Zeszyty Naukowe
Wyższej Szkoły Bankowej we Wrocławiu
Nr 7(45)/2014

Monika Hadaś-Dyduch

Uniwersytet Ekonomiczny w Katowicach

Zastosowanie metod taksonomiczno-sieciowych w procesie wyznaczania syntetycznego miernika rozwoju inwestycji

Streszczenie. W artykule przedstawiono nieklasyczną koncepcję wyznaczania syntetycznego miernika rozwoju jako taksonomicznej miary atrakcyjności inwestycji. Konstrukcję syntetycznego miernika rozwoju zaproponowano przy użyciu sztucznych sieci neuronowych. Celem głównym artykułu jest przedstawienie możliwości predykcji syntetycznego miernika na podstawie sztucznych sieci neuronowych ze wskazaniem na funkcję treningu sieci, błąd uczenia sieci itp. parametry. Konstrukcję klasycznego syntetycznego miernika rozwoju przeprowadzono dla 33 spółek akcyjnych, przyjmując następujące miary: wskaźnik bieżącej płynności, wskaźnik szybkiej płynności, wskaźnik ogólnego poziomu zadłużenia, wskaźnik zadłużenia kapitału własnego, wskaźnik rotacji zapasów, okres spływu należności, wskaźnik rotacji zobowiązań, wskaźnik zyskowności netto, wskaźnik rentowności aktywów (ROA), wskaźnik rentowności kapitału własnego (ROE), wskaźnik P/E, wskaźnik P/BV.

Słowa kluczowe: miernik syntetyczny, sztuczne sieci neuronowe, analiza portfelowa

Wprowadzenie

Każdy podmiot prowadzący działalność gospodarczą czy inwestujący na rynku kapitałowym jest narażony na ryzyko, gdyż zarówno przedsiębiorstwo, jak i indywidualny inwestor nie mają całkowitej pewności co do wielkości i okresu wystąpienia przyszłych przepływów pieniężnych związanych z podjętymi decyzjami. Podmioty te mogą osiągnąć zyski znacznie większe od oczekiwanych lub

ponieść nieoczekiwane straty. Ta niepewność odnośnie do przyszłych zysków lub strat oznacza, że działalność prowadzona jest w warunkach ryzyka. Stwarza to z jednej strony szansę, a z drugiej zagrożenia związane z prowadzoną działalnością. Jednakże inwestor stara się wyeliminować ryzyko oraz dokładnie poznać otoczenie, w którym działa firma, jak również jej sytuację finansową. Analiza wskaźnikowa pozwala zorientować się w sytuacji finansowej firmy, lecz mnogość generowanych przez nią informacji zaciemnia ogólną ocenę spółki na tle innych spółek notowanych na giełdzie. Rozwiązaniem tego problemu może być natomiast uzupełnienie jej o taksonomiczną miarę atrakcyjności inwestycji (TMAI), która poprzez stworzenie syntetycznej miary umożliwia dodatkowo ocenę pozycji spółki na tle konkurencji, co jest punktem wyjścia do podejmowania trafnych decyzji.

1. Klasyczny algorytm konstrukcji syntetycznego miernika rozwoju

Syntetyczne mierniki rozwoju są stosowane przede wszystkim do liniowego porządkowania obiektów wielocechowych ze względu na rozwój badanego zjawiska[1]. Umożliwiają zastąpienie opisu przez wiele cech diagnostycznych jedną agregatową wielkością – zmienną syntetyczną.

Konstrukcję syntetycznego miernika można przedstawić w następujących etapach:

1) zbudowanie macierzy $X = [x_{ij}] \quad i = 1,...,n \quad j = 1,...,m$, zawierającej obserwacje cech diagnostycznych badanych obiektów,

2) normalizacja wartości zmiennych diagnostycznych (x_{ij}), przedstawionych w postaci stymulant,

3) utworzenie wzorca, czyli obiektu, który ma najkorzystniejsze wartości zmiennych diagnostycznych $\left(z_{0j} = \max_i \{z_{ij}\}\right)$, jakie zostały zaobserwowane w całym zbiorze danych,

4) wyznaczenie odległości każdego obiektu od wzorca (d_i),

5) obliczenie odległości każdego obiektu od wzorca na podstawie formuły:

$$d_i = \sqrt{\frac{1}{m}\sum_{j=1}^{m}(z_{ij} - z_{oj})^2},$$

[1] M. Łuniewska, W. Tarczyński, *Metody wielowymiarowej analizy porównawczej na rynku kapitałowym*, WN PWN, Warszawa 2006.

gdzie:

n – liczba obiektów, $i = 1,..., n$,

m – liczba zmiennych, $j = 1,..., m$,

z_{ij} – znormalizowana wartość j-tej zmiennej dla i-tego obiektu,

z_{oj} – wzorcowa znormalizowana wartość j-tej zmiennej.

