

Krzysztof Koper, Magdalena Tuora

Uniwersytet Ekonomiczny w Katowicach

Możliwości wykorzystania sztucznych sieci neuronowych w logistyce

Possibilities of using artificial neural networks in logistics

Synopsis. W artykule omówiono możliwości zastosowania narzędzi sztucznej inteligencji w różnych obszarach zarządzania logistycznego, m.in. w procesach magazynowych, dystrybucyjnych oraz sprzedażowych, jako alternatywę do tradycyjnie stosowanych metod. Celem artykułu jest przedstawienie potencjału, który stanowią sztuczne sieci neuronowe, czyli możliwości szybkiego przesyłu danych oraz nauki rozpoznawania analizowanego problemu w warunkach stale zmieniających się parametrów. Istotą wykorzystania modelowania neuronowego w obszarach zarządzania logistycznego (tj. procesów magazynowych oraz dystrybucyjno-sprzedażowych) jest m.in. skrócenie czasu trwania procesów, eliminacja błędów oraz bardziej precyzyjna analiza danych wejściowych i wyjściowych, skutkująca minimalizacją czasu obsługi, kosztów, szumu informacyjnego (efektu Forreстера) oraz zwiększenia satysfakcji konsumenta. Jako przykład przedstawiono system „Just Walk Out” sieci Amazon, który idealnie ilustruje praktyczne wykorzystanie informatyzacji oraz algorytmów związanych z funkcjonowaniem sieci neuronowych.

Słowa kluczowe: sztuczne sieci neuronowe, sztuczna inteligencja, dystrybucja

Abstract. The article presents the possibilities of using artificial neural networks tools in various areas of logistics management, including warehouse, distribution and sales process management, as an alternative to traditional methods. Therefore, the principal purpose of the research is to unveil a capability of artificial neural networks, such as fast data transfer and learning of diagnosing problems under constantly changing conditions. The essence of using neural network modeling in areas of logistics management (i.e. warehouse, distribution and sales process management) is, among other things, shortening process management time, elimination of errors and more effective input and output data analysis, resulting minimized service time, costs and the bullwhip effect (Forrester effect), as well as, increased consumers satisfaction. The example used in the paper is ‘Just Walk Out’ technology created by Amazon. The instantiation perfectly picture the implementation of IT solutions and algorithms connected with functioning of artificial neural networks.

Key words: artificial neural networks, artificial intelligence, distribution

Wstęp

Współcześnie możemy zaobserwować dynamiczny rozwój gospodarczy miast i aglomeracji, który skrupulatnie przyczynia się do wzrostu konsumpcji oraz procesów informatyzacji, jednocześnie narzucając potrzebę efektywniejszego dysponowania procesami logistycznymi. Zwiększająca się potrzeba przetwarzania i analizy danych, jak również wzrost wymagań konsumentów przyczyniają się do konieczności wprowadzania przez przedsiębiorstwa innowacyjnych rozwiązań technologicznych, umożliwiających uzyskanie przewagi konkurencyjnej na rynkach dóbr i usług. Niestety tradycyjne metody przetwarzania i analizy danych (tj. arkusze kalkulacyjne, narzędzia i aplikacje bazodanowe) stają się niewystarczające w warunkach, kiedy konieczna jest ich predykcja, rozpoznawanie i klasyfikacja w warunkach stale ulegających zmianie parametrów. Skutkiem tego jest coraz większe wykorzystanie rozwiązań informatycznych bazujących na sztucznej inteligencji (ang. AI – *artificial intelligence*, polski odpowiednik – SI), czyli „komputerów i programów próbujących naśladować aspekty ludzkiego myślenia” [Gibilisco 1994]. Sztuczna inteligencja wykorzystywana jest coraz powszechniej w niemal każdej dziedzinie gospodarki – superkomputery pomagają przy analizie i przetwarzaniu wielkich zbiorów danych (*big data*), pomagają lekarzom w diagnozowaniu dolegliwości pacjentów (przykład: projekt Watson), stopniowo zaczynają podbijać rynek usługowy, a technologia wkradła się także w ludzkie życie codzienne, czego przykładem są chociażby domy typu Smart House¹. Nie powinno więc nikogo zaskakiwać, iż rozwiązania takie zaczynają być stosowane również w zakresie usprawnień procesów logistycznych. W efekcie następują zmiany wpływające na rozwój logistyki, m.in. w obszarze łańcucha dostaw – zachodzi zmiana z tradycyjnych metod na rozwiązania wirtualne. Logistyka, która jest jedną z gałęzi gospodarki charakteryzującą się wysoką reaktywnością na nowoczesne rozwiązania i technologię, jak i jednym z najwyższych stopni konkurencyjności, wykazuje wzmożone potrzeby na stosowanie najnowocześniejszych rozwiązań i tendencji dostępnych na rynku. Naprzeciw tym potrzebom wychodzi zastosowanie technologii sztucznych sieci neuronowych.

