one bardzo złożone. Wartości kapitału ludzkiego i kapitału społecznego są trudne do zmierzenia bądź oszacowania, jednak pomiar wartości niematerialnych, w tym przede wszystkim kapitału społecznego każdej firmy, jest niezbędnym.

1.1. Kapitał ludzki

Pojęcie kapitał ludzki (ang. *human capital*) wprowadzili do kanonu słownictwa ekonomicznego w drugiej połowie XX wieku: Theodore William Schultz, Jacob Mincer i Gary Stanley Becker¹⁵. Opracowali oni fundamenty teorii kapitału ludzkiego, która wciąż rozwija się w naukach społecznych. Potwierdzeniem ważności i doniosłości

¹⁵ G. Łukasiewicz, *Kapitał ludzki organizacji: pomiar i sprawozdawczość*, Wydawnictwo Naukowe PWN, Warszawa 2009, s. 11.

tej teorii jest uhonorowanie T.W. Schultza Nagrodą im. Alfreda Nobla w dziedzinie ekonomii w 1979 roku, a G.S. Beckera w 1992 roku¹⁶. Jednakże studia literaturowe dowodzą, iż zagadnienie kapitału ludzkiego było już przedmiotem rozważań naukowców dużo wcześniej. W przeszłości ekonomiści zajmowali się tą problematyką w pracach badawczych nad kształceniem, edukacją, kwalifikacjami oraz umiejętnościami i talentami, czyli nad tym, co opisywane jest jako składowe kapitału ludzkiego¹⁷.

Począwszy od XVII wieku, w sposób pośredni, przy okazji omawiania podstawowych czynników produkcji, to jest ziemi, kapitału i pracy, uwzględniano człowieka. Pierwszym ekonomistą, który zwrócił uwagę na kapitał zawierający się w pracy, jako kategorii ekonomicznej, był William Petty (1623–1687). Uważał on, że praca jest ojcem bogactwa i z tego powodu musi być brana pod uwagę¹⁸. Według niego kapitał tkwiący w człowieku charakteryzuje się wieloma podobieństwami z kapitałem trwałym (rzeźbowym). Jako jeden z pierwszych badaczy William Petty podjął próbę oszacowania wartości kapitału ludzkiego w całym społeczeństwie ówczesnej Anglii¹⁹. Dokonał obliczeń wskazujących, że wartość kapitału zgromadzonego w ludziach jest wyższa o około 70% od wartości ruchomego i nieruchomego majątku materialnego Anglii. W *Traktacie o podatkach i daninach* postawił tezę, że często ludzie biedni są ambitniejsi niż ludzie bogaci, ale bez ambicji. Ponadto Petty zauważył, że zasoby tkwiące w każdym człowieku są niewyczerpalne oraz podlegają ciągłemu rozwojowi²⁰.

Kolejnym ekonomistą, podkreślającym istotę problemu „jakości” człowieka w procesie pracy, był Adam Smith (1723–1790). Podzielał on pogląd Petty’ego, że praca jest źródłem powiększania bogactwa, podstawą zaś akumulacja kapitału. Odmienność jego poglądów wyraża się w oddzielnym traktowaniu człowieka i „kapitału trwałego w nim zawartego” w postaci nagromadzonych umiejętności. Następuje tu więc oddzielenie osobowości człowieka od jego walorów ekonomicznych²¹, co wyraźnie różni Smitha od Petty’ego, który uważał, że to człowiek sam w sobie stanowi kapitał. Smith przekonywał nawet, że kapitał tkwiący w każdym z nas jest składową kapitału trwałego, podobnie jak maszyny, budynki czy urządzenia. Swoje rozważania przedstawił w fundamentalnym dziele: *Bogactwo narodów. Badania nad naturą i przyczynami bogactwa narodów*. Jego zdaniem:

¹⁶ J. Siderska, *The role of social capital of the modern IT company* [w]: A. Myśliński (red.), *Techniki informacyjne – teoria i zastosowania*, t. 5 (17), Instytut Badań Systemowych PAN, Warszawa 2015, s. 99.

¹⁷ J. Siderska, *The role of social capital...*, dz. cyt., s. 99.

¹⁸ B.F. Kiker *The historical roots of the concept of human capital*, „Journal of Political Economy” 5, 1966, vol. 74.

¹⁹ S.R. Domański, *Kapitał ludzki i wzrost gospodarczy*, Wydawnictwo Naukowe PWN, Warszawa 1993, s. 31.

²⁰ W. Petty, *Traktat o podatkach i daninach*, Londyn 1662.

²¹ S.R. Domański, dz. cyt., s. 33, 35.

*Należy oczekiwać, że praca, którą wykształcony człowiek wykonywać się uczy, zwróci mu oprócz zwykłej płacy za zwykłą pracę, także wszystkie wydatki wyłożone na wykształcenie wraz ze zwykłymi co najmniej zyskami od równie wielkiego kapitału*²².

Jan Baptiste Say (1767–1832) starał się połączyć poglądy Petty’ego oraz Smitha i wytyczył jeszcze jeden kierunek w pojmowaniu ekonomicznych aspektów człowieka. Z jednej strony, zaliczał nagromadzone umiejętności do majątku narodowego jako część niematerialnych funduszy zdolności przemysłowych, z drugiej zaś, pojęcie kapitału zawęził tylko do materialnych wytworów pracy ludzkiej. Say był przekonany, że kapitał ludzki powinien być traktowany ilościowo i jako pierwszy, w pionierski sposób, oszacował dochód osób wykształconych, co pozwoliło na wypuklenie korzyści wynikających z poniesionych wydatków na ich kształcenie²³. Friedrich List (1789–1846) w swoich rozważaniach również podnosił kwestię wiedzy i umiejętności nagromadzonych w człowieku i ich wpływu na funkcjonowanie gospodarki. Twierdził on, że wiedza i umiejętności ludzi stanowią najważniejszy składnik narodowego kapitału i muszą być brane pod uwagę przy analizie procesów produkcyjnych²⁴. Inni badacze, tacy jak John Stuart Mill, Jahn Ramsey McCulloch, Leon Walras, Johann Heinrich von Tünen, Alfred Marshall, Irving Fisher, także podejmowali w swoich pracach problematykę traktowania ludzi w kategoriach kapitału, poruszali również tematykę oświaty i roli, jaką ona odgrywa w tworzeniu bogactwa narodowego²⁵.

Polska myśl ekonomiczna, co wynikało chociażby z kontekstu historycznego, przejęła sposób rozumowania kategoriami narodu i interesu narodu, którego podstawowym elementem składowym było podnoszenie poziomu kształcenia, kwalifikacji i rozwijanie rodzinnych talentów. W tym duchu wypowiadali się Stanisław Staszic (1755–1826) i Fryderyk Skarbek (1792–1866)²⁶.

Pragmatyzm teoretyczny Alfreda Marshalla (1842–1924) oraz jego autorytet naukowy spowodował, że po pierwszej połowie XX wieku w literaturze ekonomicznej w zasadzie nie podejmowano tej problematyki. Marshall z jednej strony uznawał teoretyczną użyteczność koncepcji szacowania kapitałowej wartości człowieka, z drugiej zaś odrzucał ją ze względów pragmatycznych²⁷. O tym, że poglądy na temat wpływu Marshalla na rozwój tych koncepcji są podzielone, świadczy fakt, że jego zdanie:

²² M. Blang, *Teoria ekonomii: ujęcie retrospektywne*, Wydawnictwo Naukowe PWN, Warszawa 2000, s. 66.

²³ J.B. Say, *Traktat o ekonomii politycznej*, Wydawnictwo Naukowe PWN, Warszawa 1960, s. 188, 878.

²⁴ S.R. Domański, dz. cyt., s. 37.

²⁵ G. Łukasiewicz, dz. cyt., s. 13.

²⁶ S.R. Domański, dz. cyt., s. 38.

²⁷ S.R. Domański, dz. cyt., s. 32, 40.

Najbardziej wartościowym ze wszystkich kapitałów jest ten zainwestowany w istoty ludzkie,

zostało mottem książki G.S. Beckera *Human Capital*²⁸.

W dorobku wymienionych ekonomistów główną osią sporu był sposób pojmowania kapitału. W zależności od przyjętej jego definicji istoty ludzkie traktowane były jak kapitał (W. Petty), w innym przypadku za kapitał uważano tylko wiedzę i doświadczenie, ucieleśnione w jednostce ludzkiej.

Po raz pierwszy pojęcie kapitału ludzkiego w literaturze przedmiotu zostało użyte przez Theodora Williama Schultza w 1961 roku w artykule w „American Economic Review”. Kapitałem ludzkim Schultz nazywał wiedzę i umiejętności ludzi, podkreślając, że jednostki świadomie inwestują w siebie, by poprawić osiągnane wyniki ekonomiczne i własny dobrobyt.

*Jest oczywiste, że ludzie nagromadzają nabyte umiejętności i wiedzę, nie jest natomiast oczywiste, iż te umiejętności i wiedza są formułą kapitału, i że rósł on w zachodnich społeczeństwach o wiele szybciej niż konwencjonalnie pojmowany kapitał, a wzrost ten nie może być traktowany jako jedna z najistotniejszych cech systemu ekonomicznego*²⁹.

Kapitał ludzki stanowi szczególny rodzaj kapitału wykorzystywanego w procesie produkcji i jest bardzo różnie interpretowany w literaturze. Tak jak termin „kapitał” nie ma jednoznacznej definicji, tak również w przypadku pojęcia „kapitał ludzki” do dziś naukowcy nie uzgodnili jednej, akceptowanej definicji. Jacob Mincer (1922–2006) rozpatrywał teorię kapitału ludzkiego w aspekcie edukacji społeczeństwa, podnosząc jakość zasobów pracy. Gary Stanley Becker (1930–2014) kapitał ludzki rozważał na poziomie jednostki. Jednostka podejmuje decyzję o inwestycji w swój kapitał ludzki, dopóki zwrot z tej inwestycji przewyższa poniesione koszty. Zwrot ten może być rozpatrywany na poziomie jednostki i całego społeczeństwa. Międzynarodowe organizacje zajmujące się pomiarem i porównywaniem w skali międzynarodowej akumulacji kapitału ludzkiego określają go jako *ucieleśnione w jednostce umiejętności, kompetencje, wiedzę, które są istotne w działalności gospodarczej*^{30, 31}.

²⁸ D. Dobija, *Pomiar kapitału ludzkiego i możliwości raportowania wyników*, „Zarządzanie zasobami ludzkimi” 2002, nr 5, s. 28.

²⁹ T.W. Schultz, *Investment in Human Capital*, The Free Press, New York 1976, s. 24.

³⁰ Human Capital Investment, An International Comparison, Center for Educational Research and Innovation, OECD, 1998, s. 9.

³¹ G. Becker, *Human capital: a theoretical and empirical analysis, with special reference to education*, The University of Chicago Press, Chicago 1964.

Stanisław Domański zdefiniował kapitał ludzki jako:

*zasób wiedzy, umiejętności, zdrowia i energii witalnej zawartej w społeczeństwie. Zasób ten jest dany przez genetyczne cechy danej populacji raz na zawsze, ale można go powiększyć drogą inwestycji w człowieka: w ludzi, w kapitał ludzki, w ludzkie życie*³²

Jacek Grodzki przez kapitał ludzki rozumie:

zasób wiedzy i umiejętności o określonej wartości będący źródłem przyszłych zarobków czy satysfakcji, przy czym jest on odnawialnym i stale powiększanym potencjałem ludzkim.

W literaturze wyróżnia kapitał ludzki *sensu largo* i kapitał ludzki *sensu stricto*³³. Łukasiewicz przyjmuje, iż przez kapitał ludzki należy rozumieć zasób wiedzy, umiejętności, zdolności, kwalifikacji, postaw, motywacji oraz zdrowia, o określonej wartości, będący źródłem przyszłych zarobków czy satysfakcji, przy czym jest on odnawialnym i stale powiększanym potencjałem ludzkim³⁴. W tak zdefiniowanym kapitale ludzkim zawierają się dwa jego wymiary: rynkowy oraz osobisty. Rynkowy wymiar to zasób wiedzy, umiejętności, zdolności, kwalifikacji, postaw oraz zdrowia, które jednostka zamierza wykorzystać bądź już wykorzystuje w swojej pracy zawodowej. Decydują one o jej szansach na znalezienie zatrudnienia, wysokości otrzymywanych zarobków, możliwości otrzymania awansu. Drugi wymiar obejmuje również wyżej wymienione zasoby, które z kolei w niewielkim stopniu wiążą się z wykonywaną pracą zawodową, lecz w życiu osobistym jednostki są wykorzystywane na szeroką skalę (zainteresowania, hobby). Istotne okazują się także negatywne cechy pracownika, to jest nielojalność, pesymizm, hipokryzja, podejrzliwość. Te cechy uwzględnione zostały w definicji zaproponowanej przez Walukiewicza, który rozumie kapitał ludzki jako³⁵: *wszystkie zasoby niematerialne, kojarzone z człowiekiem, traktowanym jako samodzielna istota ludzka, a więc jego talent, doświadczenie, kompetencje, wiedza, zaufanie, otwartość.*

³² S.R. Domański, dz. cyt., s. 19.

³³ J. Grodzki, *Rola kapitału ludzkiego w rozwoju gospodarki globalnej*, Wydawnictwo Uniwersytetu Gdańskiego, Gdańsk 2003, s. 50.

³⁴ G. Łukasiewicz, dz. cyt., s. 20.

³⁵ S. Walukiewicz, *Kapitał społeczny...*, dz. cyt., s. 85.

1.2. Kapitał społeczny

Termin kapitał społeczny (ang. *social capital*) funkcjonuje w naukach społecznych od niespełna wieku. Rozpowszechniony został między innymi dzięki pracom Francisa Fukuyamy, Jamesa Colemana i Roberta Putnama.

Fukuyama, amerykański politolog i ekonomista uważał, że:

*kapitał społeczny to zestaw wartości i norm etycznych wspólnych dla określonej grupy ludzi i umożliwiających im skuteczne współdziałanie*³⁶.

Coleman – amerykański socjolog, to pierwszy naukowiec, który w swojej pracy posłużył się pojęciem *social capital*. Określił kapitał społeczny jako cechę struktury relacji społecznych, która wspiera konkretne działania aktorów, podejmowane w jej ramach³⁷. Coleman jest autorem klasycznej definicji, systematyzującej pojęcie kapitału społecznego. Ujmował on to pojęcie jako:

*umiejętności współpracy międzyludzkiej w obrębie grup i organizacji wspólnych interesów*³⁸.

Ponadto zdaniem Colemana kapitał społeczny może być rozumiany jako:

*grupa podmiotów społecznych, które mają dwa wspólne elementy: są częścią jakiejś społecznej struktury i ułatwiają wspólne działania. Jest on produktywny, tak jak inne kapitały, to znaczy umożliwia realizację pewnych celów, których osiągnięcie byłoby niemożliwe w sytuacji jego braku*³⁹.

Kontynuatorem podejścia Jamesa Colemana był Robert Putman. Jego zdaniem kapitał społeczny odnosi się do takich cech organizacji społeczeństwa, jak zaufanie, normy i powiązania, które mogą zwiększać sprawność społeczeństwa, ułatwiając skoordynowanie działań⁴⁰. Ponadto Putman uznał zaufanie umacniające współpracę jako najważniejszy czynnik wpływający na kapitał społeczny⁴¹.

³⁶ F. Fukuyama, *Kapitał społeczny* [w:] L.E. Harrison, S.P. Huntington (red.), *Kultura ma znaczenie*, Zysk i S-ka, Kraków 2003, s. 169.

³⁷ M. Theis, *Krewni – znajomi – obywatele. Kapitał społeczny a lokalna polityka społeczna*, Wydawnictwo Adam Marszałek, Toruń 2007, s. 14.

³⁸ F. Fukuyama, *Zaufanie. Kapitał społeczny a droga do dobrobytu*, Warszawa-Wrocław 1997, s. 20.

³⁹ J. Coleman, *Social Capital in the Creation of Human Capital*, „The American Journal of Sociology, Supplement: Organizations and Institutions: Sociological and Economic Approaches to the Analysis of Social Structure” 1988, vol. 94, s. 98.

⁴⁰ R.D. Putnam, R. Leonardi, R.Y. Nanetti, *Demokracja w działaniu. Tradycje obywatelskie we współczesnych Włoszech*, Wydawnictwo Żnak, Warszawa 1995, s. 285.

⁴¹ M. Theis, dz. cyt., s. 16.

W literaturze często wymienia się także termin „kapitał intelektualny”. Pojęcie to zostało spopularyzowane w Polsce dzięki książce L. Edvinssona i M.S. Malone’a⁴², jednak ta publikacja nie wskazuje jego definicji. Z rozważań prowadzonych przez autorów wynika, że traktują oni ten termin jak wartości niematerialne. Jednak, zdaniem autorki, różnica pomiędzy tymi pojęciami ma zasadnicze znaczenie i nie należy ich używać wymiennie, zatem w dalszych rozważaniach termin ten nie będzie stosowane.

Omówione definicje kapitału społecznego dotyczą tylko jego pozytywnych cech, takich jak zaufanie, solidarność, wyrozumiałość i tym podobne. Nie uwzględniają one natomiast bardzo istotnych, zdaniem autorki, aspektów negatywnych, jak: brak zaufania, brak lojalności, hipokryzję, podejrzliwość, zakłamanie. W tym kontekście definicja zaproponowana przez Walukiewicza, traktująca kapitał społeczny jako⁴³:

wszystkie formalne i/lub nieformalne relacje pomiędzy co najmniej dwiema osobami traktowanymi jako samodzielne istoty ludzkie, więc zaufanie, lojalność, umiejętność współpracy, ale i rozwiązywania problemów i konfliktów

jest bardziej precyzyjna i holistyczna, dlatego będzie stanowiła podstawę do podejmowania dalszych rozważań w tym zakresie.

Autorka zaproponowała własną definicję kapitału społecznego jako określonej wartości umiejętności pracowników i ich zdolności do twórczej, kreatywnej pracy, stanowiące najcenniejszy zasób przedsiębiorstwa, będące źródłem jego przychodów, gwarantujące osiągnięcie przewagi konkurencyjnej, warunkujące rozwój i stabilną pozycję na rynku oraz dobre notowania na giełdzie. Można to wyjaśnić na przykładzie przedsiębiorstwa Microsoft, światowego lidera w sprzedaży oprogramowania. Microsoft zatrudnia tysiące wybitnych programistów, inżynierów oprogramowania, analityków, testerów wraz z ich wiedzą, talentem, umiejętnością programowania itp., co stanowi bardzo istotny zasób tego przedsiębiorstwa. Oprogramowanie powstaje dzięki wspólnej, twórczej pracy programistów. Kapitał ludzki każdego z nich, czyli ich wiedza informatyczna, talent, znajomość języków programowania, doświadczenie, tworzą łącznie bazę do budowy kapitału społecznego całej firmy.

W ostatnich dwudziestu latach kapitał społeczny to jedno z najczęściej dyskutowanych pojęć w naukach społecznych. Kapitał społeczny, oprócz omówionych powyżej aspektów, odgrywa także istotną rolę w procesie dzielenia się wiedzą i kształtowania współpracy i innowacyjności w sieciach klastrowych⁴⁴.

⁴² S. Walukiewicz, *Kapitał społeczny...*, dz. cyt., s. 98.

⁴³ S. Walukiewicz, *Kapitał społeczny...*, dz. cyt., s. 26.

⁴⁴ M. Runiewicz-Wardyn, *Social capital and social networks in the life sciences industry clusters. An analysis of selected case studies / Kapitał społeczny i sieci społecznościowe w klastrach sektora nauk o życiu. Analiza wybranych studiów przypadku*, „Economic and Regional Studies” 14(3), 2021, s. 279–293.

W tym miejscu warto podkreślić, że zarówno pozytywne, jak i negatywne cechy pracowników przedsiębiorstwa są niezwykle istotne z punktu widzenia realizacji celów każdej organizacji, jak i przy budowaniu jej kapitału społecznego. Powinno odróżniać się kapitał społeczny jako złożony proces społeczno-ekonomiczny, który ma bardzo konkretną wartość (ekonomiczną), szczególnie w firmach informatycznych, od jego wartości, która dla określonej chwili t jest po prostu liczbą jednostek monetarnych. Zatem analizuje się kapitał społeczny jako złożony proces społeczno-ekonomiczny w firmach informatycznych oraz szacowana jest jego wartość, na przykład na koniec okresu, kwartału. Cechy kapitału społecznego mają określoną wartość, czyli można dokonać ich pomiaru. W literaturze zaproponowanych zostało wiele metod do szacowania wartości niematerialnych, a ich zidentyfikowane słabe strony były jednym z powodów, dla których autorka podjęła się badań w tym zakresie i opracowała autorskie narzędzie do tego typu szacunków.

2. Zarządzanie wartością przedsiębiorstwa informatycznego

Wielkość i dynamika zjawisk ekonomicznych, politycznych i społecznych oraz wyzwania XXI wieku doprowadziły do pojawienia się nowych spojrzeń na zarządzanie wydajnością przedsiębiorstwa i do opracowania nowych paradygmatów w tym zakresie. Zarządzanie oparte na wartości (ang. *Value Based Management* – VBM) zaczęło stanowić realną alternatywę dla dotychczas wdrażanych systemów zarządzania skoncentrowanych na zwiększaniu wydajności. Ukierunkowanie administrowania przedsiębiorstwem na maksymalizację jego wartości dla akcjonariuszy pojawiło się w kontekście przemian gospodarczych przedostatniej dekady ubiegłego wieku, bezprecedensowej liberalizacji kapitału i rosnącej konkurencji⁴⁵. W tym rozdziale omówiona zostanie istota tego podejścia.

2.1. Założenia zarządzania przedsiębiorstwem przez wartość

Koncepcja zarządzania przez wartość w ostatnich latach zyskuje na popularności i cieszy się dużym zainteresowaniem wielu organizacji i badaczy. Coraz powszechniejsze skoki notowań akcji i postępująca globalizacja rynków kapitałowych powodują, że przedsiębiorstwa muszą konkurować o uznanie inwestorów. Dlatego wiele firm stosuje obecnie narzędzia zarządzania oparte na wartościach w celu zwiększenia wartości dla akcjonariuszy i holistycznego rozwiązywania problemów swoich interesariuszy⁴⁶. Z akademickiego punktu widzenia zarządzanie oparte na wartościach nie jest nową kwestią. Jeden z najważniejszych jej orędowników, Rappaport⁴⁷, wprowadził koncepcję tworzenia wartości dla akcjonariuszy już w 1986 roku. Stało się to podstawą do dalszych rozważań, takich badaczy jak na przykład Stern czy Stewart,

⁴⁵ C.M. Oane, K. Smolag, E.S. Marinescu i in., *Value-based management as the innovating paradigm of contemporary governance – a theoretical approach*, „Polish Journal of Management Studies” 12(1), 2015.

⁴⁶ V. Beck V., B. Britzelmaier, *Value-based management – a critical review*, „International Journal of Sales Retailing and Marketing” 2011, vol. 13 (3), s. 270–286.

⁴⁷ A. Rappaport, *Creating Shareholder Value. The New Standard for Business Performance*, New York: The Free Press, 1986.

którzy zaproponowali wskaźniki efektywności, to jest: Ekonomiczną Wartość Dodaną (ang. *Economical Value Added* – EVA) i Gotówkową Wartość Dodaną (ang. *Cash Value Added* – CVA).

Koncepcja zarządzania przez wartość polega na realizowaniu procesów zarządzania przedsiębiorstwem w sposób kompleksowy, od wyboru strategii do codziennych decyzji operacyjnych podejmowanych na najniższych szczeblach zarządzania, ukie-
runkowanych na maksymalizację wartości rynkowej przedsiębiorstwa. Koncepcja ta wiąże elementy zarządzania finansami z elementami zarządzania strategicznego, a także decyzje długofalowe z decyzjami bieżącymi, przy czym celem tego powiązania jest tworzenie wartości przedsiębiorstwa i uzyskanie dobrej pozycji konkurencyjnej⁴⁸.

Istotne w tym kontekście staje się jednak przede wszystkim zwrócenie uwagi na rolę wartości niematerialnych w procesie zarządzania. Właściwe gospodarowanie aktywami niematerialnymi w turbulentnym otoczeniu i w dobie rozwoju społeczeństwa informacyjnego jest warunkiem koniecznym dla budowania przewagi konkurencyjnej przedsiębiorstwa na rynku⁴⁹. Kapitał społeczny nie tylko przyczynia się do tworzenia nowej wartości dla przedsiębiorstw, lecz także uczestniczy w zarządzaniu tą wartością poprzez występowanie w roli nośnika dobrych praktyk i zachowań takich firm. Wpływa on na organizację, czyniąc ją bardziej elastyczną, to znaczy dostosowującą się do wciąż zmieniającego się otoczenia.

W związku z tym zmiany, które zakładają zarządzanie wartością przedsiębiorstwa, są możliwe dzięki wysokiemu poziomowi kapitału społecznego, który poprzez wzrost poziomu zaufania i współpracy wewnątrz organizacji pozwala te zmiany wprowadzić⁵⁰. Dlatego też tak ważny jest pomiar wartości kapitału społecznego przedsiębiorstwa, jako najcenniejszego zasobu wszystkich organizacji, w tym przede wszystkim firm prowadzących działalność w sektorze IT.

Warto w tym miejscu podkreślić, że efektywne pomnażanie wartości przedsiębiorstwa, a tym samym skuteczna realizacja strategii kreowania wartości jest zarówno wyzwaniem, przed którym staje kadra menedżerska organizacji, ale jednocześnie siłą dla budowania stałej i konkurencyjnej kultury oraz drogą do zrównoważonego i społecznie odpowiedzialnego rozwoju przedsiębiorstwa. Te wartości powinny być w centrum uwagi w kwestiach związanych ze zmianą organizacyjną, jak również w całej praktyce zarządzania.

W dalszej części tego rozdziału przedstawiona zostanie zasada ortogonalności i równanie fundamentalne, które stanowią uzasadnienie do przyjętej metodyki szacowania wartości kapitału społecznego. Jak już mówiono, pomiar wartości tych aktywów niematerialnych przedsiębiorstwa, przy wykorzystaniu dotychczas zaproponowanych

⁴⁸ M. Siudak, *Zarządzanie wartością przedsiębiorstwa*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2001, s. 5.

⁴⁹ J. Dziwulski, S. Skowron, *Struktura i pomiar kapitału intelektualnego*, Wydawnictwo Politechniki Lubelskiej, Lublin 2020, s. 106.

⁵⁰ A. Libertowska, *Social capital in the Value-Based Management*, „Economics and Management” 2, 2014, s. 85–96.

w literaturze narzędzi, jest procesem bardzo trudnym i żmudnym i w związku z tym często pomijanym. Co więcej, jak dotąd nie zaproponowano w literaturze jednej, powszechnie akceptowanej i wykorzystywanej metodyki i narzędzia do tego typu obliczeń. Należy zaznaczyć, że jest to bardzo istotne, by szacować wartości kapitału społecznego przedsiębiorstwa, bowiem pomijanie w sprawozdaniach księgowych tego składnika jest dużym błędem. Ponadto jest to bardzo cenna informacja dla inwestorów. W tej monografii autorka przedstawia metodykę szacowania wartości kapitału społecznego oraz prezentuje opracowane narzędzie, oparte na obliczeniach inteligentnych, co pozwala na skrócenie czasu potrzebnego na dokonanie obliczeń.