Aby syntetyczny miernik był unormowany i jego większe wartości wskazywały na wyższy poziom badanego zjawiska, odległość d_i przekształca się według następującej formuły:

$$z_i = 1 - \frac{d_i}{d_0}, \quad i = 1, 2, ..., n,$$

gdzie:

z_i – syntetyczna miara rozwoju dla i-tego obiektu,

d_i – odległość i-tego obiektu od wzorca (odległość Euklidesowa),

d_0 – norma zapewniająca przyjmowanie przez z_i wartości z przedziału od 0 do 1.

Syntetyczny miernik rozwoju im bliższy zeru, tym poziom rozwoju badanego zjawiska jest w danym obiekcie niższy. W celu uwzględnienia różnego wpływu poszczególnych zmiennych diagnostycznych na badane zjawisko, w procedurze konstrukcji syntetycznego miernika rozwoju wprowadza się wagi.

1.1. Przykład empiryczny

Konstrukcję syntetycznego miernika rozwoju przeprowadzamy dla 33 spółek akcyjnych. Do konstrukcji syntetycznego miernika rozwoju przyjmujemy następujące miary: wskaźnik bieżącej płynności, wskaźnik szybkiej płynności, wskaźnik ogólnego poziomu zadłużenia, wskaźnik zadłużenia kapitału własnego, wskaźnik rotacji zapasów, okres spływu należności, wskaźnik rotacji zobowiązań, wskaźnik zyskowności netto, wskaźnik rentowności aktywów (ROA), wskaźnik rentowności kapitału własnego (ROE), wskaźnik P/E, wskaźnik P/BV. Wybór wskaźników był subiektywny. Wszystkie zebrane dane (tab. 1) przekształcono i przedstawiono w postaci stymulant.

Wyznaczony według przedstawionego wcześniej algorytmu syntetyczny miernik rozwoju dla rozpatrywanych spółek przyjmuje wartości przedstawione na rysunku 1.