Sztuczne sieci neuronowe, dla których ludzki mózg stanowi pierwowzór, mają zdolność do predykcji, rozpoznawania, klasyfikacji, filtracji i kojarzenia danych wejściowych [Tadeusiewicz 1993]. Z definicji są to zbiory prostych jednostek obliczeniowych przetwarzających dane, komunikujących się ze sobą i pracujących równolegle, które mogą być określone poprzez model sztucznego neuronu, topologię oraz reguły uczenia sieci [Stefanowski 2006].

Geneza i implementacja sieci neuronowych

Niniejszy rozdział poświęcony jest omówieniu sieci neuronowych w kontekście rozważań matematycznych i informatycznych, z uwzględnieniem infrastruktury niezbędnej do funkcjonowania tej technologii. Sztuczne sieci neuronowe stosowane są w różnych dziedzinach, m.in. w ekonomii, teleinformatyce, medycynie, inżynierii materiałowej, a nawet w kryminalistyce. Wszystko to za sprawą swojej unikalnej budowy, opartej na

¹ <https://www.youtube.com/watch?v=vvimBPJ3XGQ>, [dostęp: 21.12.2016 r.].

biologicznej strukturze układów nerwowych, mającej wiele zdolności, tj. „zdolność do uczenia się i uogólniania zdobytej wiedzy, zdolności adaptacji zmiennych warunków, mała wrażliwość na błędy w zbiorze danych, zdolność do efektywnej pracy nawet po częściowym uszkodzeniu sieci, zdolność do równoległego i rozproszonego przetwarzania danych” [Osowski 2000].

Protoplastą dla powstania sztucznych sieci neuronowych jest ludzki mózg, a dokładniej budowa jego warstwy nerwowej, składającej się z komórek nazywanych neuronami. Neuron w ludzkim ciele składa się z jądra otoczonego błoną komórkową wraz z dendrytami, somy, aksonu oraz synapsy, stanowiącej połączenie przewodnikowe. Wpływające dendrytami bodźce poddawane są procesowi kumulacji w błonie komórkowej, a zsumowany sygnał przy pomocy aksonu dostaje się na synapsy. Na skutek zaburzenia różnicy potencjałów następuje przeskok impulsu z synaps na następną komórkę nerwową. Proces ten stał się inspiracją do utworzenia sztucznych sieci neuronowych [Stefanowski 2006]².

Należy przy tym jednak pamiętać, że sieć neuronowa jest jedynie uproszczonym modelem mózgu, wykorzystującym od kilkuset do kilkudziesięciu tysięcy neuronów przetwarzających informacje, gdzie dla porównania szacunkowo ludzki mózg składa się z około dziesięciu miliardów połączeń (przy przeciętnym dystansie od 0,01 mm do 1 m), a jego szybkość przetwarzania informacji wynosi 10^{18} m/s [Tadeusiewicz 1993]. Większość współcześnie budowanych i wykorzystywanych sieci neuronowych ma budowę warstwową, przy czym ze względu na dostępność w trakcie procesu uczenia wyróżnia się warstwy: wejściową, wyjściową oraz warstwy ukryte, o czym mowa będzie w dalszej części artykułu [Tadeusiewicz 1993].

Model struktury sztucznej sieci neuronowej składa się ze zbioru przetworników sygnałów. Z matematycznego punktu widzenia do podstawowych elementów składowych pojedynczego sztucznego neuronu zaliczamy: „ n wejść neuronu wraz z wagami w_i (wektor wag w i wektor sygnałów wejściowych x), jeden sygnał wyjściowy y , pobudzenie e neuronu jako suma ważona sygnałów wejściowych pomniejszona o próg Θ oraz funkcję aktywacji”. Pobudzenie e neuronu wyrażone jest wzorem [Stefanowski 2006]:

$$e = \sum_{i=1}^n w_i x_i - \Theta = w^T x - \Theta$$

Wprowadzając wagę $w_0 = \Theta$ podłączonej do stałego sygnału $x_0 = 1$, otrzymujemy:

$$e = \sum_{i=0}^n w_i x_i = W^T x$$

Z kolei funkcja aktywacji wyrażona jest wzorem:

$$y = f(e).$$

² <http://michalpasterski.pl/2008/11/o-neuronach/>, [dostęp:11.11.2016].