2.2. Pomiar wartości kapitału społecznego

W literaturze przedmiotu zaproponowano wiele metod pozwalających na szacowanie wartości niematerialnych przedsiębiorstw. Karl-Erik Sveiby zaproponował następującą systematyzację takich narzędzi⁵¹:

- Metody oparte na kapitalizacji rynkowej (ang. *Market Capitalization Methods* – MCM), obliczane jako różnica pomiędzy wartością giełdową a wartością księgową przedsiębiorstwa. Do tych metod zaliczane są między innymi: Wskaźnik MV/BV (ang. *Market-To-Book Value*), Wskaźnik Q Tobina, Model IAMV™ (ang. *Investor Assigned Market Value*).
- Metody oparte na zwrocie na aktywach (ang. *Return on Assets Methods* – ROA) – wartość zwrotu na aktywach (ROA) przedsiębiorstwa otrzymywana jest poprzez podzielenie wartości średnich zysków przed opodatkowaniem przez średnią wartość aktywów materialnych. Otrzymaną wartość ROA porównuje się ze średnią dla danego sektora, a otrzymana różnica, pomnożona przez przeciętną wartość aktywów materialnych, pokazuje średnie roczne zyski z aktywów niematerialnych. Wartość ta dzielona jest przez przeciętny koszt kapitału i daje wartość równą całkowitej wartości kapitału intelektualnego. Wśród tych narzędzi wymienia się między innymi: Metodę KCE™ (ang. *Knowledge Capital Earnings*), Wskaźnik EVA™ (ang. *Economic Value Added*), Metodę VAIC™ (ang. *Value Added Intellectual Coefficient*), Metodę CIV (ang. *Calculated Intangible Value*).
- Metody kart punktowych (ang. *Scorecards Methods* – SC), należące do tak zwanych wskaźników niepieniężnych. Do tych metod zaliczane są między innymi: Nawigator Skandii (ang. *Skandia Navigator™*), Model IC Rating™, Platforma wartości (ang. *Value Platform*), Monitor Aktywów Niematerialnych IAM (ang. *Intangible Assets Monitor*), Zrównoważona Karta Wyników BSC (ang. *Balanced Scorecard*), Model VCS™ (ang. *Value Chain Scoreboard*), Indeks kapitału intelektualnego IC-Index (ang. *Intellectual Capital Index*).

⁵¹ K.E. Sveiby, *Methods of Measuring Intangible Assets*, strona internetowa, <http://www.sveiby.com/articles/MeasureIntangibleAssets.html> [dostęp: 22.05.2021].

- Metody bezpośredniego pomiaru kapitału intelektualnego (ang. *Direct Intellectual Capital methods* – DIC), umożliwiające szacowanie pieniężnej wartości, na przykład: IAV (ang. *Intangible Assets Valuation*), TVC (ang. *Total Value Creation*) czy IVM (ang. *Inclusive Valuation Methodology*).

Opierając się na badaniach Sveiby'ego, przeprowadzono wstępne analizy pozwalające na identyfikację zmiennych istotnie wpływających na wartość kapitału społecznego przedsiębiorstwa. Ponieważ celem podjętych prac badawczych było opracowanie sposobu szacowania wartości kapitału społecznego giełdowych przedsiębiorstw informatycznych, podjęto decyzję, że zaproponowane przez autorkę narzędzie powinno należeć do grupy metod opartych na kapitalizacji rynkowej. Tylko te narzędzia pozwalają na zbadanie wartości rynkowej (giełdowej) i księgowej przedsiębiorstwa. W literaturze przedmiotu podaje się, że jeżeli wartość wskaźnika MV/BV (*Market-To-Book Value*) jest większa niż 1, oznacza to, że w przedsiębiorstwie są aktywa niematerialne, które nie zostały uwzględnione w sprawozdaniach finansowych⁵².

W przypadku spółek giełdowych wartość rynkowa obliczana jest jako iloczyn liczby wszystkich akcji oraz ceny akcji. Wartość księgowa wynika natomiast z bilansów finansowych i rozumiana jest jako różnica pomiędzy sumą wszystkich aktywów i zobowiązań organizacji. Znaczna różnica (wiele razy) pomiędzy wartościami giełdowymi a księgowymi przedsiębiorstw informatycznych wynika, zdaniem autorki, z istotnej roli ich wartości niematerialnych. Przekonanie to było podstawą do podjęcia rozważań w tym zakresie oraz opracowania metodyki i narzędzi do ich pomiaru.

Dokonując przeglądu literatury, zidentyfikowano mocne i słabe strony zaproponowanych metod szacowania wartości niematerialnych przedsiębiorstw. Na tej podstawie zaproponowano autorską metodykę pomiaru wartości kapitału społecznego spółek giełdowych z branży informatycznej, bazującą przede wszystkim na danych zawartych w publikowanych przez te przedsiębiorstwa bilansach księgowych. Te rozważania pozwoliły na sformułowanie modelu teoretycznego, który następnie zastosowano do budowy narzędzia umożliwiającego szacowanie wartości niematerialnych firm informatycznych.


2.3. Zasada ortogonalności i równanie fundamentalne

Walukiewicz zauważył, że są tylko wartości materialne (WM) i wartości niematerialne (WNM). Zarówno kapitał ludzki, jak i społeczny należą do wartości niematerialnych, co wyjaśnia, dlaczego tak trudno jest je analizować i szacować ich wartości. Celem rozważań podjętych w tym punkcie jest prezentacja zasady ortogonalności, dającej

⁵² D. Appenzeller, *Wartość kapitału intelektualnego firmy a prognozowanie upadłości* [w:] P. Dittmann (red.), *Prognozowanie*, „Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu. Ekonometria 24”, nr 38, Wydawnictwo Uniwersytetu Ekonomicznego, Wrocław 2009, s. 114–115.

odpowieź na pytanie; *jakie elementy determinuj na wartoř kaŹdej firmy informatycznej, niezaleŹnie od przesanek i celw jej wyceny?* Rezultatem pořrednim podjętych w tym punkcie rozwaŹa jest takŹe rozszerzona definicja terminu kapita spoeczny⁵³.

W celu przybliŹenia istoty zasady ortogonalnořci naleŹoby rozwaŹyć wszystkie wartořci, a wic zasoby, kapitay i inne, przedsięwiorstwa informatycznego w chwili *t*. Zatem dokonywana jest analiza wycinka rzeczywistořci *X* (wszystkich wartořci firmy) w chwili *t*. Graficznie wszystkie wartořci przedsięwiorstwa moŹna przedstawić za pomoc koa. NaleŹy zaoŹyć, Źe rozpatrywanie wszystkich wartořci wycinka rzeczywistořci jest zbyt skomplikowane, zatem dla uatwienia moŹna podzielić go na dwie mniejsze kategorie, przedstawione na rysunku 2.1 jako A i B. MoŹliwe s tylko dwie sytuacje: kategoria A, zakreskowana pionowo, zachodzi na B, zakreskowan poziomo, co jest podziaem wycinka koa *X* na A i B i pokazano to na rysunku 2.1a jako częřć koa zakreskowan w kratkę; albo kategorie A i B s rozaczne i tworz rozbićcie wycinka *X* na A i B i zostao to zilustrowane na rysunku 2.1b⁵⁴.



RYСУNEK 2.1. Różnica pomidzy podziaem a rozbićciem: a) podzia wycinka *X* na A oraz B, b) rozbićcie wycinka *X* na A oraz B

ŹROO: S. Walukiewicz, *Kapita spoeczny...*, dz. cyt., s. 78.

Wyznaczenie wartořci kategorii A dokonuje si poprzez dodanie wartořci jej poszczegolnych elementw (pozycji w bilansie finansowym), oznaczonych na rysunku 2.1a białymi kolkami, a kategorii B – dodajc wartořci oznaczone krzyŹykami. NaleŹy zauwaŹyć, Źe na rysunku 2.1a drugi element kategorii B pokrywa si z trzecim elementem kategorii A. W rachunkowořci kaŹdy element z analizowanego wycinka rzeczywistořci moŹe być uwzględniany w bilansie tylko raz. Jasne jest, Źe taka sytuacja nie moŹe zdarzyć si, gdy kategorie s rozaczne, jak na rysunku 2.1b. W wielu dziedzinach nauki nie jest moŹliwe przedstawienie wycinka rzeczywistořci

⁵³ S. Walukiewicz, *Kapita spoeczny...*, dz. cyt., s. 77.

⁵⁴ TamŹe, s. 78–79.

X jako rysunek 2.1a albo 2.1b, zatem należy sformułować odpowiednią zasadę i podać jej matematyczną i graficzną interpretację. Reguła ta została nazwana **zasadą ortogonalności** i pozwala ona stwierdzić, kiedy dwie formy są rozłączne⁵⁵:

Dwa pojęcia A oraz B (kategorie, formy, wymiary) są ortogonalne lub rozłączne wtedy i tylko wtedy, kiedy istnieje **obiektywna, prosta, jednowymiarowa reguła decyzyjna typu tak – nie**, pozwalająca zdecydować, czy element przynależy albo do A, albo do B⁵⁶.

Ponieważ zasada ortogonalności jest fundamentem dalszych badań nad wartością przedsiębiorstw informatycznych, to należy podać jej matematyczną interpretację, czyli zapisać ją w języku matematycznej teorii zbiorów (matematyki). Jeżeli X jest analizowanym wycinkiem rzeczywistości, czyli zbiorem wszystkich analizowanych elementów, to reguła decyzyjna umożliwia rozbić tego zbioru na dwa rozłączne, niepuste podzbiory A oraz B, takie że⁵⁷:

$$X = A \cup B \quad \text{oraz} \quad A \cap B = \emptyset, A \neq \emptyset, B \neq \emptyset. \quad (2.1)$$

Zasada ortogonalności zostanie zastosowana do analizy wszystkich zasobów składających się na wartość przedsiębiorstwa informatycznego. Wartością (kapitałem) firmy są następujące składniki: zasoby finansowe lub jej **kapitał finansowy** (oszczędności, akcje, kredyty i tym podobne) oraz jej zasoby materialne lub jej **kapitał materialny** (na przykład budynki, maszyny, samochody). Ponadto przedsiębiorstwo informatyczne zatrudnia programistów, analityków, testerów, inżynierów oprogramowania itp., mających doświadczenie, talent, umiejętności itp., nazywane odąd **kapitałem ludzkim**, który jest bardzo istotnym zasobem firmy. Produkty oferowane przez te firmy są efektem wspólnej, kreatywnej pracy tych pracowników, ich wzajemnego zaufania, umiejętności współpracy, co określane jest jako **kapitał społeczny** firmy.

Wszystkie zasoby składające się na wartość każdego przedsiębiorstwa informatycznego można wyrazić w jednostkach monetarnych i dzielone są na **wartości materialne (WM)** i **wartości niematerialne (WNM)**. Rozbicia takiego dokonano na podstawie zasady ortogonalności. Regułą decyzyjną jest tutaj fakt, że wartości materialne, takie jak budynki, maszyny, urządzenia są namacalne, w przeciwieństwie do wartości niematerialnych, takich jak wiedza, doświadczenie, zaufanie, współpraca.

Niech $V(F, t)$ będzie wartością rozważanego przedsiębiorstwa IT w momencie t . Wielkości odpowiadające wartościom materialnym i niematerialnym oznaczono odpowiednio jako $v(WM, t)$ i $v(WNM, t)$ i są one do siebie ortogonalne, rozłączne, co oznacza, że można je do siebie dodawać⁵⁸:

$$V(F, t) = v(WM, t) + v(WNM, t) \quad \text{dla każdego } t \quad (2.2)$$

⁵⁵ Tamże, s. 79.

⁵⁶ S. Walukiewicz, *Kapitał ludzki...*, dz. cyt., s. 43.


⁵⁷ S. Walukiewicz, *Kapitał społeczny...*, dz. cyt., s. 80.

⁵⁸ Tamże, s. 106.

W dalszym kroku, korzystając z zasady ortogonalności, rozbito kolejno wartości materialne na **kapitał finansowy (KF)** i **kapitał materialny (KM)**, a wartości niematerialne na **kapitał ludzki (KL)** i **kapitał społeczny (KS)**. Wartości wymienionych elementów składających się na wartość każdej firmy oznaczono odpowiednio: $v(KF)$, $v(KM)$, $v(KL)$ oraz $v(KS)$. Ze względu na to, że poszczególne formy kapitału nie mają żadnych elementów wspólnych, ich wartości można do siebie dodawać. Rozbicia te przedstawiono na rysunku 2.2 oraz opisano następującym wzorem⁵⁹:

$$V(F, t) = v(KF, t) + v(KM, t) + v(KL, t) + v(KS, t) \text{ dla każdego } t \quad (2.3)$$

W tym miejscu warto przypomnieć, iż kapitał finansowy (KF) przedsiębiorstwa obejmuje jego zasoby finansowe, czyli wyemitowane akcje i obligacje, zgromadzone środki pieniężne, ale i zaciągnięte pożyczki i kredyty. Kapitał materialny (KM) odnosi się natomiast do budynków, maszyn, nieruchomości, sprzętu komputerowego. Doświadczenie pracowników, ich wiedza talent i inne cechy, przyczyniające się w dużym stopniu do zdobywania przewagi konkurencyjnej firmy, a charakteryzujące każdego pracownika z osobna nazwane zostały kapitałem ludzkim (KL) danej osoby lub **kapitałem ludzkim w liczbie pojedynczej**. Wartości kapitałów ludzkich różnych pracowników, zgodnie z zasadą ortogonalności, można dodawać, a ich sumę nazywa się **kapitałem ludzkim w liczbie mnogiej**.



RYSUNEK 2.2. Rozbicie wartości firmy na cztery formy kapitału

ŹRÓDŁO: S. Walukiewicz, *Kapitał społeczny...*, dz. cyt., s. 107.

⁵⁹ Tamże, s.107.

Wartości niematerialne wynikające z relacji pomiędzy pracownikami, ich umiejętność kooperacji, pracy zespołowej itp., ale też ich wypracowane relacje z otoczeniem określono jako **kapitał społeczny** (KS)⁶⁰. Należy podkreślić, że kapitał ludzki odnosi się zawsze tylko do jednego pracownika, natomiast kapitał społeczny pojawia się tam, gdzie zachodzi relacja, zarówno w pozytywnym jak i negatywnym znaczeniu, co najmniej dwóch osób. Z tego wynika, że zgodnie z zasadą ortogonalności kapitał ludzki i kapitał społeczny są rozłączne lub ortogonalne, zatem ich wartości można dodawać⁶¹.

Zależność opisana we wzorze 2.3 nazwana została **równaniem fundamentalnym**. Jest ono równaniem typu tu i teraz, które podaje, że wartość dowolnego przedsiębiorstwa, w tym także firm działających w branży IT, w momencie t jest równa sumie wartości czterech i tylko czterech form kapitału: finansowego, materialnego, ludzkiego i społecznego⁶². Te cztery kapitały są wzajemnie rozłączne (ortogonalne) i tworzą rozbięcie wszystkich zasobów firmy na tylko cztery formy kapitału. Równanie fundamentalne mówi, że w gospodarce rynkowej w stanie równowagi, gdy popyt równoważy podaż, wartość firmy w dowolnej chwili t , jest równa sumie wartości czterech i tylko czterech form kapitału wyznaczonych dla tej chwili.

⁶⁰ S. Walukiewicz, *Kapitał ludzki...*, dz. cyt., s. 48.

⁶¹ Tamże.

⁶² S. Walukiewicz, *The Dimensionality of Capital and Proximity*, „Proceedings of ERS 2008” 2008, s. 2.

3. Sztuczne sieci neuronowe

Celem tego rozdziału jest omówienie budowy i własności sieci neuronowych oraz możliwości przetwarzania przez nie danych. Pokazano, że mogą być one stosowane do rozwiązywania problemów związanych z tworzeniem modeli matematycznych pozwalających odwzorowywać złożone zależności pomiędzy sygnałami wejściowymi a wybranymi sygnałami wyjściowymi. W pierwszej części tego rozdziału omówiono istotę sztucznej inteligencji (ang. *artificial intelligence*) – dziedziny nauki, z metod której najpowszechniej implementowane są sztuczne sieci neuronowe. Przedyskutowano także wkład naukowców, którzy w pionierski i istotny sposób przyczynili się do rozwoju badań oraz do wzrostu zainteresowania świata nauki i biznesu tą tematyką. Ponadto przedstawiono rys historyczny zainteresowania badaczy sieciami neuronowymi oraz wskazano prekursorów w tej dziedzinie, którzy wnieśli znaczący wkład w jej rozwój. Omówiono budowę, własności i sposób przetwarzania informacji wejściowych w pojedynczym sztucznym neuronie oraz wskazano jego podobieństwa do biologicznego neuronu człowieka. Zidentyfikowano także obszary zastosowań sieci neuronowych, ze szczególnym uwzględnieniem możliwości ich implementowania do rozwiązywania problemów z zakresu zarządzania i ekonomii. Pokazano, jak sztuczne sieci neuronowe są stosowane do rozwiązywania problemów dotyczących modelowania występujących prawidłowości, pozyskiwania wiedzy oraz klasyfikacji i prognozowania zjawisk.

3.1. Istota sztucznej inteligencji i geneza sztucznych sieci neuronowych

Sztuczna inteligencja jest dziedziną nauki zajmującą się implementacją naturalnej (ludzkiej) inteligencji w maszynach (w szczególności w maszynach cyfrowych) w celu stworzenia narzędzi do automatycznego rozwiązywania skomplikowanych problemów⁶³. Metody sztucznej inteligencji są szczególnie użyteczne przy rozwiązywaniu problemów, w których nie istnieją skuteczne metody analityczne czy statystyczne ani efektywne algorytmy komputerowe, a ponadto nie jest znany charakter badanych

⁶³ P. Lula., J. Stal, R. Tadeusiewicz i in., *Komputerowe metody analizy i przetwarzania danych.*, Uniwersytet Ekonomiczny, Kraków 2012, s. 121.

zjawisk⁶⁴. Sztuczna inteligencja to także gałąź informatyki, zajmująca się rozwojem technologii pozwalającej komputerom na rozwiązywanie problemów (lub wspomaganie człowieka w tym procesie) przy wykorzystaniu metod wnioskowania i zgromadzonej w systemie wiedzy⁶⁵.

Istotny wkład w badania nad sztuczną inteligencją wniósł John McCarthy (1927–2011), profesor matematyki na Uniwersytecie w Dartmouth College w New Hampshire (Stany Zjednoczone). Był on organizatorem seminarium na temat inteligentnych maszyn, podczas którego dyskutowano nad dziedzinami, w których komputery mogłyby zastąpić człowieka. To wtedy po raz pierwszy użyto pojęcia sztuczna inteligencja. W 1956 roku Marvin Minsky zdefiniował sztuczną inteligencję jako:

*działalność zmierzającą do konstruowania urządzeń i programów zdolnych do wykonywania zadań, które – gdyby były rozwiązywane przez człowieka – wymagałyby zaangażowania jego inteligencji*⁶⁶.

Od tego momentu nastąpił gwałtowny rozwój badań w tym zakresie oraz zaczęto identyfikować kolejne obszary, w których implementowano nowe pomysły⁶⁷. Za prekursora badań nad sztuczną inteligencją uważa się także Alana Turinga – angielskiego matematyka, pomysłodawcę testu Turinga – eksperymentu będącego próbą formalnego zdefiniowania sztucznej inteligencji⁶⁸.

Narzędzia sztucznej inteligencji, w tym przede wszystkim sztuczne sieci neuronowe, są powszechnie stosowane nie tylko w obszarach nauk technicznych (rozpoznawanie obrazów, przetwarzanie sygnałów, sterowanie, optymalizacja), ale coraz częściej w ekonomii i zarządzaniu. Od wielu lat proponowane są sztuczne systemy i programy komputerowe, które potrafią odtwarzać niektóre cechy intelektu naturalnego oraz obrazują procesy myślowe zachodzące u człowieka⁶⁹. Do najpowszechniej stosowanych metod sztucznej inteligencji można zaliczyć: sztuczne sieci neuronowe, zbiory rozmyte i logikę rozmytą, systemy ekspertowe, algorytmy genetyczne, algorytmy mrówkowe, algorytmy ewolucyjne, systemy hybrydowe oraz teorię chaosu⁷⁰. W monografii zaproponowano model sztucznej sieci neuronowej do analizy i modelowania kapitału społecznego przedsiębiorstw IT, zatem w dalszej części pracy szczególnie omówiono tylko to narzędzie.

⁶⁴ Tamże, s. 163.

⁶⁵ P. Lula, G. Paliwoda-Pękosz, R. Tadeusiewicz, dz. cyt., s. 14.

⁶⁶ Tamże., s. 13.


⁶⁷ Tamże, s. 14.

⁶⁸ A.M. Turing, *Computing Machinery and Intelligence*, „Mind, New Series” 236, 1950, vol. 59, s. 433–460.

⁶⁹ J.J. Mulawka, *Systemy ekspertowe*, Wydawnictwo Naukowo-Techniczne, Warszawa 1996, s. 17.

⁷⁰ J.S. Zieliński, *Inteligentne systemy w zarządzaniu. Teoria i praktyka*, Wydawnictwo Naukowe PWN, Warszawa 2000, s. 23.

Pionierskie prace nad poznaniem zasad funkcjonowania mózgu prowadził już pod koniec XIX wieku hiszpański histolog i neurobiolog – Santiago Ramón y Cajál⁷¹. Dokonał on bardzo istotnego odkrycia, że mózg nie jest jednolitą masą, oraz zaproponował nowatorską metodę obserwacji kształtu komórek nerwowych i ich połączeń (synapsy). Naukowiec ten został laureatem Nagrody Nobla w dziedzinie medycyny za badania nad strukturą układu nerwowego⁷². Historyczną pracą, w której po raz pierwszy zaprezentowano matematyczny opis komórki nerwowej i powiązано go z problemem przetwarzania danych, była praca Warrena S. McCullocha – amerykańskiego neurofizjologia i cybernetyka – oraz logika Waltera H. Pittsa⁷³. 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 alternatywą w stosunku do tradycyjnego programowania⁷⁴. Opracowany model stanowił podstawę do dalszych badań dotyczących potencjalnych możliwości zastosowania sprzężonych ze sobą sztucznych neuronów. Schemat neuronu McCullocha-Pittsa, składający się z n wejść i jednego wyjścia pokazano na rysunku 3.1.



RYSUNEK 3.1. Schemat neuronu McCullocha-Pittsa

ŹRÓDŁO: Opracowanie własne na podstawie: S. Haykin, *Neural networks. A comprehensive foundation*, Macmillan College Publishing Company, New York 1994.

Pod koniec lat czterdziestych XX wieku amerykański neuropsycholog Donald O. Hebb jako pierwszy odkrył, że informacje mogą być przechowywane w strukturze połączeń pomiędzy neuronami. W 1949 roku zaproponował on metodę uczenia sieci

⁷¹ Santiago Ramón y Cajál – profesor Uniwersytetu w Madrycie, Barcelonie i Walencji. Laureat Nagrody Nobla za badania nad strukturą układu nerwowego.

⁷² S. Ramón y Cajál, *Histology of the Nervous System of Man and Vertebrates*, „History of Neuroscience” 6, 1995, vol. 2.

⁷³ W.S. McCulloch, *A Logical Calculus of the Ideas Immanent in Nervous Activity*, „Bulletin of Mathematical Biophysics” 1943, vol. 5, s. 115–133.

⁷⁴ R. Tadeusiewicz, *Sieci neuronowe...*, dz. cyt., s. 8–12.

polegającą na zmianach wag połączeń między neuronami, nazywaną regułą Hebba⁷⁵. Pionierską siecią neuronową, zbudowaną w 1957 roku przez Franka Rosenblatta i Charlesa Wightmana w Cornell Aeronautical Laboratory, był perceptron. Była to pierwsza poprawnie działająca imitacja sieci nerwowej, której przeznaczeniem było rozpoznawanie znaków alfanumerycznych, z procesem uczenia jako metodą programowania systemu. Najprostszy perceptron był układem złożonym z dwóch warstw neuronów, w którym neurony warstwy wyjściowej odbierają sygnały z warstwy wejściowej. Ten ciekawy pomysł znalazł wielu naśladowców nie tylko w Stanach Zjednoczonych, ale i w Japonii, Europie i na terenach byłego Związku Radzieckiego⁷⁶.

W 1960 roku na Uniwersytecie Stanforda Bernard Widrow i Ted Hoff opracowali pierwszy komercyjny neurokomputer, zbudowany z uczących się elementów, noszących nazwę Adaline (ang. *Adaptive Linear Neuron*). Cała sieć, składająca się z 8 sztucznych neuronów o 128 połączeniach, nazwana została Madaline (ang. *Multiple-Adaline*) i jej stosowanie wiązano odtąd z adaptacyjnym przetwarzaniem sygnałów. Istotnym wydarzeniem w rozwoju badań nad sieciami neuronowymi było wydanie w 1969 roku książki Marvinina Minsky'ego i Seymoura Paperta pt. *Perceptrons*. W publikacji tej autorzy dowiedli, że możliwości zastosowania jednowarstwowych sieci wzorowanych na budowie perceptronu są ograniczone oraz nie pozwalają one na rozwiązanie wielu, nawet prostych problemów⁷⁷. Odkrycie to zniechęciło wielu badaczy do podejmowania badań nad sieciami neuronowymi oraz zahamowało rozwój tej dziedziny na około 15 lat. Jednak nawet w tym czasie opublikowano kilka znaczących prac w tym obszarze, a najistotniejsze okazały się publikacje prezentujące efektywne metody uczenia wielowarstwowych sieci neuronowych⁷⁸. Spośród nich na największą uwagę zasługuje **algorytm wstecznej propagacji błędów** (ang. *backpropagation algorithm*), zaproponowany niezależnie przez: Paula Werbosa (1974), M. Parkera (1982) oraz Davida Rumelharta (1986)⁷⁹. Metoda ta jest od wielu lat jedną z najefektywniejszych i najczęściej stosowanych algorytmów uczenia wielowarstwowej sieci typu perceptronowego. Duże znaczenie w rozwoju badań nad sztucznymi sieciami neuronowymi miała sieć ze sprzężeniem zwrotnym (sieć rekurencyjna), zaproponowana w 1982 roku przez Johna Josepha Hopfielda – amerykańskiego fizyka, związanego przez wiele lat z Bell Labs. Jako metody uczenia stosuje się w tym przypadku najczęściej regułę Hebba. Nawet obecnie sieć ta znajduje wiele zastosowań technicznych, między innymi służy do rozpoznawania obrazów oraz rozwiązywania problemów

⁷⁵ J. Korbicz, A. Obuchowicz, D. Uciński, *Sztuczne sieci neuronowe. Podstawy i zastosowania*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1994, s. 18–20.

⁷⁶ R. Tadeusiewicz, *Sieci neuronowe...*, dz. cyt., s. 8–10.

⁷⁷ M. Marvin, S. Papert, *Perceptrons: An Introduction to Computational Geometry*, The MIT Press, Cambridge 1969.