Tabela 1. Wartości zmiennych diagnostycznych w wybranych do analizy spółkach

Spółka	Płynność bieżąca	Płynność szybka	Zadłużenie ogółem	Zadłużenie kapitału własnego	Rotacja zapasów	Rotacja należności	Rotacja zobowiązań	Zyskowność netto	ROA	ROE	P/BV	P/E
LOTOS	2,40	1,36	0,30	0,43	–56,06	36,32	–77,94	0,03	0,01	0,02	0,95	7,48
PGNiG	2,58	2,12	0,31	0,45	0,00	53,69	0,00	0,09	0,01	0,02	0,43	7,37
PKNORLEN	1,20	0,70	0,52	1,09	–57,77	43,30	–185,97	0,01	0,00	0,00	1,04	8,45
BUDIMEX	1,20	0,93	0,76	3,22	–42,25	54,65	–170,62	0,00	0,00	0,00	4,98	668,74
ELEKTREX	0,18	0,15	1,51	–2,33	–24,66	101,18	–747,67	–0,58	–0,10	0,15	–0,46	–0,87
ENERGOPLD	1,17	0,75	0,70	2,29	–74,99	96,81	–219,01	–0,05	–0,02	–0,05	2,34	–8,13
ENERGOPN	2,01	1,93	0,42	0,72	–8,22	86,49	–113,82	0,02	0,01	0,01	4,70	71,97
ELKOP	1,01	1,00	1,07	–7,13	–1,22	83,99	–582,77	0,41	0,09	–0,61	–17,32	0,00
INSTAL KRAKÓW	1,76	1,18	0,38	0,68	–37,74	57,46	–65,44	0,02	0,01	0,02	4,09	0,00
POLIMEXMS	1,38	1,19	0,72	2,55	–19,06	91,23	–130,88	0,01	0,01	0,02	10,33	0,00
ECHO	1,51	0,94	0,49	1,10	–562,59	59,64	–3435,32	0,46	0,01	0,03	3,93	0,00
ASSECOPOL	1,67	1,60	0,50	0,99	–13,80	97,22	–279,53	0,21	0,04	0,09	9,48	0,00
CSS	1,36	1,26	0,48	0,96	–8,40	64,35	–86,00	0,04	0,02	0,05	4,94	0,00
COMARCH	1,77	1,63	0,44	0,79	–12,99	73,77	–130,11	0,13	0,05	0,09	7,25	0,00
COMPUTER-LAND	1,24	1,12	0,56	1,56	–15,06	83,50	–139,51	0,04	0,02	0,05	2,35	0,00
COMP	2,22	1,88	0,46	0,85	–54,57	111,45	–264,21	0,20	0,05	0,10	3,96	0,00
OPTIMUS	0,97	0,60	0,68	2,12	–40,97	50,38	–113,84	–0,16	–0,10	–0,30	5,54	0,00
SIMPLE	2,62	2,59	0,42	0,73	–1,56	55,38	–179,72	0,10	0,04	0,07	3,38	0,00
MACROLOGIC	2,01	1,94	0,25	0,33	–5,38	46,85	–90,63	0,16	0,08	0,10	4,92	0,00
AGORA	2,82	2,73	0,24	0,32	–9,77	58,73	–193,43	0,05	0,01	0,01	2,27	0,00
ATM GRUPA	4,43	4,01	0,15	0,18	–27,38	101,95	–70,68	0,24	0,07	0,09	10,99	0,00
INTERIA	2,81	2,81	0,24	0,34	–0,24	57,32	–110,63	0,07	0,04	0,06	9,84	0,00
MNI	0,86	0,85	0,51	1,06	–1,69	73,62	–243,48	0,01	0,00	0,01	4,93	0,00
MUZA	2,58	1,09	0,29	0,67	–268,01	135,95	–180,21	–0,39	–0,08	–0,18	1,46	0,00
PPWK	2,13	1,73	0,17	0,21	–4225,50	99,69	–11022,75	0,24	0,03	0,03	0,93	0,00
TVN	1,91	1,34	0,49	1,08	–81,26	41,16	–584,75	0,32	0,05	0,10	7,29	0,00
WSiP	4,28	3,35	0,35	0,63	–159,57	29,81	–406,61	–0,36	–0,04	–0,07	3,44	0,00
ATMSA	1,84	1,74	0,37	0,67	–11,21	127,17	–135,28	0,37	0,13	0,24	5,53	0,00
ELEKTRIM	0,94	0,93	0,75	3,04	4,38	559,24	1868,92	–6,64	–0,28	–1,13	–1,94	0,00
HYPERION	9,31	9,31	0,13	0,15	–0,04	82,44	–130,40	0,21	0,02	0,02	2,93	0,00
NETIA	1,70	1,69	0,10	0,11	0,00	67,34	0,00	–1,78	–0,14	–0,16	0,82	0,00
TP	0,41	0,39	0,45	0,81	0,00	36,05	0,00	0,08	0,01	0,02	1,79	0,00
TELL	1,49	1,20	0,55	1,27	–20,66	52,22	–69,33	0,03	0,03	0,06	5,51	0,00

Ź r ó d ł o: opracowanie własne.

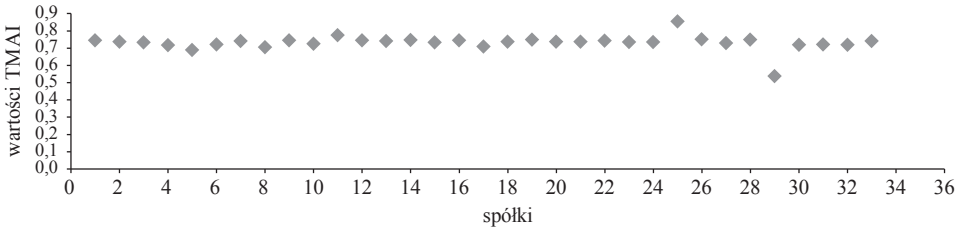

Rys. 1. Wartości TMAI w analizowanym okresie dla rozpatrywanych spółek akcyjnych
Ź r ó d ł o: opracowanie własne.

Syntetyczny miernik rozwoju im bliższy zeru, tym poziom rozwoju badanego zjawiska jest w danym obiekcie niższy. Z wykonanych obliczeń oraz danych przedstawionych na rys. 1 wynika, że najlepszą ze względu na siłę fundamentalną jest spółka PPWK. Z kolei najgorzej w badanym okresie wypadły spółki ELEKTRIM i ELEKTREX. Wyznaczone miary TMAI są syntetyczną oceną faktycznej kondycji ekonomiczno-finansowej badanych spółek.