Architektura sztucznych sieci neuronowych zbudowana jest najczęściej z dwóch typów sieci: sieci jednokierunkowych (ang. *feedforwarded*), tj. sieci o jednym kierunku przepływu sygnałów oraz sieci rekurencyjnych (ang. *feedback, bidirectional*), tj. sieci ze sprzężeniem zwrotnym lub sieci uczenia się przez współzawodnictwo [Stefanowski 2006]. Wyróżniany jest szczególnie przypadek sieci jednokierunkowej, tzw. sieci warstwowej, która ze względu na swoją budowę jest współcześnie najczęściej wykorzystywana przy budowie sztucznych sieci neuronowych. Składa się z warstwy wejściowej, warstwy ukrytej oraz warstwy wyjściowej [Stefanowski 2006].

Wyróżniamy trzy typy połączeń między poszczególnymi neuronami wchodzącymi w skład sieci. Pierwszy z nich, nazywany jako „każdy z każdym”, jest typem połączeń, w którym każdy neuron ma połączenie z resztą neuronów, które tworzą sieć. Drugim typem połączenia jest połączenie warstwowe, w którym połączone ze sobą są poszczególne warstwy sieci neuronowej (każda warstwa połączona jest z warstwą następującą po niej, nie ma za to połączenia z każdym poszczególnym neuronem), ostatni zaś typ połączenia zakłada połączenie poszczególnego neuronu tylko z wybraną grupą – najczęściej tą, która jest w jego sąsiedztwie [Stefanowski 2006].


Sieci neuronowe mają również możliwość „uczenia się”. Metody „uczenia się” sieci są proste w realizacji i właśnie to czyni sieci neuronowe atrakcyjnym rozwiązaniem w zakresie przetwarzania i analizy danych. „Uczenie się” sieci należy rozumieć jako wymuszanie na sieci określonego zachowania, sprecyzowanego dla charakterystycznych sygnałów wejściowych. Proces ten polega na utrwalaniu określonych zachowań w bazie doświadczeń sieci i przypomina w swojej strukturze działanie odruchów warunkowych u człowieka. Efekty takiego uczenia mogą być różne dla każdej utworzonej sieci, dlatego konieczne jest weryfikowanie „zdobytej wiedzy” – stosuje się etapy uczenia, testowania i aplikacji. „Uczenie sieci”, jak i jej testowanie są procesami, które można wykonywać wielokrotnie. Sieć uczona jest wykonywania obliczeń poprzez dostrajanie wartości wag w_{ij} , a naukę można zrealizować dwiema metodami: uczeniem nadzorowanym (inna nazwa tej metody to „uczenie z nauczycielem”) oraz poprzez samouczenie sieci³.

Proces uczenia nadzorowanego bazuje na zadaniu danych wejściowych, jakie sieć ma przyjąć, oraz sugerowanej odpowiedzi, jaką powinna ona uzyskać. Zwrócony przez sieć wynik jest zestawiany z wynikiem, jaki powinna ona uzyskać i na jej podstawie obliczana jest odległość, czyli rozbieżność pomiędzy dwoma wynikami. Odległość jest w tym wypadku miarą błędu, która jest następnie używana do poprawy parametrów sieci. Zestaw danych, zarówno wejściowych, jak i wyjściowych, jest zaś nazywany zbiorem uczącym⁴.

Wagi sieci w tej metodzie są dobierane w taki sposób, aby zapewniały one to, że wyjścia z sieci będą z każdym kolejnym przebiegiem (iteracją) zbliżać się do pożądaných wyników. Najpopularniejszą metodą „uczenia sieci” jest tak zwana reguła Delta (stosowana dla sieci jednowarstwowych). Reguła ta, opracowana przez Bernarda Widrowa oraz Marciana Hoffa, zakłada, że dla każdego wektora wejściowego sieć odpowiada sygnałem, a przy wielokrotnym powtarzaniu tego procesu możliwe jest uzyskanie sygnału, który pozwala na obliczenie błędu (rys. 1). Na podstawie sygnału błędu oraz wektora

³ http://www.neurosoft.edu.pl/media/pdf/tkwater/sztuczna_inteligencja/2_alg_ucz_ssn.pdf [dostęp: 06.04.2017].