⁷⁸ J. Korbicz, A. Obuchowicz, D. Uciński, dz. cyt., s. 19.

⁷⁹ R.S. Sexton, R.E. Dorsey, J.D. Johnson, *Beyond backpropagation: using simulated annealing for training neural network*, „Journal of Organizational and End User Computing (JOEUC)” 3, 1999, vol. 11, s. 8.

optymalizacyjnych⁸⁰. W latach osiemdziesiątych XX wieku ponownie zwiększyło się zainteresowanie sieciami neuronowymi. Było to uwarunkowane osiągnięciem granicznych prędkości przetwarzania szeregowego informacji, stąd pomysł przetwarzania równoległego przez sieci neuronowe⁸¹.

Do dzisiaj zainteresowanie tematyką sztucznych sieci neuronowych jest wśród badaczy ogromne. Znajduje to swoje odzwierciedlenie w tysiącach książek oraz publikacji w czasopismach poświęconych tej problematyce. Na całym świecie są organizowane cykliczne konferencje, podczas których naukowcy udowadniają, że zastosowanie sieci neuronowych w badaniach naukowych jest wciąż aktualne i warto eksploracji. Ponadto należy podkreślić, że wiele przedsiębiorstw ma w swojej ofercie oprogramowanie umożliwiające zastosowanie sztucznych sieci neuronowych, co cieszy się dużym powodzeniem zarówno wśród naukowców, jak i praktyków pracujących w szeroko rozumianym biznesie.

3.2. Zastosowanie sztucznych sieci neuronowych w badaniach naukowych

Sztuczne sieci neuronowe należą do metod analizy danych o bardzo dużych możliwościach aplikacyjnych i dlatego są coraz powszechniej wykorzystywane alternatywnie do tradycyjnych metod analitycznych, zapewniając rzetelne wyniki. Ponadto często problemy badawcze są na tyle złożone i wielowymiarowe, że zawodzą dotychczas stosowane, klasyczne narzędzia. Na duże zainteresowanie badaczy implementacją sieci neuronowych wpływają niewątpliwie ich liczne zalety, wśród których najważniejsza, zdaniem autorki, jest zdolność do wykonywania obliczeń równoległych i możliwości przetwarzania dzięki temu dużych ilości informacji.

Jedną z istotnych własności sieci neuronowych jest ich zdolność do adaptacji oraz samoorganizacji. Cechy te są z powodzeniem wykorzystywane w zdecydowanej większości implementacji. Z dużym sukcesem metody te są stosowane do rozwiązywania problemów poruszanych w naukach technicznych. Praktyczne zastosowanie sieci neuronowych obejmuje między innymi następujące dziedziny⁸²:

- rozpoznawanie obrazów (analiza, klasyfikacja, grupowanie, przetwarzanie);
- rozpoznawanie dźwięków (na przykład mowy lub sygnałów sonarowych);
- rozpoznawanie ręcznie pisanych znaków;
- wykrywanie podejrzanych obiektów w bagażach lotniczych;

⁸⁰ R.A. Kosiński, *Sztuczne sieci neuronowe – dynamika nieliniowa i chaos*, Wydawnictwo Naukowo-Techniczne, Warszawa 2007, s. 56.

⁸¹ J. Korbicz, A. Obuchowicz, D. Uciński, dz. cyt., s. 20.

⁸² S. Osowski, *Sieci neuronowe w ujęciu algorytmicznym*, Wydawnictwo Naukowo-Techniczne, Warszawa 1996; R. Tadeusiewicz, *Sieci neuronowe...*, dz. cyt., s. 14–18; R. Knosala, *Zastosowanie metod sztucznej inteligencji w inżynierii produkcji*, Wydawnictwo Naukowo-Techniczne, Warszawa 2002, s. 178.

- diagnostyka, przetwarzanie i filtracja sygnałów (na przykład radarowych, sonarowych);
- optymalizacja;
- automatyka;
- sterowanie obiektów dynamicznych (automatów, robotów, procesów przemysłowych).

Modele sieci neuronowych są często wykorzystywane w badaniach ekonomicznych i w naukach o zarządzaniu i jakości jako efektywne narzędzia do predykcji i klasyfikacji. Sieci neuronowe znajdują w szczególności zastosowanie do⁸³:

- prognozowania zjawisk gospodarczych, przewidywania trendów na giełdzie i innych rynkach;
- prognozowania stóp procentowych i kursów walut;
- prognozowania cen, wielkości sprzedaży i kondycji finansowej przedsiębiorstw oraz modelowania zjawisk finansowych w przedsiębiorstwach (analiza kosztów, zmiany należności na rachunkach, inwestycje kapitałowe);
- określania ryzyka związanego z udzieleniem kredytu;
- prognozowania bankructwa instytucji finansowych (w tym przede wszystkim banków) oraz przewidywania upadłości firm;
- zarządzania stanem magazynów w przedsiębiorstwach;
- wspomagania podejmowania decyzji w zarządzaniu przedsiębiorstwem.

Należy również wspomnieć, że sieci neuronowe dzięki swojej zdolności do uczenia, adaptacji i uogólniania doświadczeń cechują się zdolnością do kojarzenia danych i identyfikacji istotnych powiązań między nimi, pozwalają zatem zautomatyzować procesy wnioskowania na podstawie zgromadzonych danych.

Warto także podkreślić, że sieci neuronowe (w tym przede wszystkim rekurencyjne sieci Hopfielda) wykorzystywane są często do poszukiwania optymalnych decyzji gospodarczych w różnych sektorach. Dobrym przykładem jest zastosowanie tych narzędzi do budowy modelu prognozującego cenę energii elektrycznej na giełdzie^{84, 85, 86}, czy też rozwiązanie przez taką sieć tak zwanego problemu komiwojażera⁸⁷.

⁸³ R. Herbrich, M. Keilbach, T. Graepel i in., *Neural Networks in Economics: Background, Applications and New Developments*, Advances in Computational Economics: Computational Techniques for Modeling Learning in Economics, Springer, New York 1999; J. Morajda, *Wybrane możliwości zastosowań sieci neuronowych w ekonomii i zarządzaniu*, „Zeszyty Naukowe Akademii Ekonomicznej”, nr 493, Kraków 1997, s. 61–71.

⁸⁴ H. Halicka, *Wykorzystanie sztucznych sieci neuronowych do prognozowania cen na giełdzie energii*, „Rynek Energii” 2010, nr 1, s. 20–23.

⁸⁵ E. Chodakowska, K. Halicka, A. Kononiuk, J. Nazarko, *Zastosowanie sztucznych sieci neuronowych do prognozowania cen energii elektrycznej na Towarowej Giełdzie Energii S.A* [w:] L. Kiełtyka, J. Nazarko (red.), *Technologie informatyczne i prognozowanie w zarządzaniu – wybrane zagadnienia*, Białystok 2005, s. 235–245.

⁸⁶ J. Nazarko, K. Halicka, *Electric energy prices forecasting on power exchange with the application of artificial neural networks*, 28th International Symposium on Forecasting, ISF'2008, Nice, France, June 22–25, 2008.

⁸⁷ R. Tadeusiewicz, *Sieci neuronowe...*, dz. cyt., s. 17–18.

Jedną z pierwszych publikacji, w których omówiono przykład zastosowania sieci neuronowych do prognozowania dziennej stopy zwrotu akcji w przedsiębiorstwie IBM, była praca Halberta White'a – profesora ekonomii na Uniwersytecie Kalifornijskim w San Diego. Autor zaproponował modele sieci neuronowych pozwalające na identyfikowanie oraz dekodowanie nieliniowych prawidłowości w zmianach cen aktywów⁸⁸. Ciekawe rozwiązania, wykorzystujące sieci neuronowe do analiz ekonomicznych, omówiono ponad 20 lat temu w artykułach następujących autorów: K.G. Coleman, T.J. Graettinger, W.F. Lawrence (1991)⁸⁹, R.R. Trippi (1993)⁹⁰ czy G. Zhang, B.E. Patuwo, M.Y. Hu (1998)⁹¹. Zastosowanie sztucznych sieci neuronowych do rozwiązywania problemów w ekonomii, na przykład przy przewidywaniu trendów na giełdzie, cieszy się także obecnie dużym zainteresowaniem badaczy z całego świata. Świadczy o tym rosnąca liczba publikacji w tym zakresie. Autorami, których warto wymienić, są: L.C. Martinez, D.N. da Hora, J.R. de M. Palotti, G.L. Pappa (Brazylia 2009)⁹², P.-Ch. Chang, Ch.-H. Liu, Ch.-Y. Fan, J.-L. Lin, Ch.-M. Lai (Tajwan 2009)⁹³ czy M. Janeski, S. Kalajdziski⁹⁴.

Sztuczne sieci neuronowe, ze względu na ich duży utylitaryzm, są z powodzeniem wykorzystywane w szeroko rozumianej diagnozie i profilaktyce zakażeń koronawirusem SARS-CoV-2 i wywoływanej nim choroby COVID-19. Martyniuk i in., wykorzystując sztuczne sieci neuronowe z radialnymi funkcjami bazowymi, dokonali analizy wpływu pandemii COVID-19 na rotację personelu, która jest jednym z najważniejszych wskaźników jego bezpieczeństwa⁹⁵. Hamadneh i in. zaproponowali model sztucznej sieci neuronowej do szacowania i prognozowania liczby potwierdzonych

⁸⁸ H. White, *Economic prediction using neural networks: the case of IBM daily stock returns*, IEEE International Conference on Neural Networks, vol. 2, San Diego 1988, s. 451–458.

⁸⁹ K.G. Coleman, T.J. Graettinger, W.F. Lawrence, *Neural networks for bankruptcy prediction: The power to solve financial problems*, „Artificial Intelligence Review” 4, 1991, s. 48–50.

⁹⁰ R.R. Trippi, E. Turban, *Neural Networks in Finance and Investment: Using Artificial Intelligence to Improve Real – World Performance*, Probus, Chicago, IL 1993.

⁹¹ G. Zhang, B.E. Patuwo, M.Y. Hu, *Forecasting with artificial neural networks: The state of the art*, „International Journal of Forecasting” 14, 1998, s. 35–62.

⁹² L.C. Martinez, D.N. da Hora, J.R. de M. Palotti i in., *From an artificial neural network to a stock market day-trading system: a case study on the BM&F BOVESPA*, IJCNN'09 Proceedings of the 2009 International Joint Conference on Neural Networks, „IEEE Press Piscataway” 2009, s. 3251–3258.

⁹³ P.-Ch. Chang, Ch.-H. Liu, Ch.-Y. Fan i in., *An ensemble of neural networks for stock trading decision making*, ICIC'09 Proceedings of the Intelligent computing 5th international conference on Emerging intelligent computing technology and applications, Springer-Verlag, Berlin 2009, s. 1–10.

⁹⁴ M. Janeski, S. Kalajdziski, *Neural network model for forecasting Balkan stock exchange*, ICIC'11 Proceedings of the 7th International Conference on Advanced Intelligent Computing, Springer-Verlag, Berlin 2011, s. 17–24.

⁹⁵ V. Martyniuk, N. Tsygylk, S. Skowron, *The Impact of the Covid-19 Pandemic on Key Indicators of Personnel Security: A Study with Neural Network Technologies*, European Research Studies Journal, vol. 24, „Special Issue” 2, 2021, s. 141–151.

i wykrytych przypadków COVID-19⁹⁶. H.R. Niazkar i M. Niazkar opracowali modele predykcyjne oparte na sztucznych sieciach neuronowych pozwalające na przewidywanie przebiegu i rozwoju pandemii COVID-19^{97, 98, 99}. Badacze ci proponują też wykorzystanie sztucznych sieci neuronowych do przewidywania przebiegu choroby u pacjentów¹⁰⁰.

Sztuczne sieci neuronowe są narzędziami, które mogą być stosowane do rozwiązywania problemów, w których algorytm postępowania jest trudny do skonstruowania, dane są niekompletne, a badane zjawisko ma charakter nieliniowy. Zatem od wielu lat sieci neuronowe stanowią sprawne i efektywne narzędzia, przy pomocy których rozwiązywanych jest wiele zadań z różnych dziedzin.

3.3. Budowa i działanie sztucznego neuronu

Sztuczny neuron jest to element, którego budowa i właściwości odpowiadają wybranym własnościom biologicznego neuronu. Pod koniec XIX wieku Santiago Ramón y Cajal odkrył, że mózg i system nerwowy nie stanowią jednolitej masy, a są strukturą złożoną z wielu komórek nerwowych, których budowę Cajal omówił jako pierwszy. System nerwowy człowieka zawiera około 1018 komórek, z których 1011 połączonych jest w sieci odpowiadające za funkcje inteligencji, emocji, zdolności i pamięci¹⁰¹. Ogólną budowę komórki nerwowej przedstawiono na rysunku 3.2.

Centralną częścią komórki nerwowej jest ciało, zwane somą, wewnątrz którego znajduje się jądro. Z somy wyrastają wypustki, pełniące istotną rolę w połączeniu z innymi komórkami, czyli cienkie i gęsto rozkrzewione dendryty oraz gruby, rozwidlający się na końcu akson. Synapsy doprowadzają do komórki sygnały wejściowe, natomiast sygnał wyjściowy odprowadzany jest za pomocą aksonu. Podczas przekazywania impulsu od jednej komórki do drugiej wydzielana jest substancja (neuromediator). Poszczególnym wejściom komórki przypisywane są współczynniki wagowe (wagi), odpowiadające ilości wydzielonego neuromediatora. Są one liczbami rzeczywistymi, przyjmującymi wartości dodatnie (działanie pobudzające) lub ujemne (działanie hamujące). W ten sposób pobudzona zostaje komórka nerwowa, przy czym dzięki

⁹⁶ N.N. Hamadneh, W.A. Khan, W. Ashraf i in., *Artificial neural networks for prediction of Covid-19 in Saudi Arabia*, *Computers, Materials & Continua* 3, 2021, vol. 66, s. 2787–2796.

⁹⁷ H.R. Niazkar, M. Niazkar, *Application of artificial neural networks to predict the COVID-19 outbreak*, „Global Health Research and Policy”, 5, 50, 2020.


⁹⁸ M. Shawaqfah M., A. Fares, *Forecast of the outbreak of COVID-19 using artificial neural network: Case study Qatar, Spain, and Italy*, „Results in Physics”, 2021, vol. 27.

⁹⁹ A. Azhari, A. Elhag, A. Tahani Aloafi, i in., *Artificial neural networks and statistical models for optimization studying COVID-19*, „Results in Physics” 25(4), 2021.

¹⁰⁰ W. Hariri, A. Narin, *Deep Neural Networks for COVID-19 Detection and Diagnosis using Images and Acoustic-based Techniques: A Recent Review*, *Soft Computing*, Springer, 2021.

¹⁰¹ J. Korbicz, A. Obuchowicz, D. Uciński, dz. cyt., s. 22.


uwolnieniu neuromediatora zmienia się potencjał elektryczny jej błony komórkowej. Reakcja neuronu jest odpowiedzią na skumulowane, zsumowane wartości wszystkich pobudzeń¹⁰².



RYSUNEK 3.2. Budowa komórki nerwowej

ŹRÓDŁO: Opracowanie własne na podstawie: J. Korbicz, A. Obuchowicz, D. Uciński, *Sztuczne sieci neuronowe...*, dz. cyt., s. 22.

Neuron jest zatem układem o wielu wejściach (synapsy) i tylko jednym wyjściu (akson). Może być przez to rozpatrywany jako przetwornik sygnałów, a jego uproszczony model zaprezentowano na rysunku 3.3¹⁰³.



RYSUNEK 3.3. Cybernetyczny model neuronu

ŹRÓDŁO: Opracowanie własne na podstawie: A. Korbicz, A. Obuchowicz, D. Uciński, dz. cyt.


Budowa i sposób przetwarzania impulsu w biologicznej komórce nerwowej człowieka były inspiracją do budowy sztucznych neuronów, podstawowych elementów sztucznej sieci neuronowej, odpowiedzialnych za przetwarzanie sygnałów wejściowych. Model takiego neuronu odzwierciedla mechanizm działania rzeczywistych komórek nerwowych, będących zasadniczymi elementami układu nerwowego. Pomimo

¹⁰² Strona internetowa Katedry Inżynierii Komputerowej Politechniki Białostockiej, <http://iisi.pcz.pl/nn/budowa.php> [dostęp: 12.07.2014].

¹⁰³ J. Korbicz, A. Obuchowicz, D. Uciński, dz. cyt., s. 23.

dużego podobieństwa pomiędzy nimi sztuczny neuron jest jednak uproszczonym naśladowcą biologicznego pierwowzoru¹⁰⁴. Dla ułatwienia w dalszej części monografii nazywany jest on neuronem. Analizując jego budowę (rysunek 3.4), należy wskazać, że podobnie jak biologiczny neuron przetwarzający impulsy wejściowe doprowadzane do komórki za pośrednictwem synaps przekształca on sygnały wprowadzane na jego wejście w pojedynczą wartość wyjściową. Własności biologicznych komórek nerwowych zostały odzwierciedlone w wielu modelach matematycznych, zbudowanych na podstawie i na wzór rzeczywistego neuronu.

Niekiedy podczas trenowania sieci neuronowej przydatne są wagi, które nie są związane z żadnym z sygnałów. Takie wyrazy wolne w równaniach opisujących neurony oraz całe sieci pozwalają lepiej reprezentować zadania, które sieć powinna rozwiązywać. Dla ujednolicenia opisu neuronów korzystających z takich wyrazów wolnych i tych, które z nich nie korzystają, wprowadza się często do struktury sieci neuronowej generatory sztucznego pseudosygnału, zwanego BIAS, oznaczonego na rysunku 3.4 kolorem niebieskim. Sygnał ten ma z definicji zawsze wartość +1 i jest podawany na dodatkowe wejście neuronu. Waga związana z tym sygnałem podlega trenowaniu podobnie jak wszystkie inne wagi, jednak w odpowiednich formułach algorytmu uczenia w miejscu rzeczywistych sygnałów – występuje BIAS¹⁰⁵.



RYСУNEK 3.4. Model sztucznego neuronu

ŹRÓDŁO: R. Tadeusiewicz, G. Paliwoda-Pękosz, P. Lula, dz. cyt., s. 79.

Każdy neuron posiada zależną od potrzeb liczbę wejść n oraz jedno wyjście. Na wejścia wprowadzane są numeryczne wartości wejściowe $x_1, x_2, \dots, x_n$, tworzące wektor wartości wejściowych $X = [x_1, x_2, \dots, x_n]$. Z każdym wejściem powiązany jest odpowiadający mu współczynnik wagowy. Wartości tych współczynników, zwanych **wagami synaptycznymi**, tworzą wektor wag neuronu $W = [w_1, w_2, \dots, w_n]$ i wyznaczone są automatycznie podczas uczenia sieci neuronowej¹⁰⁶.

W najprostszym przypadku zależność:

$$f(x) = x_1, x_2, \dots, x_n \quad (3.1)$$

¹⁰⁴ R. Tadeusiewicz, *Sieci neuronowe...*, dz. cyt., s. 8–12.

¹⁰⁵ R. Tadeusiewicz, M. Szaleniec, dz. cyt., Wrocław 2015, s. 23.

¹⁰⁶ R. Tadeusiewicz, P. Lula, G. Paliwoda-Pękosz, dz. cyt., s. 79–86.

może być rozpatrywana jako liniowa:

$$y = \sum_{i=1}^n w_i x_i \quad (3.2)$$

Sposób działania neuronu podzielić można na dwa etapy:

- wyznaczenie zagregowanej wartości wejściowej – faza ta realizowana jest za pomocą tak zwanej funkcji agregującej;
- wyznaczenie wartości wyjściowej neuronu, za co odpowiedzialna jest funkcja aktywacji, zwana też funkcją przejścia.

Agregacja danych wejściowych, przeprowadzana w neuronie, polega na zsumowaniu iloczynów wartości wejściowych i odpowiadających im współczynników wagowych i jest opisana wzorem¹⁰⁷:

$$s = \sum_{i=1}^n w_i x_i \quad (3.3)$$

albo na obliczeniu kwadratu odległości Euklidesa pomiędzy wektorem wartości wejściowych $\mathbf{X}$ a wektorem wag $\mathbf{W}$, co jest opisane wzorem:

$$s = \sum_{i=1}^n (w_i - x_i)^2 \quad (3.4)$$

Wyjście neuronu jest podane za pomocą relacji:

$$y = f(\mathbf{W}^T \mathbf{X}) = f\left(\sum_{i=1}^n w_i x_i\right) \quad (3.5)$$

gdzie:

n – liczba wejść;

$x_1, x_2, \dots, x_n$ – wartości sygnałów wejściowych dla neuronu;

$x_0 = \text{const} = 1$;

$w_1, w_2, \dots, w_n$ – wartości wag połączeń wejściowych dla danego neuronu, określające znaczenie poszczególnych wejść;

w_0 – składnik stały (ang. *bias*), reprezentujący wartość progową (z przeciwnym znakiem);

f – funkcja aktywacji, inaczej funkcja przejścia (ang. *transfer function*) określająca zależność wyjścia od ważonej sumy wejść.

¹⁰⁷ Tamże, s. 79–86.

Wektor wag zdefiniowany jest jako¹⁰⁸:

$$\mathbf{W} = [w_1, w_2, \dots, w_n]^T \quad (3.6)$$

gdzie:

T – symbol transpozycji;

$\mathbf{W}$ – wektor wyznaczający punkt w n -wymiarowej przestrzeni, zwanej przestrzenią wag.

Wektor $\mathbf{X}$ jest wektorem wejściowym:

$$\mathbf{X} = [x_1, x_2, \dots, x_n]^T \quad (3.7)$$

Biorąc pod uwagę powyższe założenia, równanie neuronu wyrażone może być jako iloczyn skalarny wektora wejść i wektora wag¹⁰⁹:

$$y = \mathbf{W} \cdot \mathbf{X} \quad (3.8)$$

Bardzo ważną rolę w historii sztucznych sieci neuronowych odegrał perceptron, który w odróżnieniu od sieci liniowych (*Adaline* oraz *Madaline*) zawierał nowy, nieliniowy element przetwarzający informację w każdym neuronie sieci. Taki zabieg był uzasadniony, bowiem neurony biologiczne są nieliniowe. Nieliniowy element może być wyrażony następującym równaniem:

$$y = \varphi(e) \quad (3.9)$$

gdzie:

$\varphi(\cdot)$ – wybrana funkcja nieliniowa;

sygnał e to pobudzenie neuronu zgodne z formułą przyjmowaną wcześniej dla sieci Adaline.

Przy wyznaczaniu wartości wyjściowej neuronu stosowana jest tak zwana funkcja aktywacji, oznaczana jako $f(\mathbf{w}^T \mathbf{x})$. Argumentem tej funkcji jest zagregowana wcześniej wartość wejściowa s . Sygnał s poddawany jest przetwarzaniu przez blok aktywacji, który opisany może być różnymi funkcjami, na przykład funkcją liniową czy funkcją skoku jednostkowego. Nieliniowy charakter funkcji aktywacji neuronu biologicznego najdokładniej opisuje funkcja sigmoidalna oraz funkcja tangensoidalna. Na rysunku 3.4 funkcja aktywacji została oznaczona jako $f(\cdot)$.

Rozważając dobór odpowiedniej funkcji aktywacji, należy wziąć pod uwagę jej różniczkowalność. Najprostsze oczywiście byłoby stosowanie funkcji nieróżniczkowalnych (na przykład funkcji progowych czy progowo-liniowych). Niestety, charakteryzują

¹⁰⁸ R Tadeusiewicz, *Sieci neuronowe...*, dz. cyt., s. 28.

¹⁰⁹ Tamże.

się one występowaniem punktów, w których pochodna nie istnieje, zatem funkcje te nie mogą być stosowane w sieciach uczonych za pomocą algorytmów wykorzystujących pochodne funkcji przejścia (jak na przykład powszechnie używany algorytm wstecznej propagacji błędów)¹¹⁰.

Przykładowe funkcje aktywacji zostały zaprezentowane w tabeli 3.1.

TABELA 3.1. Matematyczne definicje funkcji aktywacji


Funkcja	Wzór	Zakres
Liniowa	x	$(-\infty, +\infty)$
Logistyczna	$\frac{1}{1+e^{-x}}$	$(0,1)$
Hiperboliczna	$\frac{e^x - e^{-x}}{e^x + e^{-x}}$	$(-1,1)$
Wykładnicza	e^{-x}	$(0, +\infty)$
Softmax	$\frac{e^x}{\sum_i e^x}$	$(0,1)$
Suma jednostkowa	$\frac{x}{\sum_i x_i}$	$(0,1)$
Pierwiastek	$\sqrt{x}$	$(0, +\infty)$
Sinus	$\sin(x)$	$[0,1]$
Liniowa z nasyceniem	-1 , dla $x \leq -1$ x , dla $-1 < x < 1$ 1 , dla $x \geq 1$	$[-1,1]$
Progowa	0 , dla $x \leq 0$ 1 , dla $x \geq 1$	$[0,1]$

Źródło: Opracowanie własne.

Do najczęściej stosowanych funkcji aktywacji należą między innymi: funkcja sigmoidalna (logistyczna), tangensoidalna (hiperboliczna), funkcja liniowa, funkcja Gaussa¹¹¹. Na rysunku 3.5 pokazano przebiegi wybranych funkcji aktywacji neuronu.

¹¹⁰ J. Morajda, *Metody sztucznej inteligencji w zarządzaniu portfelem inwestycyjnym* (praca doktorska), Kraków 1999, s. 35.

¹¹¹ P. Sibi, A. Allwyn-Jones, P. Siddarth, *Analysis of different activation function using back propagation neural network*, „Journal of Theoretical and Applied Information Technology” 3, 2013, vol. 47, s. 1264–1268.




RYSUNEK 3.5. Wybrane wykresy funkcji aktywacji neuronu

ŹRÓDŁO: Opracowanie własne.

3.4. Klasyfikacja i uczenie sieci neuronowych

Możliwości przetwarzania informacji przez pojedynczy neuron są niewielkie, co powoduje, że powszechnie stosowane są ich połączenia w grupę neuronów, zwaną sztuczną siecią neuronową. Neurony w sieci ułożone są zazwyczaj w warstwach. Schematyczną budowę prostej wielowarstwowej sieci neuronowej przedstawiono na rysunku 3.6.



RYSUNEK 3.6. Schemat budowy prostej wielowarstwowej sieci neuronowej

ŹRÓDŁO: Opracowanie własne na podstawie: R. Tadeusiewicz, *Odkrywanie właściwości sieci neuronowych...*, dz. cyt.

Wartości wyjściowe neuronów jednej warstwy są wprowadzane jako wejścia warstwy następnej. Wyjątkiem jest warstwa pierwsza, do której doprowadzane są wartości z zewnątrz, oraz warstwa ostatnia, zwana wyjściową, której neurony wyznaczają wartości wysyłane na zewnątrz sieci jako sygnał wyjściowy. Warstwy pomiędzy wejściową a wyjściową nazywane są warstwami ukrytymi. Warstwa wejściowa odbiera sygnały i rozprowadza je po sieci, natomiast warstwa wyjściowa generuje sygnał wyjściowy, będący rozwiązaniem.