2. Konstrukcja syntetycznego miernika przy użyciu sztucznych sieci neuronowych

Alternatywnym sposobem konstrukcji syntetycznego miernika TMAI do przedstawionego w rozdziale pierwszym jest algorytm wykorzystujący sieci neuronowe. Aby wygenerować TMAI poprzez sieć neuronową, należy określić w pierwszej kolejności jej strukturę, funkcję treningu, funkcje aktywacji oraz wektor wejściowy i wyjściowy sieci.

Do konstrukcji stosujemy sieć wielowarstwową jednokierunkową, czyli sieć, w której przepływ sygnałów występuje w jednym kierunku, od wejścia do wyjścia. Każda warstwa tej sieci składa się z zadanej liczby neuronów o nieliniowych funkcjach aktywacji (jakkolwiek funkcje aktywacji w poszczególnych warstwach mogą mieć również postać liniową).

Przyjmujemy sieć złożoną z 12 wejść i 1 wyjścia (rys. 2). Wektorem wejściowym sieci będą wartości wskaźników dla poszczególnych spółek, natomiast wektorem wyjściowym będzie wektor TMAI. Sieć będzie miała 1 warstwę ukrytą złożoną z 20 neuronów, pobudzoną liniową funkcją aktywacji i 1 warstwę wyjściową, złożoną z 1 neuronu, pobudzoną również liniową funkcją aktywacji.

Trening sieci odbywa się metodą gradientową, algorytmem Broydena–Flrtchera–Goldfarba–Shano z krokiem uczenia wynoszącym 0,05 i dopuszczalnym błędem sieci e^{-12}.

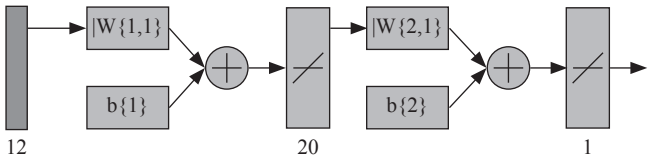

Rys. 2. Obraz zaprojektowanej sieci

Ź r ó d ł o: opracowanie własne.

Mając przygotowany zbiór danych uczących i zaprojektowaną sieć oraz korzystając z oprogramowania MATLAB, możemy uruchomić proces uczenia sztucznej sieci neuronowej, w którym zmieniane są wagi sieci, zgodnie z zadanym algorytmem tak, aby zminimalizować błąd pomiędzy odpowiedzią sieci a zbiorem uczącym.

W czasie procesu uczenia wyświetlany jest wykres zmian wartości błędu w kolejnych krokach iteracji (wykres 1).

Wykres 1. Błąd MSE sieci

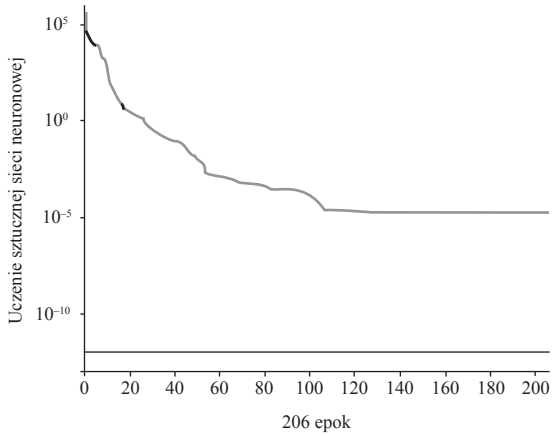

Performance is 1.5616e-005, Goal is 1e-012

Ź r ó d ł o: opracowanie własne.

Założony maksymalny błąd e^{-12} nie został osiągnięty (wykres 1). Jednak ta sieć nie potrafi dopasować się lepiej niż e^{-5}. Nawet gdybyśmy pozwolili uczyć się sieci dalej, zwiększając liczbę epok, to nie ma ona szans osiągnąć założonego pułapu.

Uzyskanie na tym etapie dużej zgodności (małego błędu) pomiędzy wartościami zbioru uczącego a wartościami uzyskanymi z sieci daje podstawę do stwierdzenia, że sieć spełnia nasze wymagania (wykres 2).

Analizując wykres 2, można stwierdzić, że sieć dobrze generuje wartości syntetycznego miernika dla zadanych danych. Osiąga wyniki podobne do wygenerowanych na podstawie algorytmu przedstawionego w rozdziale pierwszym (wykres 2). Sieć wygenerowała dane po 206 epokach.