⁴ Ibidem.



Rysunek 1. Schemat uczenia sieci neuronowych poprzez nadzór

Figure 1. Scheme of ANNs learning process under the custody

Źródło: http://www.neurosoft.edu.pl/media/pdf/tkwater/sztuczna_inteligencja/2_alg_ucz_ssn.pdf [dostęp: 06.04.2017].

wejściowego możliwe jest skorygowanie wektora wag w taki sposób, aby zwracał on wyniki bliższe oczekiwanym. Proces ten jest powtarzany do momentu, w którym uzyskany zostanie oczekiwany wynik, bądź jak najbliższy jemu rezultat. Warto dodać, że istnieją także inne sieci neuronowe nadzorowanego nauczania. Jest to np. nauczanie z krytykiem, algorytm zmiennej metryki, algorytm Levenberga-Marquartda czy metoda momentum⁵.

Drugą metodą nauczania sieci neuronowych jest samouczenie. Metoda ta jest analogiczna do metody uczenia nadzorowanego – w tym wypadku do sieci neuronowej podawane są tylko dane wejściowe, brakuje zaś danych o oczekiwanych wynikach. W metodzie tej prawidłowo zaprojektowana sieć neuronowa ma zdolność do analizy sygnałów i zwracanych wartości, by na ich podstawie opracować odpowiedni algorytm działania. Algorytm ten najczęściej opiera swoje działanie na wykrywaniu powtarzających się klas, a sieć w sposób spontaniczny uczy się rozpoznawać te klasy i reagować odpowiednimi metodami. Właśnie ten typ uczenia się upodabnia sieć neuronową do działania ludzkiego mózgu, który również ma zdolność do samodoskonalenia i samokształcenia się. Metoda ta jest także bardziej atrakcyjna ze względów finansowych – wystarczy wprowadzić do sieci dane wejściowe, a sieć sama przeprowadzi proces nauki – nie jest konieczna obecność żadnej osoby nadzorującej proces „uczenia się sieci”⁶.

Jeśli chodzi o realizację zagadnienia samouczenia się, na początku każdy neuron w sieci otrzymuje losową wagę i do tak zainicjowanej sieci zaczynają napływać różne zmienne. Na podstawie tych zmiennych (sygnałów) oraz swoich wag neurony określają sygnały wyjściowe, które mogą być dodatnie lub też ujemne. Na podstawie tych sygnałów neurony w dalszej kolejności korygują swoje wagi – w jej trakcie zachowanie poszczególnych neuronów zależy od tego, jaka była początkowa wartość jego sygnału – jeśli wartość była pozytywna, to neuron przybliży się do preferowanego obiektu, jeśli zaś ujemna – oddala się od niego. W następnej iteracji uzyskane wagi stają się starymi,

⁵ Ibidem.

⁶ http://www.neurosoft.edu.pl/media/pdf/tkwater/sztuczna_inteligencja/2_alg_ucz_ssn.pdf [dostęp: 06.04.2017].

a cykl rozpoczyna się od początku. Iteracja trwa aż do momentu, w którym powstanie skupisko neuronów wyspecjalizowanych w rozpoznawaniu typowego obiektu należącego do danej grupy. W ten sposób sieć zupełnie sama się uczy rozpoznawać poszczególne problemy i skutecznie na nie reagować. Matematycznym opisem tej struktury jest model Hebba. Innym podejściem konstruowania sieci neuronowych bazujących na algorytmach samouczenia się jest uczenie konkurencyjne (WTA – *Winner Takes All* oraz WTM – *Winner Takes Most*). Od metody Hebba różni się one tym, że w metodzie tej tylko jeden neuron może pozostać aktywny⁷.