Sieci neuronowe charakteryzują się pewnymi cechami zbliżonymi do cech mózgu człowieka, bowiem wykazują zdolność uczenia i kojarzenia. Właściwości te są szeroko wykorzystywane w wielu dziedzinach nauki, gospodarki i życia. Sieci neuronowe mogą być implementowane do rozwiązywania czterech głównych typów zadań:¹¹²

- autoasocjacja – zadanie polegające na rekonstrukcji (odtworzeniu) obrazu na podstawie wcześniej zakodowanych w pamięci wzorców; zgodnie z tą regułą pracuje na przykład sieć Hopfielda, nazywana pamięcią skojarzeniową;
- heteroasocjacja – zadanie wiążące obrazy wejściowe z odpowiednimi wzorcami generowanymi jako obrazy wyjściowe (na przykład sieć z kontrpropagacją, ang. *counterpropagation network* – CP);
- klasyfikacja – zadanie mające na celu przypisywanie obrazów wejściowych od odpowiednich zbiorów definiowanych jako klasy, określone przez wzorce zapisane w sieci podczas uczenia; liczba wyjść odpowiada wtedy zdefiniowanej liczbie klas. Przykładem takiej sieci jest perceptron wielowarstwowy, sieć Adaline oraz Madaline;
- detekcja regularności – zadanie dotyczące samodzielnego wykrywania przez sieć istotnych cech w obrazach wejściowych i ich grupowaniu ze względu na podobieństwo tych cech; taki proces uczenia sieci nazywany jest uczeniem nienadzorowanym lub uczeniem bez nauczyciela; przykładem takiej sieci jest sieć Kohonena.

Przedstawiona klasyfikacja sieci neuronowych, przeprowadzona ze względu na rodzaj rozwiązywanych zadań obliczeniowych, jest bardzo istotna z uwagi na zastosowania. W literaturze przedmiotu sieci klasyfikowane są również z uwzględnieniem ich architektury¹¹³:

- sieci jednokierunkowe (ang. *feedforward networks*) – są to sieci, w których neurony ułożone są w warstwach o jednym kierunku przepływu sygnałów oraz o połączeniach międzywarstwowych tylko między sąsiednimi warstwami; przykładem jest perceptron wielowarstwowy, który posiada warstwę wejściową, wyjściową oraz jedną lub więcej warstw ukrytych;
- sieci rekurencyjne – są to sieci o połączeniach dwukierunkowych między elementami przetwarzającymi lub ze sprzężeniem zwrotnym; przykładem są między innymi maszyna Boltzman, będąca uogólnieniem sieci Hopfielda oraz sieć typu BAM;

¹¹² R. Knosala, *Zastosowanie metod sztucznej inteligencji w inżynierii produkcji*, Wydawnictwo Naukowo-Techniczne, Warszawa 2002, s. 179.

¹¹³ J. Korbicz, A. Obuchowicz, D. Uciński, dz. cyt., s. 27–31.

- sieci komórkowe – są to sieci o wzajemnych sprzężeniach między elementami przetwarzającymi znajdującymi się jedynie w najbliższym sąsiedztwie; zazwyczaj połączenia te są nieliniowe oraz opisane poprzez układ równań różniczkowych; przykładem jest samoorganizująca się mapa (SOM), czyli sieć Kohonena;
- sieci o radialnych funkcjach bazowych (sieci RBF, zwane lokalnymi) – w sieciach tych, zamiast jednej dla wszystkich neuronów funkcji aktywacji, stosowane są tak zwane radialne funkcje bazowe, definiowane osobno dla każdego neuronu; funkcja bazowa, zmieniająca się radialnie wokół jednego punktu, umożliwia neuronowi lokalne wyodrębnienie zbioru (skupiska) punktów wokół tego punktu¹¹⁴.

Należy podkreślić, że sieci neuronowe mogą być stosowane w praktycznie każdej sytuacji, kiedy pomiędzy zmiennymi zależnymi i niezależnymi istnieje rzeczywista zależność (lub kilka zależności), nawet jeśli są one bardzo skomplikowane i niewyraźne w klasyczny sposób poprzez korelacje czy różnice pomiędzy grupami przypadków. Zatem sztuczna sieć neuronowa to uniwersalny aproksymator, który często zapewnia wysoką efektywność modelowania nieliniowych zjawisk, a także złożonych wielkoskalowych problemów.

Ważną i praktycznie użyteczną własnością sieci neuronowych jest ich zdolność do predykcji. Problemy predykcyjne dzielą się na dwie kategorie¹¹⁵:

- klasyfikacja – celem zagadnień klasyfikacyjnych jest przydzielenie rozpatrywanego przypadku do jednej ze zdefiniowanych wcześniej klas. W charakterze przykładów można podać: rozpatrywanie wniosków kredytowych (udzielić kredytu danej osobie czy też nie), wykrywanie nowotworów (wykrycie lub wykluczenie nowotworu), rozpoznawanie podpisów (fałszywy bądź autentyczny) itp. W każdym z powyższych przypadków na wyjściu wymagana jest pojedyncza zmienna nominalna. Najczęściej rozważane zagadnienia klasyfikacyjne mają charakter dwustanowy, chociaż problemy wielostanowe również są często rozpatrywane;
- regresja – w zagadnieniach regresyjnych celem jest oszacowanie wartości ciągłej zmiennej wyjściowej, w sytuacji gdy znane są wartości zmiennych wejściowych. Problemy regresyjne mogą być rozwiązywane przy użyciu następujących typów sieci MLP, RBF, GRNN i sieci liniowych. Problemy regresyjne reprezentowane są w przez zbiory danych, w których zmienna wyjściowa (lub zmienne wyjściowe, bo sieć może mieć kilka wyjść) nie jest zmienną nominalną, lecz przeciwnie – ma charakter numeryczny. Co ważne, sieci neuronowe mogą rozwiązać zadanie związane z regresją wieloraką, której ogólnym celem jest analiza związków pomiędzy kilkoma zmiennymi niezależnymi (objaśniającymi) a jedną zmienną zależną (objaśnianą).

¹¹⁴ M. Flasiński, *Wstęp do sztucznej inteligencji*, Wydawnictwo Naukowe PWN, Warszawa 2011, s. 176.

¹¹⁵ Internetowy Podręcznik Statystyki, https://www.statsoft.pl/textbook/stathome_stat.html?https%3A%2F%2Fwww.statsoft.pl%2Ftextbook%2Fstneunet.html [12.10.2015].

W tej monografii autorka wykorzystała zdolność sieci neuronowych do rozwiązania problemu predykcyjnego (regresja wieloraka). Korzystając z własności sieci neuronowych, do budowy modelu regresyjnego zastosowano sieć jednokierunkową, której jedną z najważniejszych zalet jest, zdaniem autorki, zawsze stabilne zachowanie. W literaturze przedmiotu podaje się wprawdzie, że jeśli sieć ma wbudowane sprzężenie zwrotne, czyli połączenia powrotne od późniejszych do wcześniejszych neuronów, to może wykonywać bardziej skomplikowane obliczenia. Jednak na skutek krążenia sygnałów w takiej sieci rekurencyjnej ze sprzężeniem zwrotnym może ona zachowywać się niestabilnie i mieć bardzo złożoną dynamikę, w ramach której można oczekiwać bardziej skomplikowanych form zachowania – na przykład w formie chaosu deterministycznego. Sieci rekurencyjne są w związku z tym bardzo interesującym obiektem zainteresowania i skomplikowanych badań dla naukowców studiujących zachowania i możliwości sieci neuronowych, ale wśród praktyków korzystających z sieci neuronowych jako narzędzi obliczeniowych – jak dotąd panuje przekonanie, że do rozwiązywania rzeczywistych problemów bardziej przydatne są sieci o strukturze jednokierunkowej¹¹⁶.

Zasadniczym czynnikiem determinującym działanie sieci jest jej uczenie, a nie struktura. Głównym sposobem korzystania z sieci neuronowej staje się tworzenie modeli, czyli sformalizowanej struktury, odwzorowującej pewien proces czy zjawisko. Proces uczenia jest procesem iteracyjnym, powtarzanym wielokrotnie, krok po kroku, którego zasadniczym celem jest optymalizacja parametrów sieci, to jest współczynników wagowych¹¹⁷.

Zanim omówiony zostanie proces uczenia sieci, należy przeanalizować jego poszczególne etapy poprzedzające. Do neuronów warstwy wejściowej docierają sygnały wejściowe. 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 źródło wiedzy, inteligencji neuronu. Im większa jest wartość wagi, tym dana zmienna jest istotniejsza¹¹⁸. Sygnały wejściowe są rozsyłane do wszystkich neuronów warstwy ukrytej, które następnie zostają aktywizowane: wykorzystują one zgromadzoną w swoich wagach wiedzę – najpierw modyfikują sygnały wejściowe, następnie agregują je, a potem korzystając ze swoich funkcji aktywacji, wyliczają sygnały wyjściowe. Sygnały te są wysyłane do neuronów warstwy wyjściowej. Jest to bardzo istotny etap przetwarzania informacji w sieci neuronowej, ponieważ znaczna część informacji zgromadzonych w trakcie przetwarzania sygnałów zlokalizowana jest

¹¹⁶ Strona internetowa, http://www.statsoft.pl/textbook/stathome_stat.html?http%3A%2F%2Fwww.statsoft.pl%2Ftextbook%2Fstneunet.html [dostęp: 11.04.2015].

¹¹⁷ J. Siderska, *Analiza możliwości zastosowania sieci neuronowych do modelowania wartości kapitału społecznego w firmach IT*, „Ekonomia i Zarządzanie” 2013, t. 5 (1).

¹¹⁸ P. Lula, G. Paliwoda-Pękosz, R. Tadeusiewicz, dz. cyt., s. 79–86.

w tej warstwie. Neurony w warstwie wyjściowej korzystają z przetworzonej w warstwie ukrytej informacji oraz obliczają wyniki, będące końcowym rozwiązaniem postawionego problemu¹¹⁹.

Uczenie sieci neuronowej polega zatem na wyznaczaniu wartości współczynników wagowych (w_{ij}) połączeń pomiędzy i -tymi i j -tymi elementami przetwarzającymi¹²⁰. Techniki uczenia sieci podzielono na:¹²¹

- uczenie nadzorowane (tak zwane *uczenie z nauczycielem*) – polega na tym, że na wejście neuronu podawane są sygnały, dla których znane są prawidłowe wartości sygnałów wzorcowych na wyjściu. Takie próbki wejściowe oraz odpowiadające im wartości sygnałów wzorcowych nazywa się zbiorami (ciągami) wzorcowymi. Po podaniu wartości wejściowych obliczane są sygnały wyjściowe neuronu, a następnie, aby zminimalizować błąd między sygnałem wzorcowym, modyfikowane współczynniki wagowe;
- uczenie nienadzorowane (tzw. *uczenie bez nauczyciela*) – stosowane jest w przypadkach, kiedy nie są znane prawidłowe odpowiedzi, wzorce dla zbioru danych – nie istnieje zatem żadne sprzężenie zwrotne. W pewnym sensie elementy i połączenia muszą wykazywać się w tym przypadku zdolnością do samoorganizacji.

Najpowszechniej stosowanym i najskuteczniejszym algorytmem nadzorowanego uczenia wielowarstwowej sieci neuronowej jest algorytm wstecznej propagacji błędów (ang. *backpropagation*)¹²², będący metodą pozwalającą na modyfikację wag w sieci o architekturze warstwowej. Jego istota polega na tym, że wyznaczony błąd d , występujący podczas realizacji pojedynczego kroku procesu uczenia, jest propagowany wstecz do wszystkich neuronów, których sygnały wyjściowe stanowiły wejścia dla rozważanego neuronu. Trenowanie sieci neuronowej oraz metoda wstecznej propagacji błędów zostaną bardziej szczegółowo opisane w rozdziale piątym.

Obszary zastosowań sieci neuronowych ulegają rozszerzaniu, ponieważ mogą być one z powodzeniem używane wszędzie tam, gdzie do rozwiązania są problemy wymagające szybkiego i sprawnego przetwarzania dużych zbiorów danych oraz ich analizy. Popularność i powodzenie stosowania sieci neuronowych wynikają z ich licznych zalet. 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

¹¹⁹ R. Tadeusiewicz, *Odkrywanie właściwości sieci neuronowych...*, dz. cyt., s. 77–81.

¹²⁰ R. Tadeusiewicz, *Sieci neuronowe...*, dz. cyt., s. 33–37.

¹²¹ L. Rutkowski, *Metody i techniki sztucznej inteligencji*, Wydawnictwo Naukowo PWN, Warszawa 2009, s. 170.

¹²² D.E. Rumelhart, G.E. Hinton, R.J. Williams, *Learning Internal Representations by Error Propagation* [w]: *Parallel Distributed Processing*, MIT Press, Cambridge, MA 1986.

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 rozwiązania problemu regresyjnego może być zatem metodą zastępczą, alternatywą na przykład dla regresji wielorakiej, lub też poprzedzać bardziej zaawansowane studia.

Omówione w tym rozdziale możliwości aplikacyjne sztucznych sieci neuronowych oraz liczne zalety tych narzędzi uzasadniają propozycję wykorzystania sieci neuronowych do modelowania i analizy kapitału społecznego firm informatycznych.

4. Budowa modelu neuronowego

Zasadniczym celem tego rozdziału jest przedstawienie wyników przeprowadzonego przez autorkę procesu, mającego na celu opracowanie modelu sztucznej sieci neuronowej oraz zaproponowanie jej parametrów i struktury. Przeprowadzono liczne symulacje komputerowe w pakiecie statystycznym STATISTICA Automatyczne Sieci Neuronowe (SANN), których celem był wybór takiej struktury i parametrów sieci neuronowej, dla których jakość sieci ma najwyższą wartość. Przeanalizowano sieci neuronowe różniące się: liczbą neuronów w poszczególnych warstwach, algorytmem uczenia, rodzajami funkcji aktywacji czy funkcji błędu. W analizowanym przypadku zastosowano uczenie nadzorowane, z wykorzystaniem metody wstecznej propagacji błędów.

4.1. Założenia badawcze

Głównym celem prac badawczych było opracowanie modelu regresyjnego, czyli funkcji określającej zależność wartości oczekiwanej zmiennej objaśnianej (wartości kapitału społecznego) od zmiennych objaśniających, oraz na tej podstawie modelu sztucznej sieci neuronowej, pozwalającego na identyfikację zależności pomiędzy zmiennymi wejściowymi a zmienną wyjściową (wartością kapitału społecznego przedsiębiorstw informatycznych), oraz do szacowania wartości kapitału społecznego. Dodatkowym celem było opracowanie w języku C++ aplikacji realizującej algorytm obliczeniowy i umożliwiającej szacowanie wartości kapitału społecznego przedsiębiorstw informatycznych.

Narzędziem i środowiskiem do budowy i testowania modelu sieci neuronowej oraz do szacowania wartości kapitału społecznego przedsiębiorstw IT był pakiet statystyczny **STATISTICA (moduł Automatyczne Sieci Neuronowe)**. Wybrano to oprogramowanie z uwagi na jego liczne zalety, wśród których warto wymienić następujące¹²³:

- prostota obsługi połączona z bardzo dużą mocą analityczną;
- algorytmy uczące zbudowane na bazie najnowszych rozwiązań są w wysokim stopniu zoptymalizowane (w tym algorytm gradientów sprzężonych i zastosowany w opracowanym modelu algorytm Broyden–Fletcher–Goldfarb–Shanno, zwany dalej BFGS);

¹²³ Strona internetowa firmy Statsoft, producenta oprogramowania STATISTICA; www.statsoft.pl, [dostęp: 04.06.2016].

- możliwość wyboru funkcji aktywacji, funkcji błędu i złożoności sieci;
- szeroki wybór narzędzi graficznych i statystycznych umożliwiających interakcyjną analizę eksploracyjną.

Nie bez znaczenia przy wyborze środowiska do pracy był również fakt, że nadzór merytoryczny nad przygotowywaniem modułu Automatyczne Sieci Neuronowe w pakiecie STATISTICA sprawowali prof. Ryszard Tadeusiewicz oraz prof. Paweł Lula, znakomici specjaliści w dziedzinie sieci neuronowych. Ponadto byli oni autorami dokumentacji na temat teorii i praktyki sztucznych sieci neuronowych, z której autorka korzystała podczas opracowywania założeń do modelu sztucznej sieci neuronowej.

STATISTICA Automatyczne Sieci Neuronowe (SANN) umożliwia konstruowanie sieci neuronowych najważniejszych typów, takich jak:

- perceptrony wielowarstwowe (ang. *Multilayer Perceptrons*);
- sieci o radialnych funkcjach bazowych (ang. *Radial Basis Function Networks*);
- samoorganizujące się mapy cech Kohonena (ang. *Self-Organizing Maps*);
- sieci liniowe (ang. *Linear Networks*).

Wymienione architektury sieciowe mogą być stosowane w przypadku rozwiązywania problemów:

- regresyjnych – sieć uczona jest oceniania istotności poszczególnych wejść i ich wpływu na wartość zmiennej wyjściowej;
- klasyfikacyjnych – na wyjściu sieć klasyfikuje, segmentuje dane wejściowe;
- prognozowania szeregów czasowych – sieć daje prognozę przyszłej wartości zmiennej;
- analizy skupień – sieć potrafi zgrupować podobne zmienne w klasy, kategoryzuje je, kwalifikuje do klas.

W tej monografii autorka wykorzystała sztuczne sieci neuronowe jako instrument do rozwiązywania problemu regresyjnego. Wybrano regresję, ponieważ istota problemu badawczego, którego rozwiązanie stanowi cel główny tej monografii, polega na badaniu zależności pomiędzy zbiorem zmiennych objaśniających a zmienną objaśnianą. Tradycyjna regresja liniowa, służąca estymowaniu wartości oczekiwanej zmiennej objaśnianej, wykorzystana może być tylko do analizowania danych powiązanych liniowo. Założenie, że zależności pomiędzy zmiennymi mają charakter liniowy, nie miałyby w tym przypadku uzasadnienia merytorycznego.

W praktyce zastosowanie regresji sprowadza się do dwóch etapów¹²⁴:

- Skonstruowania modelu regresyjnego, czyli funkcji określającej zależność wartości oczekiwanej zmiennej objaśnianej od zmiennych objaśniających. Funkcja ta może być określona za pomocą wzoru matematycznego, algorytmu (drzewo regresyjne, sieć neuronowa itp.). Budowa modelu powinna odzwierciedlać dane ze zbioru uczącego, zawierającego zarówno zmienne objaśniające, jak i objaśniane.


¹²⁴ J. Koronacki, J. Ćwik, *Statystyczne systemy uczące się*, Wydawnictwa Naukowo-Techniczne, Warszawa 2005, s. 157–193.

- Zastosowania opracowanego modelu (ang. *scoring*) do danych, w których znane były wartości tylko zmiennych objaśniających, w celu wyznaczenia wartości oczekiwanej zmiennej objaśnianej.

Skuteczne przetwarzanie informacji podczas pracy sieci neuronowej jest uzależnione od poprawnego określenia¹²⁵:

- przyjętych modeli neuronów – a zatem wybranych funkcji agregacji oraz funkcji aktywacji dla neuronów w poszczególnych warstwach sieci;
- wartości współczynników wagowych neuronów, ustalanych automatycznie podczas trenowania sieci neuronowej;
- liczby warstw sieci;
- liczby neuronów w poszczególnych warstwach sieci;
- przyjętych sposobów połączeń neuronów.

Bardzo istotne było, aby model adekwatnie odzwierciedlał istniejące w rzeczywistości powiązania pomiędzy zestawem zmiennych wejściowych (objaśniających) a zmienną objaśnianą (wyjściową). Przyjęto założenie, że zmienna objaśniana, odpowiadająca wartości kapitału społecznego przedsiębiorstwa na koniec każdego kwartału, jest powiązana ze zmiennymi wejściowymi, tak jak to przedstawiono na rysunku 4.1.



RYSUNEK 4.1. Uproszczony schemat przetwarzania sygnałów wejściowych przez sztuczną sieć neuronową

ŹRÓDŁO: Opracowanie własne.

Celem eksperymentów było nauczenie sieci wzorców zależności, które mogłyby być generalizowane, czyli uogólniane na nowe przypadki, które nie znajdowały się w zbiorze uczącym podczas procesu trenowania sieci¹²⁶.

Przy budowie sieci neuronowych jedną z pierwszych, ale strategicznych decyzji jest wybór zmiennych wejściowych. W początkowych fazach projektowania struktury sieci projektant powinien opierać się na intuicji oraz znajomości specyfiki badanych zagadnień. Pozwala to na wybór sygnałów wejściowych, oddziałujących w istotny sposób na wyjście sieci neuronowej. Dlatego też struktura pierwszej sieci, opracowywanej do rozwiązywania określonego problemu, powinna uwzględniać wszystkie zmienne,

¹²⁵ P. Lula, G. Paliwoda-Pękosz, R. Tadeusiewicz, dz. cyt., s. 84.

¹²⁶ J. Siderska, *Analiza możliwości zastosowania sieci neuronowych...*, dz. cyt., s. 88.

które zdaniem projektanta mają znaczenie. Zbiór ten, w wyniku przeprowadzonych symulacji i eksperymentów, podlega w dalszej kolejności redukcji¹²⁷. Taki tok postępowania przyjęto w przeprowadzonym procesie badawczym.

4.2. Dobór zmiennych wejściowych

Przy wyborze zmiennych do zbioru wejściowego konieczne jest uwzględnienie kilku istotnych kwestii¹²⁸:

- Wielowymiarowość – należy mieć świadomość, że każdy dodatkowy neuron w warstwie wejściowej zwiększa wymiar przestrzeni danych, a przez to komplikuje strukturę całej sieci. N -wymiarowa przestrzeń sygnałów wejściowych musi być wypełniona przez odpowiednią liczbę punktów uczących, aby możliwe było poznanie istniejącej struktury powiązania między danymi i odwzorowanie jej właściwości. W tym celu rozważać powinno się około $2N$ elementów zbioru danych, a dowolne zwiększanie liczności zmiennych wejściowych nie jest zalecane, gdyż powoduje konieczność posiadania wielu obserwacji, aby dane były reprezentatywne.
- Współzależność między zmiennymi – zidentyfikowanie tylko istotnych zmiennych wejściowych nie jest niestety możliwe, gdyż ważne i przydatne informacje mieszczą się zazwyczaj we współwystępowaniu zmiennych.
- Redundacja zmiennych – w przypadku występowania wielu, silnie skorelowanych zmiennych wejściowych, zaleca się użycie tylko pewnego podzbioru z nich, co jest konsekwencją problemu wymiaru wejściowego wektora danych.

Analiza piśmiennictwa z zakresu szacowania wartości niematerialnych pozwoliła na zidentyfikowanie zbioru zmiennych objaśniających, wpływających na kapitał społeczny przedsiębiorstwa. Spośród nich do pierwszych analiz wybrano 12 zmiennych wejściowych o charakterze ilościowym: liczba akcji, cena akcji, wartość księgowa, zysk netto, wartość giełdowa, aktywa, zobowiązania, przychody ogółem, dochód netto, zatrudnienie, liczba klientów oraz zysk na jednego zatrudnionego. Analiza zmiennych jakościowych jest także możliwa w pakiecie STATISTICA. Wymagałoby to przekształcenia ich wartości do postaci numerycznej, czyli dogodnej do przetworzenia przez sieć neuronową (na przykład przy zastosowaniu metody *jeden-z-N*, w której każdej wartości zmiennej przyporządkowuje się wektor wartości binarnych). Modelowanie wartości kapitału społecznego jest problemem regresyjnym, stąd na wyjściu znajduje się tylko jeden neuron charakteryzujący zmienną objaśnianą, czyli wartością kapitału społecznego.

¹²⁷ P. Lula, R. Tadeusiewicz, *STATISTICA Neural Networks PL. Przewodnik problemowy*, StatSoft, Kraków, 2001.

¹²⁸ P. Wójtowicz, *Polska wersja STATISTICA Neural Network*, Statsoft, Kraków, s. 15.

Autorka miała świadomość, że zbiór tych zmiennych jest zbyt liczny w odniesieniu do analizowanego problemu. Dodatkowo zauważono zjawisko redundancji zmiennych, zatem konieczne było zredukowanie części informacji i użycia tylko podzbioru z nich. Opierano się także na rekomendacjach R. Tadeusiewicza, z których wynika, że w celu zabezpieczenia przed przeuczeniem sieci neuronowej przyjmuje się, że najbardziej korzystna jest mała liczba zmiennych wejściowych. Zaleca się zatem odrzucenie części zmiennych zawierających nawet oryginalne dane. Jedyną metodą, która gwarantuje najlepszy wybór zbioru zmiennych wejściowych, jest wypróbowanie wszystkich możliwych zestawów i architektur sieci. Jednak w praktyce, przy dużej liczbie zmiennych jest to niemożliwe¹²⁹.

Z przeprowadzonego przeglądu literatury wynika, że nie zaproponowano jeszcze jednej, powszechnie akceptowanej i stosowanej metodologii optymalnego doboru zmiennych wejściowych. W literaturze opisuje się kilka metod najczęściej używanych do wstępnej analizy i redukcji (preprocessingu) danych wejściowych:

- metoda siłowa – tworzone są sieci wykorzystujące wszystkie możliwe podzbiory zbioru danych wejściowych. Jeżeli zostanie zastosowana taka sama metoda uczenia do wszystkich tych sieci, to wybór najlepszego zestawu danych wejściowych może być podyktowany najmniejszą wartością błędu uzyskanego po uczeniu na zbiorze walidacyjnym;
- usuwanie danych silnie skorelowanych – metoda polega na wyznaczeniu korelacji par danych wejściowych i usunięcie jednej ze zmiennych z tych par, dla których współczynnik korelacji jest większy niż przyjęty próg, na przykład 0,9;
- usuwanie danych o niskiej wariancji – jeżeli wariancja zmiennej wejściowej jest niska, to jej wartość informacyjna jest najprawdopodobniej niewielka i można ją pominąć;
- analiza wrażliwości – analiza ta pozwala na identyfikację najistotniejszych zmiennych wejściowych poprzez analizę wzrostu błędu w przypadku usunięcia z danych wejściowych poszczególnych zmiennych;
- transformacja PCA – pozwalająca na przekształcenie danych wejściowych (wektora o wielu składowych) do takiej postaci, w której podobną ilość istotnej informacji uzyskuje się z zastosowaniem wektora o mniejszej liczbie składowych (transformacji PCA nie zastosowano, ponieważ uzyskane dzięki niej składowe wektora są zdekorowane, to znaczy, że ich wzajemne korelacje są zerowe);
- algorytmy genetyczne – wybiera się struktury sieci, które poddawane są trenowaniu i konfrontuje się z zadaniem, które należy rozwiązać. Następnie przeprowadza się selekcję i poddaje operacji krzyżowania te, które taką selekcję przeszły. Krzyżowanie polega na tym, że wybrane losowo pary rozwiązań wymieniają losowo wybrane części parametrów, tworząc rozwiązania potomne, które po wprowadzenie dodatkowych korekt (mutacji) zastępują w populacji rozwiązania rodzicielskie;
- genetyczne sieci neuronowe – stanowią połączenie optymalizacji z zastosowaniem algorytmów genetycznych oraz modelowania za pomocą sieci neuronowych.