Wykres 2. Porównanie wartości TMAI wygenerowanej dwoma metodami

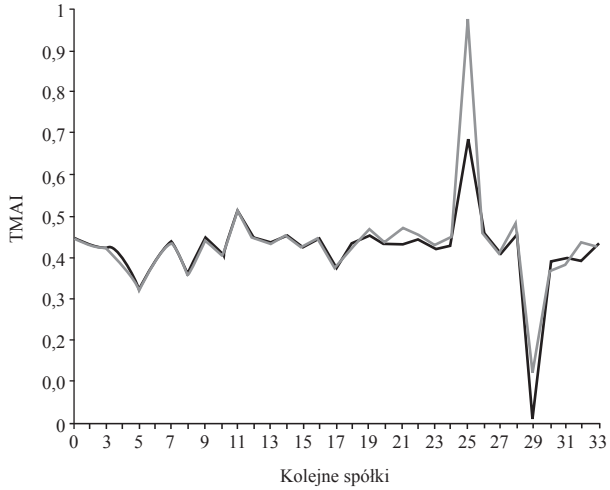

Linia czarna – TMAI, linia szara – sieć neuronowa

Ź r ó d ł o: opracowanie własne.

Choć z powyższych rozważań można wnioskować, że sztuczna sieć neuronowa jest skutecznym narzędziem do generowania i prognozowania wartości TMAI, a zatem do oceny fundamentalnej siły spółek, jednak jak pokazują poniższe rozważania „wynik", czyli wektor wyjściowy sieci, zależy od wielu parametrów, np. zastosowanej funkcji aktywacji, liczby neuronów w poszczególnych warstwach, funkcji treningu sieci.

2.1. Założony błąd a szybkość generowania TMAI

Parametrem pozwalającym na określenie żądanej jakości dopasowania sieci (dopuszczalny błąd sieci) do danych empirycznych jest średni błąd kwadratowy (MSE). W niektórych typach sieci stosuje się również inne miary, np.: SSE (*Sum squared error performance function*), MAE (*Mean absolute error*). Po osiągnięciu tej wartości algorytm uczenia sieci zostaje przerwany. Gdy ustalimy go na zbyt niskim poziomie, sieć nauczy się tylko „trochę", gdy na zbyt wysokim – może nie osiągnąć go nigdy.

Przyjmując przy założonych wcześniej parametrach dopuszczalny błąd sieci e^{-5}, otrzymujemy wartości syntetycznego miernika TMAI (wykres 3) wygenerowane przez sieć neuronową analogiczne jak przy błędzie e^{-12}, ale otrzymane zdecydowanie szybciej, bo już po 94 epokach (wykres 4).

Przyjmując jeszcze mniejszy dopuszczalny błąd sieci neuronowej – e^{-4} (wykres 6) otrzymujemy na wyjściu TMAI wygenerowane przez sieć neuronową po

Wykres 3. Porównanie wyników przy zadanym błędzie e^{-5}

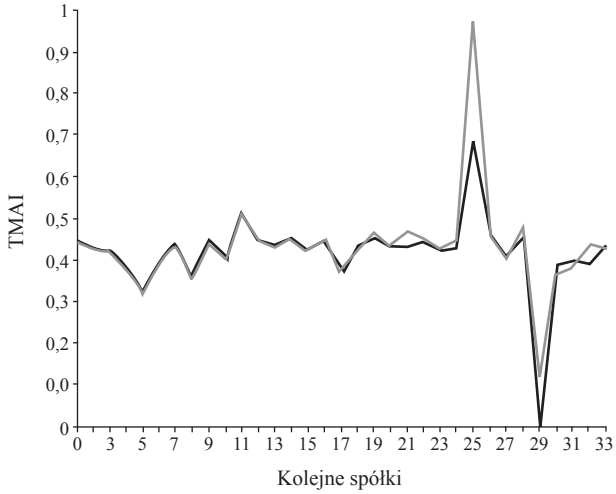

Linia czarna – TMAI, linia szara – sieć neuronowa

Ź r ó d ł o: opracowanie własne.

Wykres 4. Błąd MSE sieci przy zadanym dopuszczalnym błędzie sieci e^{-5}

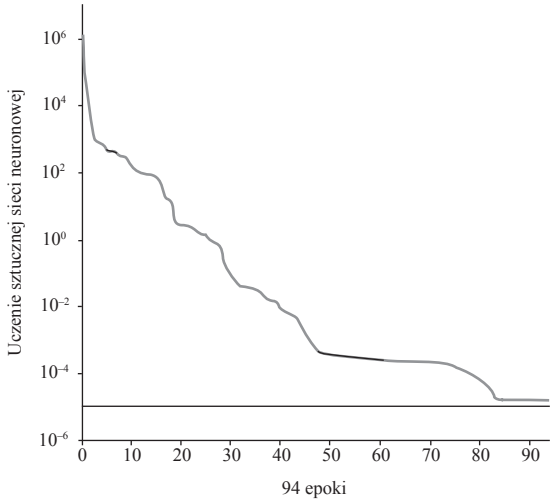

Performance is 1.5616e-005, Goal is 1e-012

Ź r ó d ł o: opracowanie własne.