Przykłady zastosowania sieci neuronowych


Do przedsiębiorstw posługujących się algorytmami sztucznych sieci neuronowych należy Amazon. Poza uczeniem maszynowym, stosowanym rozwiązaniem jest również głębokie uczenie (ang. *deep learning*), które obejmuje nakładanie na siebie kilku algorytmów w celu lepszej analizy danych. Takie podejście pozwala na wielowarstwową analizę oraz rozpoznawanie danych, przyczyniając się do tworzenia związków między elementami w sposób nieograniczony i elastyczny, ukazujący bardziej zrozumiałe i wytłumaczalne przebiegi procesów. Amazon używa algorytmów głębokiego uczenia m.in. w celu rozpoznawania głosu, segmentacji i klasyfikacji obrazów oraz plików wideo, rejestracji i rozumienia języka naturalnego oraz do wysyłania rekomendacji produktów do klientów. Wszystkie te elementy łączy technologia „Just Walk Out” stworzona przez Amazon, która weszła w życie na początku 2017 roku⁸.

Technologia „Just Walk Out” bazuje na algorytmach rozpoznawania obrazu, technologii przetwarzania sygnałów z detektorów oraz głębokim uczeniu, skoordynowanych z infrastrukturą techniczną, obejmując swoim zasięgiem m.in. sieć kamer identyfikujących klientów i śledzących ich w trakcie całego procesu zakupów. Użytkownicy są identyfikowani na podstawie karty ID powiązanej z kontem Amazon oraz aplikacją Amazon GO uprawniającą do korzystania z zakupów w trybie stacjonarnym. Konsumenci logują się przy wejściu do sklepu, następnie śledzeni są za pomocą kamer. System wykrywa lokalizację na podstawie kilku danych, m.in. triangulacji oraz danych pochodzących z mikrofonów nagrywających dźwięki wydawane przez użytkownika, z kolei wszelkie artykuły lokalizowane są za pomocą sensorów znajdujących się na półkach. Sensory te porównują wagę odkładanego produktu z wagą oryginalną, jaką ma ten produkt, przy jednoczesnym nadzorze ilościowym wykonywanym przez kamery statyczne. Niewykluczone jest, iż systemowi zostanie przypisana jeszcze jedna funkcja – funkcja rozpoznawania użytkowników na podstawie twarzy i koloru skóry. Poza wymienionymi funkcjami system „Just Walk Out” analizuje klienta pod kątem preferencji wyboru produktów, które mijają oraz czytanych przez niego etykiet – podobnie jak dzieje się to, gdy robimy zakupy online. Na podstawie tych danych wyliczany jest poziom zapasów. Mechanizm funkcjonowania technologii „Just Walk Out” zaprezentowano na rysunku 2.

Ponadto Amazon wykorzystuje w swoich obecnych przedsięwzięciach system uczenia MXNet, który „jest w pełni funkcjonalnym, elastycznym programowalnym i bardzo skalowalnym, zaawansowanym systemem nauczania, wspomagającym najnowocześnie-

⁷ Ibidem.

⁸ <https://www.amazon.com/b?node=16008589011> [dostęp: 13.04.2017].



Rysunek 2. Mechanizm przenoszenia produktów z obszarów przeładunkowych

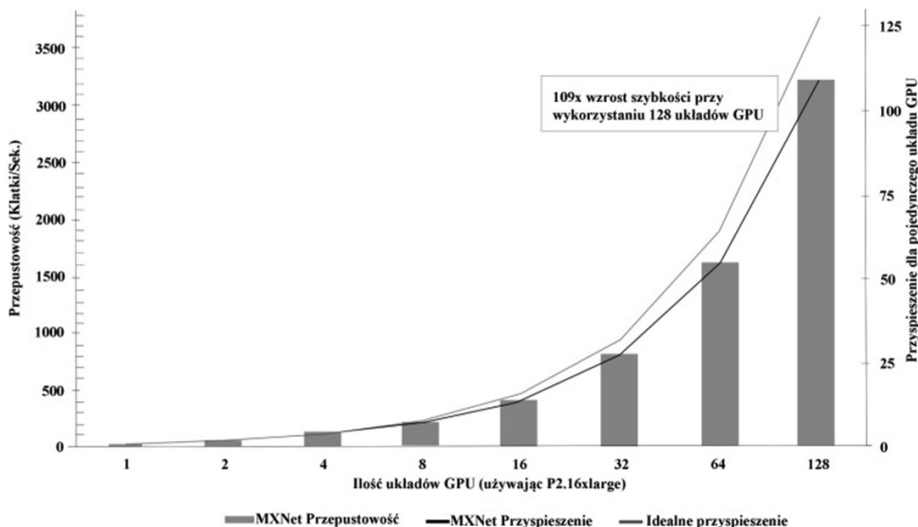
Figure 2. Transitioning items from a materials handling facility