¹²⁹ R. Tadeusiewicz, *Wprowadzenie do sieci neuronowych...*, dz. cyt.

Przeprowadzono selekcję zmiennych wejściowych w celu zmniejszenia liczby wag, które muszą zostać wyznaczone podczas trenowania sieci neuronowej. Zastosowano metodę usuwania danych silnie skorelowanych oraz globalną analizę wrażliwości, która umożliwiła wybór tylko tych zmiennych, które istotnie wpływają na wyjście sieci neuronowej. W tabeli 4.1 przedstawiono wartości analizy wrażliwości wszystkich 12 zmiennych wejściowych, które w początkowym etapie eksperymentów były wybrane do analiz. Interpretacja tych wartości jest taka, że gdy zmienna objaśniająca ma wartość globalnej analizy wartości powyżej 1, to istotnie wpływa ona na zmienną objaśnianą i należy ją uwzględnić w modelu. Wartości takie zostały w tabeli 4.1 zaznaczone pogrubioną czcionką. Wyniki te pozwoliły na wskazanie zmiennych, które powinny zostać uwzględnione w modelu neuronowym. Są to: liczba akcji, cena akcji, wartość giełdowa, aktywa, zobowiązania, zatrudnienie.

TABELA 4.1. Wartości globalnej analizy wrażliwości dla 12 zmiennych wejściowych

Nazwa zmiennej wejściowej	Wartość analizy wrażliwości dla zmiennej
Liczba akcji	1,37
Cena akcji	1,55
Wartość księgowa	0,88
Zysk netto	0,87
Wartość giełdowa	2,55
Aktywa	2,11
Zobowiązania	1,66
Przychody ogółem	1,43
Dochód netto	1,11
Zatrudnienie	1,22
Liczba klientów	0,75
Zysk na jednego zatrudnionego	0,84

ŹRÓDŁO: Opracowanie własne.

Do dalszych analiz zaangażowane zostały zatem następujące zmienne wejściowe (objaśniające):

- wartość giełdowa – zmienna ilościowa [mln dol.], obliczona jako iloczyn liczby akcji będących w obrocie i ceny jednej akcji na zamknięciu kwartału;
- aktywa – zmienna ilościowa [mln dol.];
- zobowiązania – zmienna ilościowa [mln dol.];
- przychody ogółem [mln dol.];
- dochód netto [mln dol.];
- zatrudnienie – zmienna ilościowa [szt.], rozumiana jako liczba wszystkich pracowników przedsiębiorstwa.

W dalszej części tego rozdziału zostanie pokazane, że taki model sieci neuronowej (z 6 zmiennymi zaproponowanymi zmiennymi wejściowymi) jest właściwym i przydatnym narzędziem do szacowania wartości kapitału społecznego.

Regresyjny model teoretyczny został opisany wzorem 4.1, który ilustruje założenia dotyczące wyboru zmiennych objaśniających wpływających na zmienną objaśnianą:

$$V(SC, t) = f(MV, A, L, TR, NI, Emp) \quad (\text{dla każdego } t) \quad (4.1)$$

gdzie:

SC (ang. *social capital*) – wartość kapitału społecznego firmy;

MV (ang. *market value*) – wartość giełdowa (rynkowa);

A (ang. *assets*) – aktywa;

L (ang. *liabilities*) – zobowiązania;

TR (ang. *total revenue*) – przychód ogółem;

NI (ang. *net income*) – dochód netto;

Emp (ang. *employment*) – zatrudnienie.

Zmienna objaśniana (wyjściowa), czyli wartość kapitału społecznego, została obliczona przy użyciu równania fundamentalnego, na podstawie danych finansowych zawartych w bilansach księgowych publikowanych przez analizowane firmy na koniec każdego kwartału w okresie od I kwartału 2006 do końca 2020 roku.

Sformułowany wzorem 4.1 regresyjny model teoretyczny zastosowano następnie do eksperymentów związanych z opracowaniem struktury i testowaniem sztucznej sieci neuronowej.

4.3. Zbiór uczący

Określenie liczby przypadków wymaganych do trenowania sieci neuronowej, czyli właściwego rozmiaru zbioru uczącego, jest trudne. W literaturze przedmiotu podaje się jednak pewne reguły heurystyczne, które uzależniają liczbę wymaganych przypadków uczących od rozmiaru sieci neuronowej. Podstawowa z tych reguł, opracowana i rekomendowana przez R. Tadeusiewicza, zakłada, że liczba przypadków powinna być około dziesięciokrotnie większa od liczby połączeń występujących w sieci neuronowej. Liczba ta zdeterminowana jest także zależnością funkcyjną poddawaną modelowaniu. Niestety, zazwyczaj zależność ta ma nieznaną postać, dlatego precyzyjny i trafny wybór liczby elementów ciągu uczącego jest trudny¹³⁰.

¹³⁰ Strona internetowa, http://www.statsoft.pl/textbook/stathome_stat.html?http%3A%2F%2Fwww.statsoft.pl%2Ftextbook%2Fstneunet.html%23multilayerc [dostęp: 19.07.2015].

Zbiór danych uczących obejmował informacje dotyczące 180 przypadków, to jest kwartałów wyznaczonych dla trzech przedsiębiorstw informatycznych w okresie od 2006 do 2020 roku:

- Microsoft – największego producenta oprogramowania na świecie;
- Red Hat Corp. – światowego lidera w dostarczaniu oprogramowania otwartego dla środowiska biznesowego;
- Asseco Poland S.A. – największego przedsiębiorstwa informatycznego w Polsce.

W tabeli 4.2 przedstawiono przykład danych dla przedsiębiorstwa Red Hat, charakteryzujących sześć zmiennych wejściowych oraz wartość zmiennej wyjściowej (kapitału społecznego obliczonego za pomocą równania fundamentalnego) w I kwartale 2014 roku. Zbiór uczący zawierał 180 przypadków, czyli wierszy danych z poszczególnych kwartałów lat 2006–2020 dla wymienionych przedsiębiorstw.

TABELA 4.2. Wartości danych wejściowych i kapitału społecznego w firmie Red Hat w I kwartale 2014 roku

Wartość giełdowa [mln dol.]	Aktywa razem [mln dol.]	Zobowiązania [mln dol.]	Przychody ogółem [mln dol.]	Dochód netto [mln dol.]	Zatrudnienie [szt.]	Kapitał społeczny [mln dol.]
X_1	X_2	X_3	X_4	X_5	X_6	Y
10 018,518	2 654,933	1 555,45	400,397	45,068	6 500	5 460,952

ŹRÓDŁO: Opracowanie własne.

Bardzo istotne było, aby zbudowana sieć neuronowa miała zdolność do generalizacji, czyli do oddawania prawdziwego charakteru zależności i uogólniania wiedzy na nowe przypadki. Sieć powinna prawidłowo funkcjonować na zbiorze danych, który nie był poddany uczeniu. Aby zwiększyć zdolność sieci do takiego uogólniania danych, zbiór uczący podzielono na trzy podzbiory:

- próba ucząca, do której trafiło 90% wszystkich przypadków. Dane zgromadzone w tym podzbiorze służą do monitorowania procesu uczenia cykl po cyklu oraz do określenia, kiedy zakończyć trenowanie sieci. Tylko te 90% danych zostało poddanych procesowi trenowania;
- próba walidacyjna, zawierająca 5% wszystkich przypadków, nieużywanych podczas uczenia sieci, pozwalająca na ocenę sieci po zakończeniu procesu trenowania;
- próba testowa, do której trafiło 5% wszystkich przypadków, nieużywanych podczas uczenia sieci, umożliwiającą oszacowanie wag.

Wszystkie opisane w dalszej części tego rozdziału kroki algorytmu poszukiwania optymalnego modelu opierają się na kluczowym założeniu stwierdzającym, że dane należące do zbioru uczącego, walidacyjnego i testowego są reprezentatywne dla opisywanej zależności. Najważniejsze dla badania były obserwacje zgromadzone w podzbiorze walidacyjnym, ponieważ przypadki te nie zostały poddane procesowi trenowania

sieci. Takie rozwiązanie pozwala na wskazanie jakości sieci neuronowej, to jest ocenę zdolności sieci do generalizacji danych, czyli uogólniania wiedzy na nowe przypadki (nieznające się w zbiorze uczącym). Pozostawienie części danych w próbie walidacyjnej pozwala na zatrzymanie uczenia w oparciu o zbiór uczący i możliwość oceny trafności sieci na danych nieużywanych w procesie trenowania.

4.4. Struktura i parametry sieci neuronowej

Kolejnym krokiem w prowadzonym procesie badawczym było opracowanie struktury sieci neuronowej. Wiązało się to z określeniem takich elementów, jak: typ sieci neuronowej, liczba warstw ukrytych, liczba neuronów w warstwie ukrytej, zastosowana funkcja aktywacji w neuronach ukrytych i wyjściowym oraz zaimplementowana funkcja błędu. Przeprowadzono wiele eksperymentów umożliwiających wybór takich cech modelu, które pozwalały na zbudowanie sieci dającej najlepsze wyniki i najwyższą jakość w zbiorze walidacyjnym. Jest to bardzo istotna kwestia, ponieważ niewłaściwy dobór struktury i cech sieci może znacznie pogorszyć zdolności sieci do predykcji oraz do ekstrapolacji wyników. W dalszej części tego podrozdziału pracy omówiono wyniki heurystycznych poszukiwań najlepszej architektury sieci oraz przeprowadzonych testów i zaprezentowano otrzymaną strukturę sieci neuronowej.

Istotnym momentem podczas projektowania sieci neuronowej jest wybór jej typu, ponieważ powinien on uwzględniać charakter modelowanego zjawiska. Pakiet statystyczny STATISTICA Automatyczne Sieci Neuronowe (SANN) umożliwia wybór jednego z dwóch typów sieci neuronowej: MLP (*Multi-Layer Perceptron*, zwany perceptronem wielowarstwowym) oraz RBF (sieć o radialnych funkcjach bazowych). Zasadnicza różnica pomiędzy tymi sieciami polega na różnym działaniu warstwy ukrytej oraz na różnym sposobie działania tych sieci. W przeciwieństwie do perceptronu w sieciach RBF neurony są rozmieszczane w przestrzeni danych, jako tzw. *centra* oraz działają one lokalnie jako liniowe asocjatory. Warstwy wejściowe i wyjściowe w obu sieciach działają w sposób zbliżony. Natomiast różnica pojawia się w warstwie ukrytej: każdy neuron (h) posiada swoje centrum $c_h \in R^d$. Centra te są inicjowane podczas tworzenia struktury sieci, a następnie podczas trenowania sieci są dostosowywane do danych treningowych. Wszystkie analizowane przez autorkę struktury sieci neuronowej z zastosowaniem sieci RBF pozwalały na otrzymanie jakości sieci neuronowej w zbiorze walidacyjnym tylko na poziomie 40%. Taki wynik nie jest wystarczający ani zadowalający, zatem w analizach rozważano tylko sieci typu perceptron wielowarstwow MLP.

Kolejną istotną kwestią do zdefiniowania była liczba warstw ukrytych opracowywanego modelu sieci neuronowej. Analizowany problem nie jest na tyle skomplikowany, by do jego rozwiązania konieczne było zastosowanie dwóch warstw ukrytych. Poza tym moduł Automatyczne Sieci Neuronowe w pakiecie statystycznym STATISTICA umożliwia zaimplementowanie tylko jednej warstwy ukrytej, zatem ten parametr nie podlegał analizom.

Dobór liczby neuronów w warstwie ukrytej jest istotną kwestią, gdyż ich nadmiar może spowodować nauczenie się przez sieć zależności na pamięć, natomiast ich niedobór z kolei może pozbawić sieć zdolności do uczenia się. W literaturze przedmiotu zalecane jest, aby liczba neuronów ukrytych była równa połowie sumy liczby neuronów wejściowych i liczby neuronów wyjściowych¹³¹. Dodatkowo oparto się na często wymienianej w literaturze regule piramidy geometrycznej (ang. *geometry pyramid*). Zakłada ona, że liczba neuronów w warstwie ukrytej powinna być równa pierwiastkowi iloczynu liczby neuronów w warstwie wejściowej i wyjściowej. Reguła ta wyrażona jest wzorem¹³²:

$$H = \sqrt{N \cdot M} \quad (4.2)$$

gdzie:

H – liczba neuronów w warstwie ukrytej;

N – liczba neuronów w warstwie wejściowej;

M – liczba neuronów w warstwie wyjściowej.

Znalazło to odzwierciedlenie w analizowanym przypadku. Strukturę opracowywanego modelu regresyjnego, opartego na sztucznej sieci neuronowej, przedstawiono na rysunku 4.2. W wyniku przeprowadzonych studiów literaturowych oraz prac badawczych mających na celu preprocessing zmiennych wejściowych wybrano sieć neuronową typu MLP 6–3–1, o strukturze złożonej z sześciu neuronów w warstwie wejściowej, trzech neuronów w warstwie ukrytej (h_1, h_2, h_3) oraz jednego neuronu w warstwie wyjściowej. Liczba neuronów w warstwie wejściowej zależy jedynie od liczby zmiennych wejściowych. Każdej zmiennej wejściowej ilościowej, a tylko takie analizowane są w opracowywanym modelu, odpowiada jeden neuron wejściowy. W celu zachowania czytelności rysunku 4.2 tylko kilka wybranych wartości wagowych zostało na nim zaprezentowanych¹³³.

Bardzo ważnym czynnikiem do rozważenia jest także **funkcja błędu**, pozwalająca na ocenę jakości sieci neuronowej w trakcie trenowania lub w czasie jej późniejszego uruchomienia. W iteracyjnych algorytmach uczących pochodna funkcji błędu stanowi podstawę do modyfikacji wag¹³⁴. W literaturze podaje się, że funkcja błędu najczęściej definiowana jest za pomocą jednej z trzech zależności¹³⁵:

$$F = \frac{1}{2} \sum_i (y_i - z_i)^2 \quad (4.3)$$

¹³¹ Strona internetowa, http://www.statsoft.pl/textbook/stathome_stat.html?http%3A%2F%2Fwww.statsoft.pl%2Ftextbook%2Fstneunet.html [23.10.2015].

¹³² T. Masters, *Practical Neural Network Recipes in C++*, Academic Press, San Diego, CA United States 1993.

¹³³ S. Walczak, *Methodological Triangulation Using Neural Networks for Business Research*, "Advances in Artificial Neural Systems" 2012, article ID 517234, vol. 2012.

¹³⁴ C.M. Bishop, *Neural Networks for Pattern Recognition*, Oxford University Press, Oxford 1995.

¹³⁵ E.M. Azoff, *Neural network time series forecasting of financial markets*, Wiley, New York 1994.


$$F = \sum_i |y_i - z_i| \quad (4.4)$$

$$F = \sum_i \frac{|y_i - z_i|^u}{u}, (1 \leq u \leq 2) \quad (4.5)$$

gdzie:

z_i – wartość wyjścia (wzorcowa) i -tego elementu ciągu uczącego z_i ;

y_i – otrzymana wartość wyjściowa sieci dla i -tego elementu ciągu uczącego y_i .



RYSUNEK 4.2. Struktura sieci neuronowej MLP 6–3–1

ŹRÓDŁO: Opracowanie własne.

Pakiet STATISTICA Automatyczne Sieci Neuronowe, przy modelowaniu problemu regresyjnego, umożliwia określenie **sumy kwadratów** (ang. *sum of squares* – **SOS**) jako **funkcji błędu** (wzór 4.6). Błąd jest sumą kwadratów różnic (odchyłeń) pomiędzy wartościami zadanymi i wartościami otrzymanymi na wyjściach każdego neuronu wyjściowego. Wartości błędów podnoszone są do kwadratu w celu uniknięcia efektu kompensowania błędów ujemnych przez błędy dodatnie, a ponadto powoduje to silniejsze zaakcentowanie dużych błędów przy jednoczesnym zmniejszeniu oddziaływania małych błędów. Powstający wskaźnik SSE (ang. *Sum Square Errors*) wyrażony jest wzorem¹³⁶:

¹³⁶ R. Tadeusiewicz, M. Szaleniec, dz. cyt., s. 101.

$$SSE = \sum_{p=1}^R \sum_{k=1}^M (d_{pk} - y_{pk})^2 \quad (4.6)$$

gdzie:

d_{pk} – wzorcowa odpowiedź, która powinna pojawić się przy prezentacji przypadku uczącego o numerze p na wyjściu sieci o numerze k ;
 y_{pk} – faktyczna wartość, jaka pojawiła się na wyjściu.

W analizowanym przypadku nie można było zastosować funkcji błędu opartej na entropii wzajemnej (ang. *Cross entropy* – CE), ponieważ została ona zaprojektowana do rozwiązywania tylko problemów klasyfikacyjnych. Błąd w takim przypadku jest sumą iloczynów zadanych wartości oraz logarytmów błędów dla każdego neuronu wyjściowego. Zatem w analizowanym przypadku zastosowano sumę kwadratów jako funkcję błędów.

Bardzo istotnym momentem, determinującym jakość budowanej sieci i jej zdolność do generalizacji danych, jest wybór odpowiedniej funkcji aktywacji (przejścia) w neuronach ukrytych i wyjściowych. W pakiecie statystycznym STATISTICA Automatyczne Sieci Neuronowe możliwy jest wybór jednej z następujących funkcji aktywacji: liniowa, tangens hiperboliczny, wykładnicza, logistyczna, sinusoidalna.

Przetestowano wszystkie możliwe do zaprojektowania modele sieci neuronowych różniących się rodzajami funkcji aktywacji. Przeprowadzone symulacje pozwoliły na ocenę jakości tych wszystkich modeli i wybór takiej sieci neuronowej, która pozwalała na otrzymanie najwyższej wartości jakości w zbiorze walidacyjnym. Na podstawie tych eksperymentów podjęto decyzję o zastosowaniu tangensu hiperbolicznego (w pakiecie STATISTICA oznaczanego jako *tanh*), jako funkcji aktywacji w neuronach ukrytych, wyrażonego wzorem:

$$f(x) = a \cdot \tanh(bx) = a \cdot \frac{e^{bx} - e^{-bx}}{e^{bx} + e^{-bx}} \quad (4.7)$$

W funkcji tej parametr a decyduje o zakresie jej wartości, natomiast parametr b o jej nachyleniu. Tangens hiperboliczny to funkcja symetryczna, różniczkowalna, S-kształtna z wartościami wyjściowymi mieszczącymi się w przedziale $(-1, 1)$. Funkcja ta, z uwagi na jej symetryczność, działa lepiej i daje lepsze wyniki niż funkcja logistyczna oraz dobrze sprawdza w nieliniowych sieciach neuronowych – szczególnie w perceptronach wielowarstwowych¹³⁷. Ponadto w tym miejscu warto podkreślić, że neuron sigmoidalny, najczęściej stosowany, ma ograniczenie polegające na tym, że jego sygnał wyjściowy może przyjmować tylko wartości dodatnie. Komórki nerwowe w biologicznym układzie nerwowym człowieka również mogą operować wyłącznie dodatnimi sygnałami, zatem wybór sigmoidalnej funkcji aktywacji ma na celu

¹³⁷ *Electronic Statistics Textbook*, Statsoft, Kraków 2006.

odzwierciedlenie charakteru biologicznej sieci. W sztucznej sieci neuronowej możliwe jest zastosowanie zarówno sygnałów unipolarnych (dodatnich), jak i bipolarnych (dodatnich oraz ujemnych). Ta istotna cecha pozwoliła na rozpowszechnienie stosowania neuronów z funkcją aktywacji opisaną przez formułę tangensa hiperbolicznego¹³⁸.

W neuronie wyjściowym jako funkcję aktywacji wybrano natomiast funkcję liniową, której poziom aktywacji jest bezpośrednio przekazywany na wyjście. Wybór tangensa hiperbolicznego jako funkcji aktywacji w neuronach ukrytych oraz funkcji liniowej w neuronie wyjściowym uprawdopodobniło otrzymanie modelu sieci neuronowej o możliwie najwyższej jakości, cechującej się dużą zdolnością do generalizacji danych. Ponadto warto podkreślić za Tadeusiewiczem, że tangens hiperboliczny i funkcja liniowa dobrze sprawdzają się w nieliniowych sieciach neuronowych, szczególnie w perceptronach wielowarstwowych.

Należy także zaznaczyć, że w większości modeli sztucznych sieci neuronowych stosuje się normalizację zmiennych wejściowych. Polega to na zastosowaniu przeskalowania wartości każdej zmiennej i sprowadzenia ich do określonego, zazwyczaj małego, zakresu (przedziału). Ta procedura ma za zadanie przydzielenie każdej zmiennej wejściowej jednakowego znaczenia (wagi) w stosunku do innych zmiennych¹³⁹. Dane liczbowe stanowiące wejścia sieci neuronowej przyjmują wartości należące do zupełnie różnych przedziałów i rzędów wartości. W literaturze podaje się, że w celu uzyskania dobrej efektywności procesu trenowania najkorzystniejsze jest podawanie na wejściu wartości z przedziału (0,1). Takie podejście umożliwia lepsze wykorzystanie nieliniowego fragmentu przebiegu funkcji przejścia w poszczególnych warstwach sieci, w tym przede wszystkim w warstwie ukrytej. W literaturze opisuje się kilka metod skalowania wartości zmiennych: skalowanie względem wartości maksymalnej, względem wartości średniej, względem odchylenia od wartości średniej, względem odchylenia od wartości minimalnej oraz względem standardowego odchylenia średniokwadratowego.

Skalowanie nieliniowe nie jest realizowane przez moduł Automatyczne Sieci Neuronowe w pakiecie STATISTICA, zatem w analizowanym przypadku zastosowano normalizację liniową, wyrażoną wzorem:

$$y = a \cdot x + b \quad (4.8)$$

gdzie:

$$a = \frac{1}{x_{\max} - x_{\min}}$$

$$b = \frac{-x_{\min}}{x_{\max} - x_{\min}}$$

w zakresie [min – max] → [0, 1].

¹³⁸ R. Tadeusiewicz, M. Szaleniec, dz. cyt., s. 64.

¹³⁹ J. Morajda, *Metody sztucznej inteligencji w zarządzaniu...*, dz. cyt. s. 59.

TABELA. 4.3. Wybrane parametry testowanych sieci i ich wartości jakości

Typ sieci 6-3-1	Funkcja błędu	Funkcja aktywacji (neurony ukryte)	Funkcja aktywacji (neuron wyjściowy)	Algorytm trenowania	Jakość sieci (podzbiór uczący)	Jakość sieci (podzbiór walidacyjny)	Jakość sieci (podzbiór testowy)
MLP	Suma kwadratów	Tangens	Liniowa	BFGS	0,97	0,99	0,99
MLP	Suma kwadratów	Tangens	Sinus	BFGS	0,95	0,97	0,97
MLP	Suma kwadratów	Sinus	Tangens	BFGS	0,96	0,96	0,96
MLP	Suma kwadratów	Sinus	Tangens	Najszybszego spadku	0,93	0,93	0,92
MLP	Suma kwadratów	Logistyczna	Sinus	Najszybszego spadku	0,95	0,96	0,94
MLP	Suma kwadratów	Logistyczna	Liniowa	Najszybszego spadku	0,89	0,88	0,88
MLP	Suma kwadratów	Liniowa	Wykładnicza	Najszybszego spadku	0,92	0,94	0,94
MLP	Suma kwadratów	Wykładnicza	Logistyczna	BFGS	0,78	0,79	0,71
RBF	Entropia wzajemna	Gausa	Liniowa	K-średnich	0,54	0,63	0,58
RBF	Suma kwadratów	Gausa	Liniowa	K-średnich	0,77	0,86	0,78

Przed wyborem ostatecznej budowy i cech sieci neuronowej testowano wiele modeli różniących się omówionymi w tym punkcie cechami. Aby uniknąć pomyłek spowodowanych zatrzymywaniem się algorytmu w minimum lokalnym, przeprowadzono iteracyjnie wiele eksperymentów z każdą konfiguracją sieci. Celem przeprowadzonych symulacji był wybór sieci neuronowej charakteryzującej się najlepszą jakością w zbiorze walidacyjnym, który nie podlegał procesowi trenowania. Jako ostateczną przyjęto tę strukturę, która pozwoliła na uzyskanie najlepszej wartości jakości w próbie walidacyjnej. W tabeli 4.3 pokazano wybrane szczegółowe wyniki przeprowadzonych eksperymentów, to jest wartości jakości sieci dla zbioru walidacyjnego, dla przetestowanych sieci neuronowych o różnych konfiguracjach. Stanowiły one istotne przesłanki do podjęcia decyzji o wyborze omówionych wyżej cech w opracowywanym modelu sieci neuronowej.

5. Trenowanie sieci i zastosowanie modelu neuronowego


Prawidłowe działanie sieci neuronowej zależy od jej odpowiedniego trenowania, a nie tylko właściwego określenia struktury i jej cech. Głównym sposobem korzystania z sieci neuronowej jest tworzenie modeli, czyli sformalizowanej struktury, odwzorowującej pewien proces czy zjawisko. Proces uczenia jest procesem iteracyjnym, powtarzanym wielokrotnie, krok po kroku, którego zasadniczym celem jest optymalizacja parametrów sieci, to jest 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 źródło wiedzy, inteligencji neuronu. Im większa jest wartość wagi, tym dana zmienna jest istotniejsza¹⁴⁰. Testowano wiele konfiguracji modeli sieci neuronowych, a celem eksperymentów było znalezienie takich parametrów sieci, które zapewniają maksymalną wartość jakości w zbiorze walidacyjnym, wyrażonej za pomocą współczynnika korelacji, oraz minimalizacja błędu sieci.

5.1. Uczenie sieci neuronowej

W analizowanym przypadku zastosowano uczenie nadzorowane (ang. *supervised learning*, z nauczycielem). Ten rodzaj trenowania wyróżnia się tym, że sieci zostały podane przykłady poprawnego działania, które powinny być przez nią naśladowane. Wskazano zatem, oprócz sygnałów wejściowych (zmienne $X_1, \dots, X_6$), również pożądane (oczekiwane) na nie odpowiedzi, czyli sygnał wyjściowy¹⁴¹ – wartości zmiennej Y . Sieć neuronowa była trenowana w oparciu o wiedzę na temat wartości kapitału społecznego (Y), obliczonego za pomocą równania fundamentalnego, oraz wartości zmiennych wejściowych analizowanych przedsiębiorstw informatycznych na koniec każdego kwartału w okresie 2006–2020. Po podaniu wartości wejściowych obliczone zostały sygnały wyjściowe neuronu. Następnie współczynniki wagowe były modyfikowane w ten sposób, aby zminimalizować błąd między sygnałem wzorcowymi a wyjściem perceptronu.

¹⁴⁰ P. Lula, G. Paliwoda-Pękosz, R. Tadeusiewicz, dz. cyt., s. 79–86.

¹⁴¹ Tamże, s. 79–86.



RYSUNEK. 5.1. Nadzorowane uczenie sieci neuronowej

ŹRÓDŁO: Opracowanie własne.