86 epokach, przy czym widać znaczne różnice pomiędzy TMAI wygenerowanym przez sieć neuronową a TMAI wygenerowanym klasycznym algorytmem (wykres 5), przedstawionym w rozdziale drugim. Można wnioskować, że im większy założymy dopuszczalny błąd sieci, tym potrzebny jest dłuższy czas na wygenerowanie wektora wyjściowego.

Wykres 5. Porównanie wartości TMAI wygenerowanej dwoma metodami, przy dopuszczalnym błędzie sieci e^{-4}

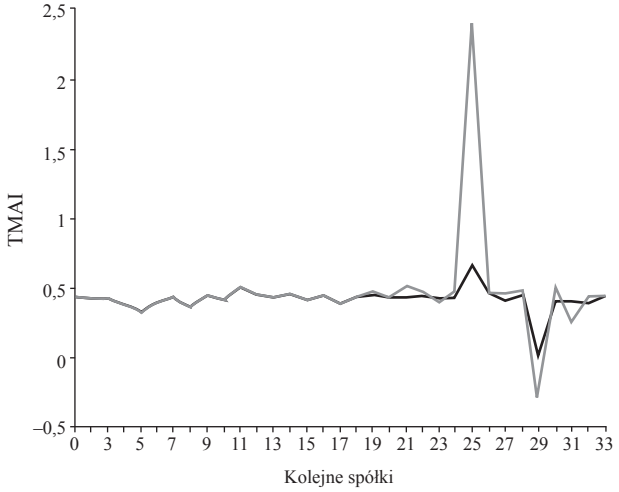

Linia czarna – TMAI, linia szara – sieć neuronowa

Ź r ó d ł o: opracowanie własne.

Wykres 6. Błąd MSE przy dopuszczalnym błędzie sieci e^{-4}

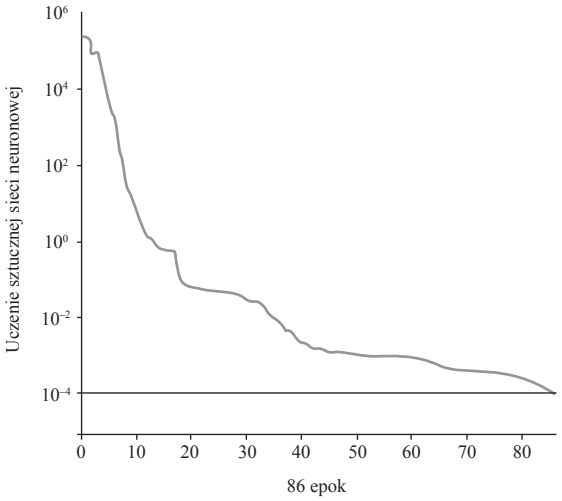

Performance is 9.73247e-005, Goal is 0.0001

Ź r ó d ł o: opracowanie własne.

2.2. Funkcja treningu sieci a generowane wartości TMAI

Działanie funkcji służących do treningu sieci sprowadza się w większości przypadków do wielokrotnego powtarzania sekwencji złożonej z wywołania odpowiedniej funkcji uczenia, modyfikacji współczynników wagowych oraz wywołania funkcji symulacji sieci w celu obliczenia osiąganego przez nią błędu średniokwadratowego. Sekwencja taka nosi nazwę cyklu treningowego (ang. *training epoch*). Argumentami wejściowymi funkcji treningowych są: początkowe wartości współczynników wagowych i progowych, macierze wektorów wejściowych oraz (w przypadku sieci uczonych pod nadzorem) wektorów wejściowych, a także opcjonalny wektor parametrów. Działanie funkcji kończy się w momencie osiągnięcia przez sieć zadanego błędu średniokwadratowego bądź w przypadku przekroczenia zadanej liczby cykli treningowych. Funkcje treningowe zwracają nowe (wyuczone) wartości współczynników wagowych oraz współczynników progowych, a także (opcjonalnie) liczbę przebytych cykli treningowych i osiągnięty błąd średniokwadratowy sieci.

W powyższych rozważaniach jako funkcję trenującą sieć jednokierunkową stosowaliśmy „trainbfg", czyli funkcję realizującą uczenie sieci metodą wstecznej propagacji błędu na podstawie algorytmu Broydena–Flrtchera–Goldfarba–Shano, z wykorzystaniem funkcji „learnlm", otrzymując zadowalające wyniki. Również dobre wyniki otrzymamy stosując inną funkcję, np. funkcję „trainlm" (wykres 7).