Ogólny schemat nadzorowanego uczenia sieci neuronowej przedstawiono na rysunku 5.1. Wartości współczynników wagowych dobierane są w taki sposób, aby aktualny sygnał wyjściowy y był najbliższy wartości zadanej d . Celem uczenia nadzorowanego jest zatem minimalizacja odpowiednio zdefiniowanej funkcji celu, która umożliwi dopasowanie wartości aktualnych odpowiedzi neuronów wyjściowych do wartości żądanych. Inaczej mówiąc, 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 przy tym polegać na intuicji lub doświadczeniu albo bazować na procedurach automatycznych. Znacznie trudniejsze i bardziej czasochłonne jest testowanie przez projektanta modelu wielu wariantów struktury sieci neuronowej i wybór ostatecznie tej, która pozwala na otrzymanie sieci o możliwie wysokiej jakości, to znaczy zdolnej do generalizacji danych. Autorka przeprowadziła wiele testów i eksperymentów w tym kierunku.

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 wartości współczynników wagowych, opierając się na danych wejściowych i odpowiadających im prawidłowym rozwiązaniom. 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 opiera 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 wejściowej¹⁴². W metodzie wstecznej propagacji błędów przyjęto następujące założenia dotyczące

¹⁴² D. Rutkowska, M. Piliński, L. Rutkowski, *Sztuczne sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, Wydawnictwo Naukowe PWN, Warszawa 1997, s. 34.

trenowania sieci: istnieją tylko połączenia pomiędzy neuronami kolejnych warstw, funkcje aktywacji sieci i funkcja celu są ciągłe i różniczkowalne oraz zbiór uczący składa się z wartości wejściowych sieci i odpowiadających im pożądaných wartości wyjściowych. Sieć analizowana jest w kierunku od jej wejścia do wyjścia. Dla zdefiniowanych wcześniej wartości sygnałów wejściowych obliczane są wartości wyjść neuronów poszczególnych warstw oraz pochodne cząstkowe wszystkich funkcji aktywacji. Funkcje aktywacji zastępowane są przez ich pochodne, a do wyjścia sieci podawane wartości będące różnicą między obliczonym wcześniej wyjściem a wartością zadaną. Błąd, obliczany dla wszystkich neuronów, propagowany jest wstecz, to jest od ostatniej do pierwszej warstwy¹⁴³.

Sposób obliczania błędów w poszczególnych warstwach jest następujący: w pierwszej kolejności, na podstawie sygnałów wyjściowych i wzorcowych, obliczane są błędy w warstwie ostatniej, a następnie w warstwach ją poprzedzających, aż do pierwszej warstwy. Początkowo wartości współczynników wagowych dobierane są w sposób losowy i zazwyczaj są bliskie zeru. Podczas procesu trenowania sieci wagi poszczególnych zmiennych wejściowych estymuje się do wartości optymalnych, gwarantujących minimalizację błędów na wyjściu¹⁴⁴. Pakiet STATISTICA Automatyczne Sieci Neuronowe automatycznie zachowuje kopię najlepszej sieci, która jest później stosowana jako najlepsze rozwiązanie, co zapobiega wystąpieniu zjawiska przeuczenia sieci neuronowej. Po zakończeniu procesu trenowania sieci przeprowadzana jest ostateczna ocena sieci za pomocą niezależnego zbioru testowego.

W literaturze przedmiotu podaje się bardziej wyrafinowane i skuteczne techniki służące do optymalizacji funkcji nieliniowych, obejmujące między innymi: metody gradientów sprzężonych, Quasi Newtona i metody Levenberga-Marquardta¹⁴⁵. Metoda gradientów sprzężonych bazuje na założeniu, że powierzchnia błędu w n -wymiarowej przestrzeni ma kształt paraboliczny. Obliczenia rozpoczyna się od pewnego punktu startowego i w tym punkcie wyznacza się kierunek zgodny z gradientem funkcji. Następnie wzdłuż tak wyznaczonego kierunku przeprowadza się proces poszukiwania minimum funkcji błędu. Algorytm Levenberga-Marquardta jest najszybszym algorytmem uczenia sieci jednokierunkowych, stosowanym tylko w przypadku niewielkich sieci z pojedynczym neuronem wyjściowym i funkcją błędu w postaci sumy kwadratów odchyleń. Metoda gradientów sprzężonych jest porównywalnie skuteczna, co algorytm Levenberga-Marquardta, a nie ma takich ograniczeń.

Pakiet STATISTICA Automatyczne Sieci Neuronowe umożliwia wybór jednego z trzech algorytmów uczenia: najszybszego spadku, BFGS oraz gradientów sprzężonych. Algorytm najszybszego spadku jest szybkim algorytmem uczącym dla perceptronu wielowarstwowego, polegającym na przeprowadzeniu wielokrotnych liniowych poszukiwań w przestrzeni wag. Kolejne kierunki poszukiwań nie powtarzają

¹⁴³ S. Haykin, *Neural Networks – A Comprehensive Foundation*, Second Edition, Prentice Hall, New York 1999.

¹⁴⁴ D. Rutkowska, M. Piliński, L. Rutkowski, dz. cyt., s. 34–37.

¹⁴⁵ Ch.M. Bishop, *Neural network for pattern recognition*, Clarendon Press, Oxford **rok**, s. 253.

się. Jest to dobry, ogólny algorytm ze stosunkowo szybką zbieżnością. Algorytm gradientów sprzężonych bazuje na założeniu, że powierzchnia błędu w n -wymiarowej przestrzeni ma kształt paraboliczny. Obliczenia rozpoczyna się od pewnego punktu startowego i w tym punkcie wyznacza się kierunek zgodny z gradientem funkcji. Następnie wzdłuż tak wyznaczonego kierunku przeprowadza się proces poszukiwania minimum funkcji błędu. Polega to na przemieszczaniu się w przestrzeni poszukiwań w kierunku punktów o coraz niższych wartościach funkcji błędu w celu zlokalizowania minimum¹⁴⁶.

Do uczenia opracowanej sieci neuronowej zastosowano algorytm BFGS (Broyden–Fletcher–Goldfarb–Shanno) oparty na metodzie gradientowej drugiego rzędu, będący alternatywą dla gradientu prostego. Algorytm BFGS należy do algorytmów quasi-newtonowskich (tak zwanych metod zmiennej metryki) o szybkiej zbieżności. Metoda Newtona zakłada, że funkcja może być lokalnie aproksymowana funkcją kwadratową w otoczeniu optimum, oraz wykorzystuje pierwsze i drugie pochodne (gradient i hesjan) w celu znalezienia punktów stacjonarnych. Algorytm BFGS zatem oprócz informacji o gradiencie wykorzystuje również aproksymację hesjanu, stosując rekurencyjną poprawkę przybliżającą odwrócony hesjan.

W metodzie BFGS zakłada się, że funkcja jest lokalnie aproksymowana w otoczeniu poszukiwanego minimum funkcją kwadratową¹⁴⁷:

$$f(x_0 + \Delta x) = f(x_0) + \nabla f(x_0)^T \Delta x + \frac{1}{2} \Delta x^T V \Delta x \quad (5.1)$$

gdzie:

V – iteracyjnie aktualizowane przybliżenie odwrotności hesjanu.

Funkcja osiąga minimum, jeżeli jej gradient przyjmuje wartość 0:

$$\nabla f(x_0 + \Delta x) = 0.$$

Pierwszy krok poprawy rozwiązania uzyskiwany jest po przekształceniach:

$$\Delta x = -V \nabla f(x_0).$$

Nowy punkt poszukiwania przyjmuje zatem wartość wyrażoną zależnością:

$$x = x_0 + \Delta x.$$

¹⁴⁶ Strona internetowa, http://www.statsoft.pl/textbook/stathome_stat.html?http%3A%2F%2Fwww.statsoft.pl%2Ftextbook%2Fstneunet.html [dostęp: 12.10.2015].

¹⁴⁷ B. Baron, A. Pasierbek, *Porównanie wydajności algorytmów gradientu sprzężonego i quasi-newtonowskiego BFGS w zagadnieniu optymalizacji rozprzysięgu mocy w systemie elektroenergetycznym*, „Prace Naukowe Politechniki Śląskiej. Elektryka” 2009, z. 3, s. 49–68.

Proces ten jest powtarzany do otrzymania punktu, w którym funkcja osiąga minimum, co pozwala osiągnąć zadowalającą dokładność. Działanie to można zapisać w następujący sposób:

$$\begin{aligned}\Delta_k &= -\alpha_k V_k \Delta f(x_k) \\ x_{k+1} &= x_k + \Delta x_k.\end{aligned}\tag{5.2}$$

gdzie:

k – numer iteracji;


α_k – współczynnik dobierany w celu spełnienia warunków Wolfe’a.

Istotną własnością do zdefiniowania było określenie sposobu inicjalizacji wag w sieci, czyli ustawienie ich wartości na początku trenowania. Moduł Automatyczne Sieci Neuronowe w pakiecie STATISTICA umożliwia wybór inicjalizacji: *losowej – gaussowskiej* lub *losowej – równomiernej*. Poza wyborem rozkładu należy również określić wartość średnia/min oraz *wariancja/maks*. Możliwa jest dowolna zmiana ustawień automatycznych dla tych parametrów, jednak zazwyczaj określana jest wartość średnia/min na zero i wartość *wariancja/maks* na nie więcej niż 0,1. Takie wartości pozwolą sieci na stopniowy wzrost ze stanu liniowego (małe wartości wag) do stanu nieliniowego (duże wartości wag) w celu odpowiedniego modelowania związku wejście-wyjście w trakcie procesu uczenia. Wybrano losową, gaussowską inicjalizację wag dla modelu sieci neuronowych do określenia początkowych wartości wag. Ponadto określono moment, w którym należy zatrzymać trenowanie sieci, aby nie dopuścić do jej przeuczenia, czyli nauczenia się zależności na pamięć (zmiana błędu 0,0000001). Zastosowano także redukcję wag dla neuronów ukrytych, definiując współczynnik redukcji o wartości 0,001, oraz ustawiono wartość początkową generatora dla inicjalizacji na 1000.

Okno programu STATISTICA po skończonym trenowaniu sieci neuronowej zaprezentowano na rysunku 5.2.

W pierwszej kolumnie jest podana nazwa otrzymanej sieci neuronowej, określająca jej typ (*MLP*), liczbę neuronów w warstwie wejściowej (6), liczbę neuronów w warstwie ukrytej (3) i liczbę wyjść (1). W trzech kolejnych kolumnach podane są wskaźniki jakości sieci, osobno dla danych znajdujących się w trzech podzbiorach: uczącym, testowym oraz walidacyjnym. Modelowaną sieć charakteryzują następujące wartości jakości: 0,97 – dla zbioru uczącego, 0,99 – dla zbioru testowego, 0,99 – dla zbioru walidacyjnego.

Następnie zaprezentowano rodzaj zastosowanego algorytmu uczącego (BFGS) oraz liczbę cykli uczenia i wykonywania algorytmu (8). W kolejnej kolumnie zaprezentowano informacje o rodzaju zastosowanej funkcji błędu: SOS, czyli suma kwadratów. W dwóch ostatnich kolumnach określone zostały funkcje aktywacji, zastosowane w warstwie ukrytej i wyjściowej sieci neuronowej.



RYSUNEK 5.2. Okno wynikowe po zakończonym trenowaniu sieci

Przy analizie regresji jakość sieci wyrażona jest za pomocą współczynnika korelacji liniowej Pearsona pomiędzy wartościami zmiennej zależnej (wyjściowej) a przewidywaniami sieci, wyrażonych wzorem:

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (5.3)$$

gdzie:

$\bar{x}$ – jest wartością średnią.

W analizowanym przypadku korelacja liniowa pomiędzy zmiennymi wynosi około 97% w zbiorze uczącym. Oceną jakości sieci jest jednak jej zdolność do generalizacji, zatem najistotniejszą miarą jest jakość na próbie walidacyjnej, czyli na danych nowych, które nie były poddane procesowi uczenia. Modelowaną sieć w zbiorze walidacyjnym charakteryzuje jeszcze większa jakość (99%).


Cechy charakterystyczne trójwarstwowego perceptronu zaprezentowano w tabeli 5.1.

TABELA 5.1. Charakterystyka modelu neuronowego

Nazwa sieci	Funkcja aktywacji (neurony ukryte)	Funkcja aktywacji (neurony wyjściowe)	Błąd sieci	Algorytm uczenia
MLP 6-3-1	Tangens hiperboliczny $\tanh x = \frac{\sinh x}{\cosh x} = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	Liniowa $y(x) = ax + b$	Suma kwadratów (SOS – sum of squares)	BFGS (oparty na metodzie gradientowej drugiego rzędu)

ŹRÓDŁO: Opracowanie własne.

Przeprowadzone studia literaturowe dotyczące struktury sieci, prace badawcze dotyczące preprocessingu zmiennych wejściowych oraz eksperymenty mające na celu określenie cech sieci pozwoliły autorce na opracowanie modelu opartego na sztucznej sieci neuronowej, odwzorowującego proces wyznaczania wartości kapitału społecznego. Został on zaprezentowany na rysunku 5.3.



RYSUNEK 5.3. Perceptron wielowarstwowy MLP 6–3–1

ŹRÓDŁO: Opracowanie własne.

W modelu tym na wejścia wprowadzane są numeryczne wartości wejściowe $x_1, \dots, x_6$, tworzące wektor wartości wejściowych $X = [x_1, \dots, x_6]$. Każdej z sześciu zmiennych wejściowych przyporządkowane zostały odpowiadające im współczynniki wagowe ($w_1, \dots, w_6$), określające siłę ich wpływu na zmienną wyjściową Y . Wartości

tych współczynników, zwanych wagami synaptycznymi, tworzą wektor wag neuronu $\mathbf{W} = [w_1, \dots, w_6]$, a podczas uczenia zostały wyznaczone sieci neuronowe. Wektor wag zdefiniowano jako¹⁴⁸:

$$\mathbf{W} = [w_1, w_2, \dots, w_6]^T \quad (5.4)$$

gdzie:

T – symbol transpozycji;

$\mathbf{W}$ – wektor wyznaczający punkt w n -wymiarowej przestrzeni wag.

Dane wejściowe zostały zagregowane poprzez zsumowanie iloczynów wartości wejściowych i odpowiadających im współczynników wagowych, co opisać można wzorem:

$$s = \sum_{i=1}^n w_i x_i \quad (5.5)$$

Przy wyznaczaniu wartości wyjściowej neuronu zastosowana została funkcja aktywacji, oznaczana jako $f(\mathbf{W}^T \mathbf{X})$. Argumentem tej funkcji była zagregowana wcześniej wartość wejściowa s . W neuronach ukrytych miała ona postać tangensu hiperbolicznego, a w neuronie wyjściowym zastosowano funkcję liniową.

Wyjście neuronu opisać można za pomocą relacji:

$$y = f(\mathbf{W}^T \mathbf{X}) = f\left(\sum_{i=1}^n w_i x_i\right) \quad (5.6)$$

gdzie:

n – liczba wejść,

$x_1, x_2, \dots, x_6$ – wartości sygnałów wejściowych dla neuronu;

$w_1, w_2, \dots, w_6$ – wartości wag połączeń wejściowych, określające znaczenie poszczególnych wejść;

f – funkcja aktywacji określająca zależność wyjścia od ważonej sumy wejść.

W analizowanym przypadku zastosowano uczenie nadzorowane. Parametry sieci dobrano w sposób pozwalający na minimalizację funkcji błędu sieci. W tym celu zastosowano odpowiedni algorytm uczenia, który umożliwił automatyczną modyfikację wartości wagowych w oparciu o dane wejściowe i odpowiadające im prawidłowe rozwiązania. Trenowanie zbudowanego modelu sieci przeprowadzono metodą wstecznej propagacji błędów z zastosowaniem algorytmu BFGS.

Istotną charakterystyką sieci neuronowej jest także globalna analiza wrażliwości (ang. *global sensitivity analysis*), za pomocą której można post factum ocenić słuszność wyboru poszczególnych zmiennych oraz określić, w jaki sposób zmienia się jakość

¹⁴⁸ R. Tadeusiewicz, *Sieci neuronowe...*, dz. cyt., s. 28.

modelu po wyłączeniu jednej ze zmiennych. Wyniki globalnej 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 wskazują, że usunięcie tej zmiennej może pogorszyć jakość modelu. W tym miejscu warto przypomnieć, że przed ostatecznym wyborem zmiennych wejściowych zbioru uczącego przetestowano istotność innych zmiennych, takich jak między innymi: liczba akcji, cena akcji, wartość księgowa, zysk netto. Okazało się jednak, że zmienne te charakteryzowały się globalną analizą wrażliwości o wartości poniżej 1 lub bardzo wysoką wartością korelacji pomiędzy pozostałymi zmiennymi. Te przesłanki pozwoliły na podjęcie decyzji o usunięciu wspomnianych zmiennych zarówno z modelu teoretycznego, jak i zbioru uczącego. Uzyskane wartości globalnej analizy wrażliwości sześciu zmiennych wejściowych uwiarygodniają zatem zasadność ich włączenia do przyjętego modelu sieci neuronowej¹⁴⁹.

Wartości globalnej analizy wrażliwości dla sześciu analizowanych zmiennych wejściowych zaprezentowano w tabeli 5.2. Wyniki globalnej analizy wrażliwości wskazują także, które ze zmiennych najbardziej istotnie determinują wartość kapitału społecznego przedsiębiorstw (im wyższa wartość analizy wrażliwości, tym zmienna istotniejsza).

TABELA 5.2. Wartości globalnej analizy wrażliwości dla analizowanych zmiennych

	Wartość giełdowa	Aktywa razem	Zobowiązania	Przychody ogółem	Dochód netto	Zatrudnienie
	X_1	X_2	X_3	X_4	X_5	X_6
Globalna analiza wrażliwości	2,96	1,26	1,67	1,84	1,3	1,59

ŹRÓDŁO: Opracowanie własne.

Wartości globalnej analizy wrażliwości dla wybranych zmiennych (w próbie uczącej) są następujące: wartość giełdowa 2,96; aktywa 1,26; zobowiązania 1,67; przychody 1,84; dochód 1,3 oraz zatrudnienie 1,59. Żadna z analizowanych zmiennych nie uzyskała wartości globalnej analizy wrażliwości poniżej 1, co sugeruje istotny wpływ każdej z nich na zmienną wyjściową, czyli wartość kapitału społecznego. Jak widać, zmienną, która w najistotniejszy sposób wpływa na wartość kapitału społecznego badanych firm, jest wartość giełdowa. Najwyższą wartość ma zmienna „wartość giełdowa”, zatem jest to cecha mająca największy wpływ na wartość kapitału społecznego przedsiębiorstw.

¹⁴⁹ J. Siderska, *Analiza możliwości zastosowania sieci neuronowych...*, dz. cyt., s. 93.

Dodatkowo dokonano symulacji działania sieci po usunięciu ze zbioru uczącego jednej oraz kilku z sześciu przyjętych zmiennych. Eksperymenty te pokazały, że jakość walidacyjna sieci znacznie wówczas spada. Stanowiło to istotne przesłanki do podjęcia decyzji o uwzględnieniu w opracowywanym modelu tych sześciu zmiennych objaśniających.

Dostępne statystyki regresji pozwoliły ocenić dokładność szacunków. W tabeli 5.3 przedstawiono wartości średnich oraz odchylenia standardowego dla danych w analizowanych przedsiębiorstwach i okresach. Miary określone na podstawie zbioru uczącego pozwoliły na ocenę zdolności sieci do aproksymacji. Wskazują oni na dokładność w określaniu wartości zmiennej wyjściowej dla wektorów wejściowych prezentowanych podczas procesu trenowania. Znacznie ważniejsza jest dokładność takich wektorów wejściowych, które nie były prezentowane podczas uczenia.


TABELA 5.3. Średnia oraz odchylenie standardowe zmiennych

	Średnia	Odchylenie standardowe
Wartość giełdowa X_1	26857,2	76102,1
Aktywa X_2	31134,5	48572,6
Zobowiązania X_3	10500,76	17546,20
Przychody ogółem X_4	5443,95	7772,35
Dochód X_5	1479,139	2220,235
Zatrudnienie X_6	32901,8	39985,9
Kapitał społeczny Y	34162,4	52880,1

ŹRÓDŁO: Opracowanie własne.

Zdolność do prawidłowego działania sieci dla danych spoza zbioru uczącego nazywana jest zdolnością do generalizowania, czyli uogólniania. Miary określone na podstawie zbioru testowego umożliwiły ocenę właściwości sieci. Zbiór walidacyjny posłużył do obliczania miar jakości wykorzystywanych do monitorowania przebiegu procesu uczenia sieci.

Na rysunku 5.4 przedstawiono przebieg krzywej błędu w podzbiorze uczącym. W tym miejscu warto wyjaśnić znaczenie pojęcia epoki (do tej pory w monografii określana oraz na rysunku oznaczona jako „cykl uczenia”). Jest to jednokrotne przeprowadzenie iteracyjnego procesu uczenia sieci neuronowej, w trakcie którego w sieci prezentowane są wszystkie przypadki uczące. Po zrealizowaniu epoki przeprowadza się zazwyczaj ocenę sieci przy pomocy zbioru walidacyjnego. W analizowanym przypadku, aby proces uczenia osiągnął zbieżność, czyli aby błąd dla próby uczącej osiągnął swoje minimum, potrzeba było 8 epok uczenia, to jest ośmiokrotna prezentacja wszystkich elementów zbioru uczącego. Potem każdy kolejny cykl uczenia w zasadzie nie zmieniał istotnie poziomu błędu sieci.



RYSUNEK 5.4. Wykres błęd uczenia w próbie uczącej

ŹRÓDŁO: Opracowanie własne z wykorzystaniem pakietu statystycznego STATISTICA.

Ponadto należy zauważyć, że kształt wykresu błęd dla próby uczącej jest prawidłowy – błąd gwałtownie maleje na początku, potem łagodnie zbliża się do wartości 0. W tym miejscu warto podkreślić, że w przypadku perceptronu miarą błęd sieci jest funkcja zwana **błędem średniokwadratowym** (ang. *sum-squared error*), wyrażona wzorem:

$$E = \frac{1}{2} \sum_{i=1}^P (d_i - y_i)^2 \quad (5.7)$$

gdzie:

P – liczba przypadków uczących;

d_i – oczekiwana odpowiedź dla i tego przypadku;

y_i – odpowiedź perceptronu dla i tego przypadku.

Na rysunku 5.4 błąd uczenia jest przedstawiony dla znormalizowanej do zakresu $[0,1]$ zmiennej wyjściowej.

5.2. Algorytm obliczeniowy

Pakiet STATISTICA Automatyczne Sieci Neuronowe pozwala na zapisanie struktury wytrenowanej sieci neuronowej jako skrypt PMML (ang. *The Predictive Model Markup Language*). Jest on opartym na XML językiem służącym do prezentacji modeli przetwarzania danych (ang. *data mining models*) lub modeli analitycznych pozwalających na tworzenie prognoz (ang. *predictive analytic models*). Język ten umożliwia zapisywanie reguł, na podstawie których możliwe jest wyciąganie wzorców z dostępnych danych. Podstawą działania są modele matematyczne i statystyczne umożliwiające poznanie ukrytych w danych wzorców. Fragment kodu opracowanej sieci neuronowej, zapisany w języku PMML, pokazano na rysunku 5.5.

```
</Header>
<DataDictionary numberOfFields="7">
  <DataField name="Social capital (in mln $)" optype="continuous"/>
  <DataField name="Market value (in mln $)" optype="continuous"/>
  <DataField name="Employment" optype="continuous"/>
  <DataField name="Assets (in mln $)" optype="continuous"/>
  <DataField name="Liabilities (in mln $)" optype="continuous"/>
  <DataField name="Total revenue (in mln $)" optype="continuous"/>
  <DataField name="Net income (in mln $)" optype="continuous"/>
</DataDictionary>
<NeuralNetwork functionName="regression" modelName="zestawienie_MLP 6-3-1">
  <MiningSchema>
    <MiningField name="Social capital (in mln $)" usageType="predicted"/>
    <MiningField name="Market value (in mln $)" highValue="327903.000000" lowValue="101.000000"/>
    <MiningField name="Employment" highValue="128000.000000" lowValue="1800.000000"/>
    <MiningField name="Assets (in mln $)" highValue="172384.000000" lowValue="1157.000000"/>
    <MiningField name="Liabilities (in mln $)" highValue="79486.000000" lowValue="200.000000"/>
    <MiningField name="Total revenue (in mln $)" highValue="24519.000000" lowValue="82.000000"/>
    <MiningField name="Net income (in mln $)" highValue="6662.000000" lowValue="11.000000"/>
  </MiningSchema>
  <NeuralInputs numberOfInputs="6">
    <NeuralInput id="0">
      <DerivedField>
        <NormContinuous scale="3,05062202183025e-006" shift="-3,08112824204855e-004" field="Marke
          <LinearNorm norm="0.000000" orig="1.010000000000000e+002"/>
          <LinearNorm norm="1.000000" orig="3.279030000000000e+005"/>
        </NormContinuous>
      </DerivedField>
    </NeuralInput>
    <NeuralInput id="1">
      <DerivedField>
        <NormContinuous scale="7,92393026941363e-006" shift="-1,42630744849445e-002" field="Emple
          <LinearNorm norm="0.000000" orig="1.800000000000000e+003"/>
          <LinearNorm norm="1.000000" orig="1.280000000000000e+005"/>
        </NormContinuous>
      </DerivedField>
    </NeuralInput>
    <NeuralInput id="2">
```

RYСУNEK 5.5. Fragment kodu opracowanej sieci neuronowej zapisany w języku PMML (z pakietu STATISTICA)

Jednak takie informacje, zapisane tylko w pliku XML, bez wsparcia bibliotecznego nie są użyteczne z punktu widzenia ich możliwości praktycznego wykorzystania. Na tej podstawie autorka opracowała algorytm obliczeniowy, który następnie został zaimplementowany w języku C++.

W pierwszej kolejności jednak autorka skorzystała z otrzymanego pliku w języku PMML i odwzorowała matematyczną strukturę sieci w arkuszu kalkulacyjnym Excel, stosując odpowiednie formuły (między innymi wzór na funkcję liniową do obliczenia wartości znormalizowanych).

$x_i \rightarrow$ wejście, $i \in \{1, 2, \dots, 6\}$

$out_{1,i} = f_{1,i}(x_i)$, gdzie $f_{1,i} = clamp(sh_i + sc_i \cdot x, 0, 1)$

$out_{1,7} \equiv 1$

$out_{2,j} = f_2\left(\sum_{i=1}^7 w_{1 \rightarrow 2,ij} \cdot out_{1,i}\right)$, $j \in \{1, 2, 3\}$,

gdzie $f_2(x) = tgh(x)$ $out_{2,4} \equiv 1$

$out_3 = f_3\left(\sum_{j=1}^4 w_{2 \rightarrow 3,j} \cdot out_{2,j}\right)$

gdzie $f_3(x) = sk_{out} + sc_{out} \cdot x$
 w – wagi połączeń między warstwami.