Funkcję „trainlm" stosuje się do treningu sieci jednokierunkowej (do 3 warstw) według algorytmu Levenberga–Marquardta. Funkcja ta realizuje uczenie sieci na podstawie optymalizacyjnego algorytmu Levenberga-Marquardta, z wykorzystaniem funkcji „learnlm". Trening sieci zajmuje znacznie mniej czasu niż w przypadku

Wykres 7. TMAI wygenerowane metodą klasyczną i przez sieć z funkcją trenującą „trainlm"

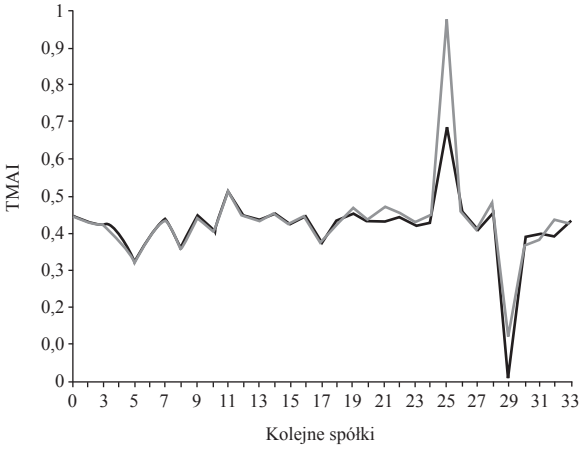

Linia czarna – TMAI, linia szara – sieć neuronowa

Ź r ó d ł o: opracowanie własne.

Wykres 8. Błąd sieci MSE dla funkcji trenującej – „trainlm”

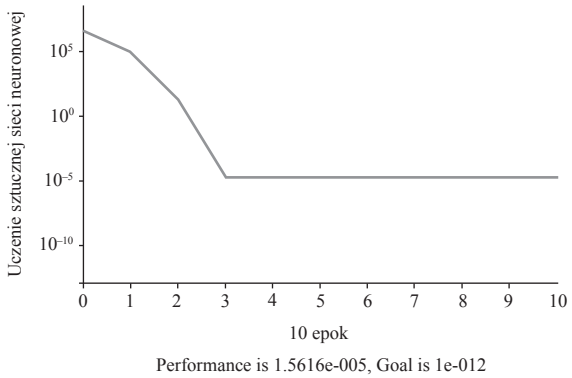

Ź r ó d ł o: opracowanie własne.

klasycznego algorytmu największego spadku, jednak znacznie rosną wymagania co do wykorzystywanej pamięci operacyjnej (większa jest złożoność obliczeniowa zadania).

W przypadku zastosowania algorytmu Levenberga–Marquardta sieć neuronowa bardzo szybko wygenerowała wektor wyjściowy – już po 10 epokach (wykres 8). Stosując algorytm Broydena–Flrtchera–Goldfarba–Shano z funkcją „taringbfg”, sieć neuronowa wygenerowała wynik po 206 epokach (wykres 1). W obu przypadkach zadany i generowany przez sieć błąd był taki sam.

Można wnioskować, że funkcja „trainlm” lepiej nadaje się do rozważanego zagadnienia niż funkcja „taringbfg”, tym bardziej że przy założonym dopuszczalnym błędzie sieci e^{-4} sieć z funkcją trenującą „trainlm” generuje wynik już po 3 epokach (wykres 9), a dopasowanie zbioru uczącego do testowego jest identyczne jak przy zadanym dopuszczalnym błędzie e^{-12}.

Wykres 9. Błąd MSE (funkcja trenująca „trainlm”, zadany dopuszczalny błąd e^{-12})

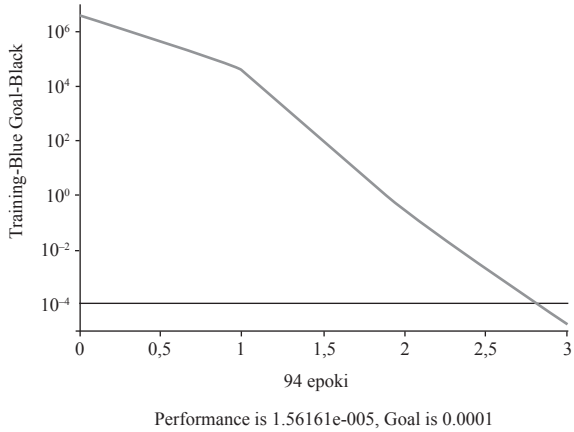

Ź r ó d ł o: opracowanie własne.