Należy zaznaczyć, że wagi nie są wektorem, tylko macierzą o wymiarach 3x7, stąd wskazano dwa indeksy i oraz j .

$$y = a\left(\sum_{j=1}^3 w_{2j} f\left(\sum_{i=1}^6 w_{1ij} x_i + w_{1b}\right) + w_{2b}\right) + b$$

$$f(x) = tgh(x)$$

$$y^I = \frac{\partial y}{\partial x_i} a \sum_{j=1}^3 w_{2j} f\left(\sum_{k=1}^6 w_{1kj} x_k + w_{1b}\right) \cdot w_{1ij}$$

$$\Delta y \approx \frac{\partial y}{\partial x_i} \Delta x_i$$

$$\Delta y \approx \sum_{i=1}^6 \frac{\partial y}{\partial x_i} \Delta x_i$$

Część opracowanego algorytmu obliczeniowego pokazano w tabeli 5.4. Otrzymana w ten sposób sekwencja instrukcji umożliwia szacowanie wartości wyjściowej na podstawie wprowadzonych wartości sześciu zmiennych wejściowych.

TABELA 5.4. Matematyczna struktura opracowanej sieci neuronowej

Input		Lvl 1					Lvl 2							
	Value	Shift	Scale	Out	Out lvl 1	Weight1	Weight2	Weight3	W1*out1	W2*out1	W3*out1	Name	Out lvl 2	
Market value [mln \$]	5000	-3,08E-04	3,05E-06	1,49E-02	1,49E-02	0,4654	-0,0164	-0,2509	6,95E-03	-2,46E-04	-3,75E-03	Neuron 1	1,40E-01	
Employment	50	-1,43E-02	7,92E-06	-1,39E-02	0,00E+00	0,2212	-0,1961	-0,4744	-3,07E-03	2,72E-03	6,58E-03	Neuron 2	-4,70E-01	
Assets [mln \$]	7000	-6,76E-03	5,84E-06	3,41E-02	3,41E-02	0,1143	-0,1384	-0,3617	3,90E-03	-4,72E-03	-1,23E-02	Neuron 3	-7,79E-01	
Liabilities [mln \$]	5556	-2,52E-03	1,26E-05	6,76E-02	6,76E-02	0,2350	-0,0569	-0,2398	1,59E-02	-3,85E-03	-1,62E-02	Bias	1	
Total revenue [mln \$]	60000	-3,36E-03	4,09E-05	2,45E+00	1,00E+00	0,1471	-0,2136	-0,4467	3,61E-01	-5,24E-01	-1,10E+00			
Net income [mln \$]	55	6,98E-02	1,40E-04	7,75E-02	7,75E-02	0,0761	-0,1930	-0,4056	5,90E-03	-1,50E-02	-3,14E-02			
Bias				1	1	-0,2497	0,0348	0,1098	-2,50E-01	3,48E-02	1,10E-01			
						Lvl input			1,41E-01	-5,10E-01	-1,04E+00			
						Lvl activ			1,40E-01	-4,70E-01	-7,79E-01			

Źródło: Opracowanie własne

6. Wyniki eksperymentów

6.1. Aplikacja realizująca algorytm obliczeniowy

Zaprojektowany algorytm obliczeniowy został w dalszej kolejności zaimplementowany przez autorkę w języku C++. Poniżej pokazano kod źródłowy najważniejszej części tego programu, to jest funkcji *siec()*, która zwraca wynik działania sieci neuronowej, czyli obliczoną wartość kapitału społecznego. Pełen kod źródłowy do aplikacji SOCAP Neural Network stanowi załącznik do tej monografii.

```
double siec(double market_value, double employment, double assets, double liabilities, double
total_revenue, double net_income)
{
    double we[6] = {market_value, employment, assets, liabilities, total_revenue, net_income};

    double norm[6][2] = {
        {-0.000308112824204855, 0.00000305062202183025};
        {-0.0142630744849445, 0.00000792393026941363};
        {-0.00675711190408055, 0.00000584020043567895};
        {-0.00252251343238403, 0.0000126125671619201};
        {-0.00335556737733764, 0.0000409215533821664};
        {0.0698129014241832, 0.000139625802848366}
    };

    double warstwa_1[7] = {0, 0, 0, 0, 0, 0, 1};

    double polaczenia_1[7][3] = {
        {0.46535603101202, -0.0164468035572661, -0.250930985777859};
        {0.22116783994935, -0.196107365007555, -0.474374588736207};
        {0.114347980891993, -0.138367451462913, -0.361710187889834};
        {0.234993575725989, -0.0569468946987624, -0.239846232639002};
        {0.147142390436937, -0.213611184499937, -0.446705285279842};
        {0.0760911172068558, -0.192986983255022, -0.405620792517231};
        {-0.249733005512385, 0.0348090181539225, 0.10984820926091}
    };
};
```

```

    double warstwa_2[4] = {0, 0, 0, 1};

    double polaczenia_2[4] = {0.923069249830434, 0.213109912388641, -0.192673861949869,
0.236188008027543};

    double norm_wynik[2] = {-228.509830684168, 184411.130119774};

    double wynik = 0;

    int i, j;

    for(i=0; i<6; ++i)
        warstwa_1[i] = norm[i][0]+we[i]*norm[i][1];

    for(j=0; j<3; ++j)
        for(i=0; i<7; ++i)
            warstwa_2[j] += warstwa_1[i]*polaczenia_1[i][j];


    for(i=0; i<3; ++i)
        warstwa_2[i] = std::tanh(warstwa_2[i]);

    for(i=0; i<4; ++i)
        wynik += warstwa_2[i]*polaczenia_2[i];

    return norm_wynik[0] + wynik*norm_wynik[1];
}

```


Napisany przez autorkę w środowisku programistycznym DEV-C++ graficzny interfejs aplikacji SOCAP Neural Network pokazano na rysunku 6.1. Działanie aplikacji jest następujące: po wprowadzeniu wartości sześciu zmiennych wejściowych charakteryzujących przedsiębiorstwo informatyczne program oblicza wartość zmiennej wyjściowej, czyli wartość kapitału społecznego i pokazuje wynik w polu tekstowym „Wyjście”. Ponadto program został uzupełniony o dodatkowe funkcjonalności, takie jak: zapis obrazu do pliku graficznego, kopiowanie obrazu do schowka, zmiana języka na angielski oraz wyświetlanie informacji o programie.



RYSUNEK 6.1. Okno graficznego interfejsu aplikacji SOCAP Neural Network


ŹRÓDŁO: Opracowanie własne.

Wyniki oszacowania wartości kapitału społecznego przedsiębiorstwa Red Hat Corporation w II kwartale 2014 roku pokazano na rysunkach 6.2 i 6.3. Wyznaczanie wartości kapitału społecznego odbyło się z zastosowaniem obu zaproponowanych przez autorkę narzędzi, to jest za pomocą opracowanego modelu sieci neuronowej w programie STATISTICA oraz przy użyciu napisanej na tej podstawie aplikacji. Zmienne wejściowe w obu przypadkach charakteryzowały się taką samą wartością.



RYSUNEK 6.2. Przewidywania sieci w programie STATISTICA

ŹRÓDŁO: Opracowanie własne.



RYSUNEK 6.3. Przewidywania sieci w aplikacji SOCAP Neural Network

ŹRÓDŁO: Opracowanie własne.

Wartość kapitału społecznego wyznaczona przy użyciu modelu sieci neuronowej w programie STATISTICA wynosi 6280,22 mln dol. oraz 6307,2 mln dol. przy użyciu aplikacji SOCAP Neural Network. Różnica pomiędzy tymi wartościami jest niewielka (wynosi około 0,05%) i wynika najprawdopodobniej z powodów numerycznych. Pozwala to, zdaniem autorki, na uznanie opracowanej metody pomiaru oraz zaproponowanej aplikacji jako uzasadnionego merytorycznie narzędzia do szacowania wartości kapitału społecznego przedsiębiorstw informatycznych.

Pakiet statystyczny STATISTICA, w którym opracowany został model sieci neuronowej, jest oprogramowaniem komercyjnym, do którego dostęp możliwy jest tylko po wykupieniu licencji. Koszt zakupu tego pakietu w wersji jednostanowiskowej wynosi kilka tysięcy złotych. Utrudnia to potencjalnym odbiorcom sieci możliwość z niej skorzystania i oszacowania wartości kapitału społecznego w ich przedsiębiorstwach. Intencją autorki było, aby zaproponowany model i opracowane na jego podstawie narzędzia informatyczne były udostępnione jako oprogramowanie open source. Pozwoli to na skorzystanie z nich przez większą liczbę odbiorców.

6.2. Możliwości aplikacyjne modelu

Zaproponowana metodyka badawcza jest nowa, dlatego istniała konieczność zweryfikowania jej poprawności poprzez zestawienie wyników uzyskanych przy jej użyciu z wynikami otrzymanymi za pomocą innego narzędzia – równania fundamentalnego.

TABELA 6.1. Wartości kapitału społecznego w wybranych przedsiębiorstwach

Firma	Wartość gieldowa [mln dol.]	Aktywa razem [mln dol.]	Zobowiązania [mln dol.]	Przychody ogółem [mln dol.]	Dochód netto [mln dol.]	Zatrudnienie [szt.]	Kapitał społeczny [mln dol.] (równanie fundamentalne)	Kapitał społeczny [mln dol.] (sieć MLP 6-3-1)
Red Hat	10 451,557	2 739,581	1 545,21	423,754	37,745	6 500	5 996,376	6 280,22
Microsoft	411 000	172 000	95 000	6 500	5 000	128 000	173 327	181 412
IBM	136 790	112 037	99 543	19 600	2 900	379 592	53 811	136 580
Comarch	330,100	403,111	164	80,110	10,100	4 041	*	1307,8

* Brak możliwości obliczenia wartości kapitału społecznego za pomocą równania fundamentalnego, ponieważ wartość aktywów firmy jest wyższa niż jej wartość giełdowa.

Źródło: Opracowanie własne.

W tabeli 6.1 porównano wyniki wartości kapitału społecznego oszacowanego za pomocą równania fundamentalnego oraz z wykorzystaniem zbudowanego modelu (sieci neuronowej MLP 6–3–1). Wartości zmiennych wejściowych nie znajdowały się w zbiorze uczącym, zatem nie poddano ich trenowaniu. Wielkość kapitału społecznego została podana przez nauczoną zależność sieć neuronową (ostatnia kolumna). Takie oszacowanie możliwe było dzięki zdolności zbudowanego modelu do generalizacji (uogólniania) danych.

Przeprowadzono badania eksperymentalne, mające na celu symulację wartości kapitału społecznego przedsiębiorstw Red Hat, Microsoft, IBM oraz Comarch. Zaprezentowane w tabeli 6.1. wartości zmiennych wejściowych wszystkich przedsiębiorstw nie należały do zbioru uczącego (w przypadku firm Red Hat, Microsoft oraz Asseco dane te obejmują inne okresy niż te, na których trenowana była sieć). Wybrano dodatkowo firmę SAP – lidera rynku oprogramowania w Europie. W symulacji uwzględniono także przedsiębiorstwo Comarch ze względu na to, że jest to jedna z największych polskich spółek informatycznych oraz jest notowana na Giełdzie Papierów Wartościowych w Warszawie. Comarch specjalizuje się w projektowaniu, wdrażaniu oraz integracji zaawansowanych systemów informatycznych, narzędzi programistycznych, narzędzi i infrastruktur sieciowych. Model powinien dobrze działać dla danych firm IBM oraz Comarch, ponieważ do zbioru uczącego, na którym trenowana była sieć neuronowa, należały dane wejściowe zarówno lidera branży IT na świecie (Microsoft), jak i największej polskiej spółki IT (Asseco), a więc jednostek o podobnych wynikach finansowych.

W tabeli 6.1 pokazano wartości zmiennych wejściowych wszystkich poddanych symulacji firm oraz wartości zmiennej wyjściowej, to jest kapitału społecznego, oszacowanego za pomocą równania fundamentalnego i opracowanego przez autorkę modelu sztucznej sieci neuronowej MLP 6–3–1. Dane wejściowe polskich przedsiębiorstw zostały przeliczone ze złotych na dolary. Wartość kapitału społecznego wyznaczona z zastosowaniem sieci MLP 6–3–1 jest mniejsza o około 5% w stosunku do wartości kapitału społecznego obliczonej za pomocą równania fundamentalnego. Różnica jest niewielka i akceptowalna, co uwiarygodnia zaproponowaną metodykę jako sprawne narzędzie informatyczne do tego typu szacunków, charakteryzujące się dużą zdolnością do generalizacji danych.

Ponadto należy zwrócić uwagę na stosunek sumy aktywów firmy IBM do jej wartości giełdowej. Okazuje się, że stanowią one 60% całej wartości rynkowej przedsiębiorstwa, zatem 40% prawdziwej wartości spółki nie zostało odzwierciedlone w opublikowanych bilansach finansowych. Z przeprowadzonych badań wynika, że blisko połowę wartości giełdowej firmy IBM stanowią jej wartości niematerialne, to jest kapitał ludzki i kapitał społeczny. Z obliczeń przedstawionych w tabeli 6.1 można wywnioskować, że stosunek sumy aktywów firmy Red Hat do jej wartości giełdowej jest jeszcze mniejszy, bowiem wynosi niespełna 30%. Jest to bardzo typowe w gospodarce opartej na wiedzy, w firmach wysokich technologii różnice pomiędzy wartościami niematerialnymi i materialnymi są dużo większe.

Zupełnie odwrotne proporcje można zauważyć dla krajowych firm prowadzących działalność na rynku informatycznym. W badanych okresach aktywa materialne tworzyły wartość rynkową spółki w około 70%, a aktywa niematerialne stanowiły zaledwie około 30% wartości giełdowej firmy. Polskie przedsiębiorstwa informatyczne produkujące oprogramowanie gromadzą zbyt dużo kapitału finansowego. Taka strategia nie jest stosowana przez liderów sektora IT na świecie. Wartość giełdowa spółki jest znacznie niższa niż jej wartość księgowa (rozumiana jako różnica pomiędzy sumą aktywów a sumą zobowiązań). Świadczy to między innymi o niskiej wartości kapitału społecznego tej firmy. Przedsiębiorstwa HI-TECH o wysokiej wartości kapitału społecznego warte są na rynku giełdowym zazwyczaj kilka razy więcej niż wartość firmy wynikająca z publikowanych bilansów księgowych. Wycena wartości niematerialnych przez księgowych polskich firm (na rynku wewnętrznym) znacznie różni się od wyceny na rynku giełdowym. Zatem inwestorzy giełdowi nie są zainteresowani inwestowaniem w akcje danego przedsiębiorstwa. Podobny wniosek, potwierdzający powyższe rozważania, można także wyciągnąć, analizując dane dotyczące przedsiębiorstwa Comarch, zaprezentowane w tabeli 6.1. Suma aktywów zgromadzonych przez tą firmę jest większa niż jej wartość giełdowa. W związku z tym nie jest możliwe oszacowanie wartości kapitału społecznego tej spółki z zastosowaniem równania fundamentalnego.

Podsumowanie

Podjęta w monografii problematyka zastosowania sztucznych sieci neuronowych jako narzędzia do modelowania i analizy kapitału społecznego firm informatycznych stanowiła duże wyzwanie badawcze ze względu na chaos pojęciowy i metodologiczny w literaturze przedmiotu oraz w praktyce szacowania wartości kapitału społecznego. Zaproponowana metodyka badawcza jest podejściem nowatorskim, ponieważ jak dotąd w literaturze nie zaproponowano modelu wykorzystującego obliczenia inteligentne oraz równanie fundamentalne do modelowania kapitału społecznego firm informatycznych. Treści zaproponowane w monografii mogą stanowić wypełnienie luki badawczej polegającej na braku opracowań teoretycznych oraz narzędzi informatycznych do szacowania wartości kapitału społecznego i identyfikacji zmiennych determinujących taką wartość. Opracowany model sieci neuronowej został zaadaptowany do programu napisanego przez autorkę w języku C++. Stanowić on może narzędzie użyteczne dla kierownictwa firm informatycznych, znacznie skracając czasochłonne procesy wyceny wartości niematerialnych. Ponadto z opracowanej metodyki skorzystać mogą także inwestorzy giełdowi, którzy w krótkim czasie i w przystępny sposób mogą dokonać oszacowania wartości kapitału społecznego przedsiębiorstwa IT, w którego akcje chcą zainwestować.

Sztuczne sieci neuronowe zostały wybrane do rozwiązania postawionego problemu badawczego, ponieważ są to narzędzia o szerokich możliwościach aplikacyjnych w modelowaniu. Oprócz dużej zdolności sieci do generalizowania danych istotną ich własnością jest umiejętność odwzorowywania nieliniowych zależności. Ponadto sieć neuronowa to model oparty przede wszystkim na danych, a następnie na wiedzy analityka, zatem przed rozpoczęciem projektowania twórca sieci nie musi czynić żadnych założeń dotyczących kształtu modelu.

W monografii przeprowadzono syntezę prac studialnych z zakresu znaczenia kapitału społecznego w przedsiębiorstwach IT, omówiono stan wiedzy na temat metod i narzędzi do szacowania wartości niematerialnych oraz dokonano identyfikacji zmiennych objaśniających i założeń koncepcyjnych dotyczących pomiaru wartości kapitału społecznego organizacji informatycznych. Sformułowano model teoretyczny, a następnie zastosowano go do opracowania struktury perceptronu wielowarstwowego. W zakresie metodycznym opracowano założenia teoretyczne metodyki oraz zaproponowano instrumentarium pomiarowe kapitału społecznego, będącego najcenniejszym zasobem każdej firmy informatycznej. W aspekcie utylitarnym zaprojektowano narzędzie informatyczne, wykorzystujące obliczenia inteligentne, umożliwiające analizę

i modelowanie kapitału społecznego firm informatycznych prowadzących działalność na rynku informatycznym. Opracowany model sztucznej sieci neuronowej MLP 6-3-1 zastosowano do oszacowania wartości kapitału społecznego przedsiębiorstw informatycznych, takich jak Red Hat, Microsoft, IBM oraz Comarch. Okazało się, że oszacowane w ten sposób wartości kapitału społecznego tych firm nie różnią się w znaczący sposób od wartości obliczonych za pomocą równania fundamentalnego. Jest to argument pozwalający na uznanie zaproponowanej sieci MLP 6-3-1 jako uzasadnionego i użytecznego narzędzia do takich szacunków.

Opracowany przez autorkę program SOCAP Neural Network jest narzędziem prostym w obsłudze, pozwalającym na sprawne i szybkie obliczenia wartości kapitału społecznego firmy informatycznej. Może być także uzupełnieniem tradycyjnej wyceny o dane dotyczące ilości i jakości wartości niematerialnych przedsiębiorstwa. Nowa metodyka szacowania wartości kapitału społecznego oraz opracowane narzędzia informatyczne rozszerzają możliwości aplikacyjne sieci neuronowych. Ponadto aplikacja SOCAP Neural Network stanowić może narzędzie użyteczne dla praktyków zarządzania (szefów IT i ich księgowych) do szacowania wartości kapitału społecznego i oceny konkurencyjności przedsiębiorstwa. Odbiorcą tego narzędzia mogą być także inwestorzy giełdowi, którzy w sprawny i prosty sposób mogą oszacować wartość kapitału społecznego firmy, w której akcje giełdowe chcą zainwestować. Wartość giełdowa firm wysokich technologii zwiększa się wraz ze wzrostem wartości ich kapitału społecznego. Z punktu widzenia inwestorów giełdowych, zaproponowane rozwiązanie może być zatem dla nich praktycznie przydatne.

Warto też podkreślić, że we współczesnej literaturze zwraca się uwagę, że nadrzędnym i strategicznym celem działalności przedsiębiorstwa jest maksymalizacja jego wartości rynkowej. Pod koniec XX wieku to podejście do skutecznego zarządzania przedsiębiorstwem zostało nazwane koncepcją zarządzania wartością (ang. *Value Based Management*)¹⁵⁰. W tym kontekście zaproponowane narzędzie pozwala na weryfikowanie zmiany wartości kapitału społecznego (a więc i wartości giełdowej) w zależności od zmiany zatrudnienia i zmiany wartości innych zmiennych wejściowych.

Analiza piśmiennictwa oraz przeprowadzone rozważania teoretyczne i empiryczne mogą być podstawą do podejmowania dalszych dociekań naukowych w tym obszarze. Szczególnie interesujące może być klasyfikowanie przedsiębiorstw informatycznych z uwzględnieniem wartości ich kapitału społecznego. W rankingach firm IT oprócz przychodów ogółem, przychodów ze sprzedaży produktów i usług IT, zysku netto, produktywności na jednego pracownika, nakładów na działalność badawczo-rozwojową czy liczby zatrudnionych powinno się brać pod uwagę również wartość kapitału społecznego tego typu przedsiębiorstw. Nie zawsze pracownicy organizacji będących liderami rynku informatycznego wykazują się dużą produktywnością. Jednak wspólnie pracując twórczo nad najnowszymi rozwiązaniami, budują kapitał społeczny wielkiej wartości. Za interesujący kierunek badań należy uznać także

¹⁵⁰ G. Gołębiowski, P. Szczepankowski, *Analiza wartości przedsiębiorstwa*, Difin, Warszawa 2007, s. 11.

opracowanie założeń teoretycznych do metodyki szacowania wartości kapitału społecznego mniejszych firm informatycznych, które jeszcze nie są notowane na giełdzie papierów wartościowych.

Z materiału teoretycznego i empirycznego przedstawionego w monografii wynikają również interesujące poboczne wątki badawcze, takie jak na przykład próba rankingowania przedsiębiorstw z sektora informatycznego z uwzględnieniem wartości ich kapitału społecznego. Ciekawa wydaje się segmentacja podmiotów z branży IT i wyodrębnienie spośród nich jednorodnych grup firm podobnych do siebie pod względem wartości ich kapitału społecznego. Być może do jednej grupy należeć będą spółki o znacznie różniącej się wartości giełdowej czy istotnie różnej liczbie pracowników. Badania takie mogą zostać przeprowadzone z zastosowaniem sieci neuronowej Kohonena (ang. *Self Organizing Map*), która jest dobrym narzędziem pozwalającym na analizę skupień (ang. *cluster analysis*), polegającą na grupowaniu obiektów.

Monografia z oczywistych względów nie wyczerpuje w pełni podjętej tematyki. Należy podkreślić, że zadaniem badawczym nie było opracowanie uniwersalnej metodyki szacowania wartości kapitału społecznego, ale zbudowanie modelu sztucznej sieci neuronowej do wyznaczania wartości kapitału społecznego przedsiębiorstw informatycznych. Autorka ma pełną świadomość, że zastosowanie sztucznych sieci neuronowych, jako narzędzia do szacowania i analizy kapitału społecznego, wprowadza także pewne ograniczenia. Wynikają one przede wszystkim z podstawowej wady sieci neuronowych, to jest braku możliwości wieloetapowego rozumowania. Sieć neuronowa rozwiązuje postawiony problem jednokrokovio, nie można więc oczekiwać, że po oszacowaniu wartości kapitału społecznego przedsiębiorstwa IT będzie potrafiła ten wynik zinterpretować. Wnioskowanie na podstawie otrzymanego wyniku jest zadaniem osoby korzystającej z zaproponowanego modelu. Rozumowanie wieloetapowe wymagałoby zastosowania kilku sieci neuronowych. Nie należy także spodziewać się, że sieć neuronowa będzie rzetelnie generalizowała dane o zupełnie innych rzędach wartości niż te, na których model był trenowany. Ponadto analiza kapitału społecznego firmy nienotowanej na giełdzie papierów wartościowych nie jest możliwa za pomocą opracowanego modelu sieci neuronowej. W przypadku takich organizacji nie ma bowiem informacji o wartości jednej ze zmiennych wejściowych, to jest wartości giełdowej, obliczanej jako iloczyn liczby akcji będących w obiegu i ceny jednej akcji na zamknięciu kwartału. W takiej sytuacji niezbędne byłoby opracowanie założeń teoretycznych dotyczących metodyki szacowania wartości kapitału społecznego mniejszych firm informatycznych. Warto także zauważyć, że ze względu na specyfikę branży informatycznej, w której kapitał społeczny ma bardzo znaczący udział w całej wartości przedsiębiorstwa IT, opracowanej metodyki nie rekomenduje się do szacowania wartości kapitału społecznego firm prowadzących działalność w innych sektorach gospodarki. Przedsiębiorstwa informatyczne to firmy innowacyjne, a ich innowacyjność najlepiej sprawdza rynek giełdowy, dlatego wszystkie liczące się firmy są notowane na tym rynku.

Utrzymanie dobrej pozycji polskiego IT w Europie oraz rosnącej wartości rynku informatycznego w Polsce powinno być jednym z priorytetów zarówno administracji państwowej, jak i przedsiębiorców. Szybki rozwój polskiej gospodarki uwarunkowany jest funkcjonowaniem innowacyjnych, konkurencyjnych firm wysokich technologii. Odpowiednio wykorzystany kapitał społeczny, to jest potencjał pracowników polskich przedsiębiorstw IT, może pobudzić rozwój poszczególnych regionów, jak i całego kraju. Polscy programiści stanowią jedną z najsilniejszych reprezentacji podczas konkursu technologicznego Imagine Cup, organizowanego przez firmę Microsoft, oraz podczas Akademickich Mistrzostw Świata w Programowaniu Zespołowym. Studenci z Polski odnosili także sukcesy podczas światowych finałów tego typu konkursów. Polskie oprogramowanie i usługi informatyczne mają szansę stanowić atut gospodarczy kraju, a polscy informatycy powinni być doceniani nie tylko jako zwycięzcy światowych konkursów informatycznych, ale przede wszystkim jako partnerzy w biznesie.

Aneks

Załącznik 1

Kod źródłowy autorskiego programu SOCAP Neural Network

```
#include <vcl.h>
#pragma hdrstop

#include "TMainForm.h"
#include <cmath>
//-----
#pragma package(smart_init)
#pragma link "TNumEdit"
#pragma resource "*.dfm"
TMainForm *MainForm;
//-----

__fastcall TMainForm::TMainForm(TComponent* Owner)
: TForm(Owner)
{
    priv.state.timer_cnt = -1;
    Timer->Enabled = true;
}
//-----

void __fastcall TMainForm::prot_init(){
    priv.state.entered = 0;
    MenuLangPolski->Click();
    prot_static_update();
}
//-----
```

```

double siec(double market_value, double employment, double assets, double liabilities, double
total_revenue, double net_income){
    double we[6] = {market_value, employment, assets, liabilities, total_revenue, net_income};
    double norm[6][2] = {
        {-0.000308112824204855, 0.00000305062202183025};
        {-0.0142630744849445, 0.00000792393026941363};
        {-0.00675711190408055, 0.00000584020043567895};
        {-0.00252251343238403, 0.0000126125671619201};
        {-0.00335556737733764, 0.0000409215533821664};
        {0.0698129014241832, 0.000139625802848366};
    };
    double warstwa_1[7] = {0, 0, 0, 0, 0, 0, 1};

    double polaczenia_1[7][3] = {
        {0.46535603101202, -0.0164468035572661, -0.250930985777859};
        {0.22116783994935, -0.196107365007555, -0.474374588736207};
        {0.114347980891993, -0.138367451462913, -0.361710187889834};
        {0.234993575725989, -0.0569468946987624, -0.239846232639002};
        {0.147142390436937, -0.213611184499937, -0.446705285279842};
        {0.0760911172068558, -0.192986983255022, -0.405620792517231};
        {-0.249733005512385, 0.0348090181539225, 0.10984820926091};
    };

    double warstwa_2[4] = {0, 0, 0, 1};

    double polaczenia_2[4] = {0.923069249830434, 0.213109912388641, -0.192673861949869,
0.236188008027543};

    double norm_wynik[2] = {-228.509830684168, 184411.130119774};

    double wynik = 0;

    int i, j;

    for(i=0; i<6; ++i)
        warstwa_1[i] = norm[i][0]+we[i]*norm[i][1];

    for(j=0; j<3; ++j)
        for(i=0; i<7; ++i)
            warstwa_2[j] += warstwa_1[i]*polaczenia_1[i][j];

    for(i=0; i<3; ++i)
        warstwa_2[i] = std::tanh(warstwa_2[i]);

```

```

    for(i=0; i<4; ++i)
        wynik += warstwa_2[i]*polaczenia_2[i];

    return norm_wynik[0] + wynik*norm_wynik[1];
}

void __fastcall TMainForm::prot_static_update(){
    NumEditSC->Value = siec(
        NumEditMV->Value,
        NumEditEmp->Value,
        NumEditAss->Value,
        NumEditL->Value,
        NumEditRev->Value,
        NumEditNI->Value
    );
}
//-----

void __fastcall TMainForm::FormCloseQuery(TObject *Sender, bool &CanClose)
{
#ifdef _DEBUG
    CanClose = Application->MessageBox(
        MenuLangEnglish->Checked ? "Are you sure to quit?" : "Czy na pewno chcesz
zamknąć ten program?",
        Caption.c_str(),
        MB_OKCANCEL | MB_ICONQUESTION
    ) == IDOK;
#endif
}
//-----

void __fastcall TMainForm::FormCreate(TObject *Sender)
{
    prot_init();
}
//-----

void __fastcall TMainForm::FormPaint(TObject *Sender)
{
    TPoint arrow_1[3] = {TPoint(328, 86+8), TPoint(328, 118+8), TPoint(344, 102+8)}; //+22
    arrow_2[3] = {TPoint(552, 86+8), TPoint(552, 118+8), TPoint(567, 102+8)}; //+232

```

```

Canvas->Pen->Style = psClear;
Canvas->Pen->Width = 1;

Canvas->Brush->Style = bsSolid;

Canvas->Brush->Color = TColor(0x00FF5B5B);
Canvas->Polygon(arrow_1, 2);
Canvas->Brush->Color = TColor(0x00FFA8A8);
Canvas->Polygon(arrow_2, 2);
}
//-----

void __fastcall TMainForm::MenuSaveClick(TObject *Sender)
{
    SaveDialogRes->FileName = Caption + “.bmp”;

    SaveDialogRes->FileName = StringReplace(SaveDialogRes->FileName, “.”, “ ”;
TReplaceFlags()<<rfReplaceAll);

    if(!SaveDialogRes->Execute())
        return;

    priv.state.timer_cnt = 3;
    priv.state.to_clipboard = false;
}
//-----

void __fastcall TMainForm::MenuQuitClick(TObject *Sender)
{
    Close();
}
//-----

void __fastcall TMainForm::MenuSaveClipClick(TObject *Sender)
{
    priv.state.timer_cnt = 4;
    priv.state.to_clipboard = true;
}
//-----

void __fastcall TMainForm::MenuWetlandCharClick(TObject *Sender)
{

```

```

        ShellExecute(0, "open", 0, 0, (ExtractFileDir(Application->ExeName) + "\\O program-
ie").c_str(), SW_SHOWNORMAL);
    }
    //-----

void __fastcall TMainForm::MenuAboutClick(TObject *Sender)
{
    ShellExecute(0, "open", 0, 0, (ExtractFileDir(Application->ExeName) + "\\O program-
ie").c_str(), SW_SHOWNORMAL);
    Application->MessageBox(
        MenuLangEnglish->Checked
        ? "The application allows to assess the social capital value of IT company.\nAuthor:
Julia Siderska.\n(C)2015"
        : „Program pozwala na obliczenie wartości kapitału społecznego przedsiębiorstwa
informatycznego.\nAutor: Julia Siderska.\n(C) 2015”;
        Caption.c_str();
        MB_OK | MB_ICONINFORMATION
    );
}
//-----

void __fastcall TMainForm::TimerTimer(TObject *Sender)
{
    if(priv.state.timer_cnt == -1)
        return ;
    if(priv.state.timer_cnt--)
        return;

    if(priv.state.to_clipboard){
        Clipboard()->Clear();
        keybd_event(VK_SNAPSHOT, 1, 0, 0);
        return;
    }

    std::auto_ptr<Graphics::TBitmap> bmap(new Graphics::TBitmap);

    HDC hdc = GetWindowDC(Handle);

    bmap->Width = Width;
    bmap->Height = Height;

    BitBlt(bmap->Canvas->Handle, 0, 0, bmap->Width, bmap->Height, hdc, 0, 0, SRCCOPY);
    bmap->SaveToFile(SaveDialogRes->FileName);
}

```

```

    ReleaseDC(Handle, hdc);
}
//-----

void __fastcall TMainForm::NumEditValueChange(TObject *Sender)
{
    prot_static_update();
}
//-----

void __fastcall TMainForm::BitBtnWetlandCharClick(TObject *Sender)
{
    MenuWetlandChar->Click();
}
//-----

void __fastcall TMainForm::BitBtnAboutClick(TObject *Sender)
{
    MenuAbout->Click();
}
//-----

void __fastcall TMainForm::BitBtnQuitClick(TObject *Sender)
{
    MenuQuit->Click();
}
//-----

void __fastcall TMainForm::MenuLangEnglishClick(TObject *Sender)
{
    MenuLangEnglish->Checked = true;
    Caption = "SOCAP Neural Network";
    MenuFile->Caption = "File";
    MenuSave->Caption = "Save as picture";
    MenuQuit->Caption = "Quit";
    MenuEdit->Caption = "Edit";
    MenuSaveClip->Caption = "Copy to clipboard";
    MenuLang->Caption = "Language";
    MenuHelp->Caption = "Help";
    MenuWetlandChar->Caption = "Additional information";
    MenuAbout->Caption = "About";
}

```

```

StaticText3->Caption = "Input of NN";
LabelMV->Caption = "Market value (in mln $)";
LabelEmp->Caption = "Employment";
LabelAss->Caption = "Assets (in mln $).";
LabelL->Caption = "Liabilities (in mln $).";
LabelRev->Caption = "Total revenue (in mln $).";
LabelNI->Caption = "Net income (in mln $).";

StaticText2->Caption = "Neural network";

StaticText1->Caption = "Result";
LabelSC->Caption = "Social capital (in mln $).";

BitBtnWetlandChar->Caption = "Additional information";
BitBtnAbout->Caption = "About";
BitBtnQuit->Caption = "Quit";
}
//-----

void __fastcall TMainForm::MenuLangPolskiClick(TObject *Sender)
{
    MenuLangPolski->Checked = true;
    Caption = "SOCAP Neural Network";
    MenuFile->Caption = "Plik";
    MenuSave->Caption = "Zapisz jako obraz";
    MenuQuit->Caption = "Zakończ";
    MenuEdit->Caption = "Edycja";
    MenuSaveClip->Caption = „Kopiuj jako obraz do schowka”;
    MenuLang->Caption = "Język";
    MenuHelp->Caption = "Pomoc";
    MenuWetlandChar->Caption = „Dodatkowa informacja”;
    MenuAbout->Caption = „O programie”;

    StaticText3->Caption = „Zmienne wejściowe”;
    LabelMV->Caption = „Wartość giełdowa (w mln $).”;
    LabelEmp->Caption = „Zatrudnienie.”;
    LabelAss->Caption = „Aktywa (w mln $).”;
    LabelL->Caption = „Zobowiązania (w mln $).”;
    LabelRev->Caption = „Przychody ogółem (w mln $).”;
    LabelNI->Caption = „Dochód netto (w mln $).”;

    StaticText2->Caption = "Sieć neuronowa";

```

```
StaticText1->Caption = „Wyjście”;
LabelSC->Caption = „Kapitał społeczny (w mln $)”;

BitBtnWetlandChar->Caption = „Dodatkowa informacja”;
BitBtnAbout->Caption = „O programie”;
BitBtnQuit->Caption = „Wyjdź”;
}
//-----
```

Literatura

1. Appenzeller D., *Wartość kapitału intelektualnego firmy a prognozowanie upadłości* [w:] P. Dittmann (red.), *Prognozowanie*, „Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu. Ekonometria” 24, nr 38, Wydawnictwo Uniwersytetu Ekonomicznego, Wrocław 2009.
2. Azhari A., Elhag A., Tahani A. i in., *Artificial neural networks and statistical models for optimization studying COVID-19*, „Results in Physics” 25(4), 2021.
3. Azoff E.M., *Neural network time series forecasting of financial markets*, Wiley, New York 1994.
4. Baron B., Pasierbek A., *Porównanie wydajności algorytmów gradientu sprzężonego i quasi-newtonowskiego BFGS w zagadnieniu optymalizacji rozptywu mocy w systemie elektroenergetycznym*, „Prace Naukowe Politechniki Śląskiej. Elektryka” 2009, z. 3.
5. Beck V., Britzelmaier B., *Value-based management – a critical review*, „International Journal of Sales Retailing and Marketing”, vol. 13 (3), 2011, s. 270–286.
6. Becker G., *Human capital: a theoretical and empirical analysis, with special reference to education*, The University of Chicago Press, Chicago 1964.
7. Bishop Ch.M., *Neural Networks for Pattern Recognition*, Oxford University Press, Oxford 1995.
8. Blang M., *Teoria ekonomii: ujęcie retrospektywne*, Wydawnictwo Naukowe PWN, Warszawa 2000.
9. Bochniarz P., Gugała K., *Budowanie i pomiar kapitału ludzkiego w firmie*, Poltex, Warszawa 2005.
10. Chodakowska E., Halicka K., Kononiuk A., Nazarko J., *Zastosowanie sztucznych sieci neuronowych do prognozowania cen energii elektrycznej na Towarowej Giełdzie Energii S.A.* [w:] L. Kiełtyka, J. Nazarko (red.), *Technologie informatyczne i prognozowanie w zarządzaniu – wybrane zagadnienia*, Białystok 2005, s. 235–245.
11. Coleman J., *Social Capital in the Creation of Human Capital*, „The American Journal of Sociology”, Supplement: *Organizations and Institutions: Sociological and Economic Approaches to the Analysis of Social Structure* 1988, vol. 94.
12. Coleman K.G., Graettinger T.J., Lawrence W.F., *Neural networks for bankruptcy prediction: The power to solve financial problems*, Artificial Intelligence Review, California 1991.
13. Dobija D., *Pomiar kapitału ludzkiego i możliwości raportowania wyników*, „Zarządzanie zasobami ludzkimi” 2002, nr 5.
14. Domański S.P., *Kapitał ludzki i wzrost gospodarczy*, Wydawnictwo Naukowe PWN, Warszawa 1993.

15. Dziwulski J., Skowron S., *Kapitał ludzki w perspektywie strategicznej i operacyjnej – aspekty metodologii badań*, Studia i Prace Kolegium Zarządzania i Finansów, Szkoła Główna Handlowa, Warszawa 2019.
16. Dziwulski J., Skowron, *Struktura i pomiar kapitału intelektualnego*, Wydawnictwo Politechniki Lubelskiej, Lublin 2020.
17. Edvinsson L., Malone M.S., *Intellectual Capital. The Proven Way to Establish your Company's Real Value by Measuring its Hidden Brainpower*, Harper Business, London 1997; wyd. pol. *Kapitał intelektualny. Poznaj prawdziwą wartość swojego przedsiębiorstwa, odkrywając jego ukryte korzenie*, Wydawnictwo Naukowe PWN, Warszawa 2001.
18. Ejdyś J., Gudanowska A., Halicka K. i in., *Foresight in Higher Education Institutions: Evidence from Poland. Foresight and STI Governance* 1, 2018, vol. 13, s. 77–89. DOI: 10.17323/2500-2597.2019.1.77.89.
19. Flasiński M., *Wstęp do sztucznej inteligencji*, Wydawnictwo Naukowe PWN, Warszawa 2011.
20. Fukuyama F., *Kapitał społeczny* [w:] L.E. Harrison, S.P. Huntington (red.), *Kultura ma znaczenie*, Zys i S-ka, Kraków 2003.
21. Fukuyama F., *Zaufanie. Kapitał społeczny a droga do dobrobytu*, Wydawnictwo Naukowe PWN, Warszawa-Wrocław 1997.
22. Gołębiowski G., Szczepankowki P., *Analiza wartości przedsiębiorstwa*, Difin, Warszawa 2007.
23. Grodzki J., *Rola kapitału ludzkiego w rozwoju gospodarki globalnej*, Wydawnictwo Uniwersytetu Gdańskiego, Gdańsk 2003.
24. Halicka H., *Wykorzystanie sztucznych sieci neuronowych do prognozowania cen na giełdzie energii*, „Rynek Energii” 2010, nr 1.
25. Hamadneh N.N., Khan W.A., Ashraf W. i in., *Artificial neural networks for prediction of Covid-19 in Saudi Arabia*, *Computers, Materials & Continua*, 3, 2021, vol. 66.
26. Hariri W., Narin A., *Deep Neural Networks for COVID-19 Detection and Diagnosis using Images and Acoustic-based Techniques: A Recent Review*, *Soft Computing*, Springer, 2021.
27. Herbrich R., Keilbach M., Graepel T. i in., *Neural Networks in Economics: Background, Applications and New Developments*, *Advances in Computational Economics: Computational Techniques for Modeling Learning in Economics*, Springer, New York 1999.
28. Janeski M., Kalajdziski S., *Neural network model for forecasting Balkan stock exchange*, ICIC'11 Proceedings of the 7th international conference on Advanced Intelligent Computing, Springer-Verlag Berlin 2011.
29. Kaplan R.S., Norton D.P., *Using the Balanced Scorecard as a Strategic Management System*, „Harvard Business Review” 74, no. 1 (January–February 1996): 75–85. (Reprint #96107.), 1996.
30. Kiker B.F., *The historical roots of the concept of human capital*, „Journal of Political Economy” 5, 1966, vol. 74.
31. Knosala R., *Zastosowanie metod sztucznej inteligencji w inżynierii produkcji*, Wydawnictwo Naukowo-Techniczne, Warszawa 2002.
32. Koronacki J., Ćwik J., *Statystyczne systemy uczące się*, Wydawnictwo Naukowo-Techniczne, Warszawa 2005.
33. Korbicz J., Obuchowicz A., Uciński D., *Sztuczne sieci neuronowe. Podstawy i zastosowania*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1994.

34. Kosiński R.A., *Sztuczne sieci neuronowe – dynamika nieliniowa i chaos*, Wydawnictwo Naukowo-Techniczne, Warszawa 2007.
35. Li X-F., Zhang P., *A research on value of individual human capital of high-tech enterprises based on the BP neural network algorithm*, 19th International Conference on Industrial Engineering and Engineering Management: Assistive Technology of Industrial Engineering, Springer-Verlag Berlin Heidelberg, Berlin 2013.
36. Libertowska A., *Social capital in the Value-Based Management*, „Economics and Management”, 2, 2014, s. 85–96.
37. Lula P., *Jednokierunkowe sieci neuronowe w modelowaniu zjawisk ekonomicznych*, Wydawnictwo Akademii Ekonomicznej, Kraków 1999.
38. Lula P., Paliwoda-Pękosz G., Tadeusiewicz R., *Metody sztucznej inteligencji i ich zastosowania w ekonomii i zarządzaniu*, Wydawnictwo Akademii Ekonomicznej, Kraków 2007.
39. Lula P., Stal J., Tadeusiewicz R i in., *Komputerowe metody analizy i przetwarzania danych*, Uniwersytet Ekonomiczny, Kraków 2012.
40. Łukasiewicz G., *Kapitał ludzki organizacji. Pomiar i sprawozdawczość*, PWN, Warszawa 2009.
41. Martinez L.C., da Hora D.N, de M. Palotti J.R. i in., *From an artificial neural network to a stock market day-trading system: a case study on the BM&F BOVESPA*, IJCNN'09 Proceedings of the 2009 International Joint Conference on Neural Networks, “IEEE Press Piscataway” 2009.
42. Martyniuk V., Tsygylk N., Skowron S., *The Impact of the Covid-19 Pandemic on Key Indicators of Personnel Security: A Study with Neural Network Technologies*, European Research Studies Journal, vol. 24, „Special Issue” 2, 2021.
43. Marvin M, Papert S., *Perceptrons: An Introduction to Computational Geometry*, The MIT Press, Cambridge, MA 1969.
44. Masters T., *Practical Neural Network Recipes in C++*, Academic Press, New York 1993.
45. McCulloch W.S., *A Logical Calculus of the Ideas Immanent in Nervous Activity*, „Bulletin of Mathematical Biophysics” 5, 1943.
46. Mincer J., *Human capital and economic growth*, National Bureau of Economic Research, Cambridge 1981.
47. Morajda J., *Metody sztucznej inteligencji w zarządzaniu portfelem inwestycyjnym* (praca doktorska), Kraków 1999.
48. Morajda J., *Wybrane możliwości zastosowań sieci neuronowych w ekonomii i zarządzaniu*, „Zeszyty Naukowe Akademii Ekonomicznej” 1997, nr 493.
49. Mulawka J. J., *Systemy ekspertowe*, Wydawnictwo Naukowo-Techniczne, Warszawa 1996.
50. Nazarko J., Halicka K., *Electric energy prices forecasting on power exchange with the application of artificial neural networks*, 28th International Symposium on Forecasting, ISF'2008, Nice, France, June 22–25, 2008.
51. Niazkar H.R., Niazkar M., *Application of artificial neural networks to predict the COVID-19 outbreak*, „Global Health Research and Policy” 5, 50, 2020.
52. Oane C.M., Smolag K., Marinescu E.S i in., *Value-based management as the innovating paradigm of contemporary governance – a theoretical approach*, *Polish Journal of Management Studies* 12(1), 2015.

53. Osowski S., *Sieci neuronowe w ujęciu algorytmicznym*, Wydawnictwo Naukowo-Techniczne, Warszawa 1996.
54. Pei-Chann Ch., Chen-Hao L., Chin-Yuan F. i in., *An ensemble of neural networks for stock trading decision making*, ICIC'09 Proceedings of the Intelligent computing 5th International Conference on Emerging Intelligent Computing Technology and Applications, Springer-Verlag Berlin 2009/
55. Petty W., *Traktat o podatkach i daninach*, Londyn 1662.
56. Putnam R.D., Leonardi R., Nanetti R.Y., *Demokracja w działaniu. Tradycje obywatelskie we współczesnych Włoszech*, Wydawnictwo Znak, Warszawa 1995.
57. Ramón y Cajal S., *Histology of the Nervous System of Man and Vertebrates*, „History of Neuroscience” 6, 1995, vol. 2.
58. Rappaport A., *Creating Shareholder Value. The New Standard for Business Performance*, The Free Press, New York 1986.
59. Rumelhart D.E., Hinton G. E., Williams R.J., *Learning Internal Representations by Error Propagation* [w]: *Parallel Distributed Processing*, MIT Press, Cambridge, MA 1986.
60. Runiewicz-Wardyn M., *Social capital and social networks in the life sciences industry clusters. An analysis of selected case studies / Kapitał społeczny i sieci społecznościowe w klastrach sektora nauk o życiu. Analiza wybranych studiów przypadku*, „Economic and Regional Studies”, 14(3), 2021, s. 279–293.
61. Rutkowska D., Piliński M., Rutkowski L., *Sztuczne sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, Wydawnictwo Naukowe PWN, Warszawa 1997.
62. Rutkowski L., *Metody i techniki sztucznej inteligencji*, Wydawnictwo Naukowe PWN, Warszawa 2009.
63. Schultz T.W., *Investment in Human Capital*, The Free Press, New York 1976.
64. Sexton R.S., Dorsey R.E., Johnson J.D., *Beyond backpropagation: using simulated annealing for training neural network*, „Journal of Organizational and End User Computing (JOEUC)”3, 1999, vol. 11.
65. Shawaqfah M., Fares A., *Forecast of the outbreak of COVID-19 using artificial neural network: Case study Qatar, Spain, and Italy*, „Results in Physics” 2021, vol. 27.
66. Sibi P., Allwyn-Jones A., Siddarth P., *Analysis of different activation function using back propagation neural network*, „Journal of Theoretical and Applied Information Technology” 3, 2013, vol. 47.
67. Siderska J., *Analiza możliwości zastosowania sieci neuronowych do modelowania wartości kapitału społecznego w firmach IT*, „Ekonomia i Zarządzanie” 2013, t. 5 (1).
68. Siderska J., *Application of neural network for social capital analysis*, „Technical Transactions – Automatic Control” 2-AC 2013.
69. Siderska J., *The role of social capital of the modern IT company* [w:] A. Myśliński (red.), *Techniki informacyjne – teoria i zastosowania*, t. 5 (17), Instytut Badań Systemowych PAN, Warszawa 2015.
70. Siderska J., *Wstępna ocena roli wartości niematerialnych w firmie Prokom*, [w:] J. Hołubiec (red.), *Techniki informacyjne – teoria i zastosowania*, t. 1, Instytut Badań Systemowych PAN, Warszawa 2011.
71. Siudak M., *Zarządzanie wartością przedsiębiorstwa*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2001, s. 5.

72. Sveiby K.E., *The new organisational wealth. Managing and measuring knowledge – based assets*, Berret-Koehler Publishers Inc., San Francisco CA 1997.
73. Śledzik K., *Kapitał intelektualny a wartość rynkowa banków giełdowych* (rozprawa doktorska), Fundacja Rozwoju Uniwersytetu Gdańskiego, Sopot 2012.
74. Tadeusiewicz R., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza, Warszawa 1993.
75. Tadeusiewicz R., *Odkrywanie właściwości sieci neuronowych przy użyciu programów w języku C#*, Polska Akademia Umiejętności, Międzywydziałowa Komisja Nauk Technicznych, Kraków 2007.
76. Tadeusiewicz R., Lula P., *STATISTICA Neural Networks PL. Przewodnik problemowy*, StatSoft, Kraków 2001.
77. Tadeusiewicz R., Morajda J., *Artificial Intelligence Methods [w:] Analysis and Data Processing Computer Methods*, Wydawnictwo Uniwersytetu Ekonomicznego, Kraków 2012.
78. Tadeusiewicz R., Szaleniec M., *Leksykon sieci neuronowych*, Wydawnictwo Fundacji „Projekt Nauka”, Wrocław 2015.
79. Theis M., Krewni – znajomi – obywatele. *Kapitał społeczny a lokalna polityka społeczna*, Wydawnictwo Adam Marszałek, Toruń 2007.
80. Trippi R.R., Turban E., *Neural Networks in Finance and Investment: Using Artificial Intelligence to Improve Real – World Performance*, Probus, Chicago, IL 1993.
81. Turovets Y., *Intangible assets and the efficiency of manufacturing firms in the age of digitalisation: the Russian case*, „Engineering Management in Production and Services” 13(1), 2021, s. 7–26.
82. Walczak S., *Methodological Triangulation Using Neural Networks for Business Research*, „Advances in Artificial Neural Systems” 2012, vol. 2012.
83. Walukiewicz S., *The Dimensionality of Capital and Proximity*, „Proceedings of ERSA 2008” 2008.
84. Walukiewicz S., *Kapitał ludzki*, Instytut Badań Systemowych PAN, Warszawa 2010.
85. Walukiewicz S., *Kapitał społeczny*, Instytut Badań Systemowych PAN, Warszawa 2012.
86. Walukiewicz S., *The market triple*, „Central European Journal of Operations Research” 4, 2014, vol. 22.
87. White H., *Economic prediction using neural networks: the case of IBM daily stock returns*, IEEE International Conference on Neural Networks, vol. 2, San Diego 1988.
88. Wiktorzak A.A., *Analiza systemowa i obliczenia inteligentne w modelowaniu kapitału ludzkiego i społecznego na przykładzie szkoły ponadgimnazjalnej* (rozprawa doktorska), Instytut Badań Systemowych PAN, Warszawa 2009.
89. Zhang G., Patuwo B. E., Hu M.Y., *Forecasting with artificial neural networks: The state of the art*, „International Journal of Forecasting” 14, 1998.
90. Zieliński J.S., *Inteligentne systemy w zarządzaniu. Teoria i praktyka*, Wydawnictwo Naukowe PWN, Warszawa 2000.

Spis tabel

Tabela 3.1. Matematyczne definicje funkcji aktywacji	41
Tabela 4.1. Wartości globalnej analizy wrażliwości dla 12 zmiennych wejściowych.....	53
Tabela 4.2. Wartości danych wejściowych i kapitału społecznego w firmie Red Hat w I kwartale 2014 roku	55
Tabela. 4.3. Wybrane parametry testowanych sieci i ich wartości jakości	61
Tabela 5.1. Charakterystyka modelu neuronowego	67
Tabela 5.2. Wartości globalnej analizy wrażliwości dla analizowanych zmiennych	70
Tabela 5.3. Średnia oraz odchylenie standardowe zmiennych.....	71
Tabela 5.4. Matematyczna struktura opracowanej sieci neuronowej.....	75
Tabela 6.1. Wartości kapitału społecznego w wybranych przedsiębiorstwach	80

Spis rysunków

Rysunek 0.1. Metodyka badań przyjęta w monografii.....	10
Rysunek 2.1. Różnica pomiędzy podziałem a rozbiciem: a) podział wycinka X na A oraz B, b) rozbicie wycinka X na A oraz B.....	25
Rysunek 2.2. Rozbicie wartości firmy na cztery formy kapitału.....	27
Rysunek 3.1. Schemat neuronu McCullocha-Pittsa	31
Rysunek 3.2. Budowa komórki nerwowej.....	37
Rysunek 3.3. Cybernetyczny model neuronu.....	37
Rysunek 3.4. Model sztucznego neuronu	38
Rysunek 3.5. Wybrane wykresy funkcji aktywacji neuronu.....	42
Rysunek 3.6. Schemat budowy prostej wielowarstwowej sieci neuronowej	42
Rysunek 4.1. Uproszczony schemat przetwarzania sygnałów wejściowych przez sztuczną sieć neuronową	50
Rysunek 4.2. Struktura sieci neuronowej MLP 6–3–1	58
Rysunek. 5.1. Nadzorowane uczenie sieci neuronowej	63
Rysunek 5.2. Okno wynikowe po zakończonym trenowaniu sieci	67
Rysunek 5.3. Perceptron wielowarstwowy MLP 6–3–1	68
Rysunek 5.4. Wykres błędu uczenia w próbie uczącej	72
Rysunek 5.5. Fragment kodu opracowanej sieci neuronowej zapisany w języku PMML (z pakietu STATISTICA).....	73
Rysunek 6.1. Okno graficznego interfejsu aplikacji SOCAP Neural Network.....	78
Rysunek 6.2. Przewidywania sieci w programie STATISTICA.....	78
Rysunek 6.3. Przewidywania sieci w aplikacji SOCAP Neural Network	79