Zakończenie

Sztuczne sieci neuronowe dzięki swoim zaletom znajdują zastosowanie w wielu dziedzinach nauki. W stosunkowo niedługim czasie powstało wiele neuronowych modeli, które sprawdziły się w badaniu różnorodnych zjawisk, m.in. w prognozowaniu stanu finansowego przedsiębiorstw, dając nawet lepsze rezultaty niż klasyczne metody ekonometryczne. Oprócz lepszej wydajności modeli zbudowanych na podstawie sieci neuronowych, podejście to jest też bardziej uniwersalne – nie ma potrzeby budowania modelu od początku dla różnych rynków. Mając gotowy model, wystarczy zastosować inne zmienne i szybko poddać sieć ponownemu procesowi trenowania. Posiadając wiedzę na temat działania sztucznych sieci neuronowych, metod uczenia czy też architektury, łatwo można realizować różne modele do rozwiązywania złożonych problemów czy zagadnień. Ponadto narzędzia służce do budowy sztucznych sieci neuronowych pozwalają na generowanie w łatwy i przyjazny użytkownikowi sposób różnego rodzaju podsumowań i analiz ułatwiających zrozumienie problemu i interpretację chociażby wyników końcowych.

Przeprowadzone badanie pokazuje, że sztuczna sieć neuronowa jest skutecznym narzędziem do generowania i prognozowania wartości TMAI, a co za tym idzie do oceny fundamentalnej siły spółek, jednakże jak pokazują poniższe rozważania, „wynik", czyli wektor wyjściowy sieci, zależy od wielu parametrów, np. od zastosowanej funkcji aktywacji, liczby neuronów w poszczególnych warstwach czy funkcji treningu sieci. Oczywiście można wykorzystać inne alternatywne narzędzia opisane w literaturze i dotychczas nieaplikowane do generowania TMAI[2].

Literatura

Bień W., *Zarządzanie finansami przedsiębiorstwa*, wyd. 8, Difin, Warszawa 1998.

Jajuga K., *Inwestycje – instrumenty finansowe, ryzyko finansowe, inżynieria finansowa*, WN PWN, Warszawa 1998.

Łuniewska M., Tarczyński W., *Metody wielowymiarowej analizy porównawczej na rynku kapitałowym*, WN PWN, Warszawa 2006.

Morrison D.F., *Wielowymiarowa analiza statystyczna,* PWN, Warszawa 1990.

Osowski S., *Sieci neuronowe do przetwarzania informacji*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.

[2] Zob. T. Węgrzyn, *Stock selection based on financial ratios on the Warsaw Stock Exchange. Analysis between 2001 and 2010*, w: *European Financial Systems 2013. Proceedings of the 10th International Scientific Conference*, red. O. Deev, V. Ksjurova, J. Krajicek, Masaryk University, Brno 2013, s. 356-361; A. Sroczyńska-Baron, *The choice of portfolio based on the theory of cooperative games*, w: *European Financial Systems...*, s. 305-311.

Sroczyńska-Baron A., *The choice of portfolio based on the theory of cooperative games*, w: *European Financial Systems 2013. Proceedings of the 10th International Scientific Conference,* red. O. Deev, V. Ksjurova, J. Krajicek, Masaryk University, Brno 2013.

Węgrzyn T., *Stock selection based on financial ratios on the Warsaw Stock Exchange. Analysis between 2001 and 2010*, w: *European Financial Systems 2013. Proceedings of the 10th International Scientific Conference*, red. O. Deev, V. Ksjurova, J. Krajicek, Masaryk University, Brno 2013.

The use of taxonomy of network methods in the process of determining the synthetic instrument development investments

Summary. The paper presents a non-classical concept of determining the synthetic instrument development as a taxonomic measure of the attractiveness of the investment. The structure of the synthetic measure of development proposed here uses artificial neural networks. The main objective of this article is to present the possibilities of prediction of synthetic instrument based on artificial neural network with an indication of the function of network training, network learning, etc. error parameters. The structure of classical synthetic instrument development was carried out for 33 joint-stock companies, by adopting the following measures: current ratio, quick ratio, the rate of the overall level of debt, debt to equity ratio, inventory turnover, receivables collection period, payables turnover ratio, profitability ratio of net return on assets (ROA), return on equity (ROE), the P/E, P/BV.

Key words: synthetic indicator, artificial neural networks, portfolio analysis