Źródło: <https://www.google.com/patents/US20150012396> [dostęp: 06.04.2017].

sze funkcje w modelach uczenia się, w tym w sieciach neuronowych (CNN) i długich krótkoterminowych sieciach pamięci (LSTM)⁹. Efektywne skalowanie wpływa na wzrost szybkości szkolenia nowych modeli, jak i pozwala na podniesienie klasy modelu w trakcie takiego samego czasu uczenia [Vogels 2016]. Jak się okazało, przepustowość MXNet wzrosła prawie tak samo, jak liczba układów graficznych używanych w trakcie uczenia (z efektywnością skalowania 85%) [Vogels 2016]. Oznacza to, iż uczenie się sztucznych sieci neuronowych zależne jest od metody, konfiguracji sprzętowej oraz opty-

⁹ <http://www.allthingsdistributed.com/2016/11/mxnet-default-framework-deep-learning-aws.html> [dostęp: 07.04.2017].

malizacji algorytmu. Ponadto możliwe jest zwiększenie szybkości poprzez zwiększenie wydajności sprzętowej jednostki, na której zaimplementowana została sieć. Sytuacja ta została ukazana na rysunku 3 [Vogels 2016].



Rysunek 3. MXNet: Skalarnie ramy głębokiego uczenia

Figure 3. MXNet: Scalable Deep Learning Network

Źródło: <https://aws.amazon.com/amazon-ai/> [dostęp: 07.04.2017].

Takie rozwiązanie może przyczynić się także do minimalizacji efektu byczego bicza (ang. *the bullwhip effect*). Efekt ten powstaje w sytuacji, kiedy każde z ogniw łańcucha dostaw stara się zgromadzić ilość produktu większą od przewidywanej sprzedaży na wypadek wahań popytu [Szymonik 2014/2015]. Prowadzi to do sytuacji, w której każde następne przedsiębiorstwo gromadzi coraz większą ilość zapasu (powiększoną wedle informacji pochodzącej od poprzedniego ogniwa), co skutkuje zwiększeniem kosztów magazynowania, a co za tym idzie zamrożeniem większej ilości kapitału przez przedsiębiorstwo (efekt ten może też mieć charakter odwrotny – zgromadzona zostanie zbyt mała ilość zapasu, przez co przedsiębiorca poniesie koszt niewykorzystanej szansy). Zjawisko to, zwane inaczej efektem Forrestera, wynika bezpośrednio ze zniekształconego przepływu informacji w łańcuchu dostaw, tj. przepływu nieefektywnych danych na temat poziomu zapasu oraz czasu realizacji procesów. Jako że czynniki powstawania byczego bicza wynikają najczęściej z dwóch powodów: nieefektywnej i nieskoordynowanej działalności operacyjnej podmiotów (szum informacyjny) oraz zakłóceń w procesach decyzyjnych, konieczne jest zastosowanie algorytmów, które swoim zakresem obejmują te zmienne [Domański 2014].

Warto rozpatrzyć zatem sprawę w sposób praktyczny: w celu obliczeń założono tygodniowy koszt utrzymania sztuki zapasu na poziomie dwóch złotych tygodniowo, a zapas bezpieczeństwa ustanowiony przez każdy z podmiotów wchodzących w skład łańcucha dystrybucyjnego na poziomie 15%. Badania naukowców wykazały, iż sieci neuronowe pozwalają na uzyskanie wyników mniejszych o kilka procent w porównaniu z innymi tech-

nikami przewidywania i prognozowania [Kuźdowicz i Relich 2006]. Na tej podstawie założono, iż na skutek dokładniejszej metody prognozowania możliwe jest zmniejszenie poziomu zapasu bezpieczeństwa do 12% (choć należy pamiętać, że w przypadku ulepszenia algorytmów i wzrostu wydajności sprzętowej wartość ta może ulec znacznej poprawie)¹⁰.

W tabeli 1 ukazane zostały potencjalne korzyści wynikające z zastosowania technologii Sztucznych Sieci Neuronowych dla niewielkiego łańcucha dystrybucyjnego.

Tabela 1. Możliwe korzyści z zastosowania SSN w celach prognozowania zapasu na niewielkiego łańcucha dystrybucyjnego

Table 1. Possible benefits of applying ANNs for forecasting stocks on a small distribution chain

Podmiot	Tradycyjne metody			Sztuczne Sieci Neuronowe			
	Prognoza [szt.]	Z zapasem (+ 15%)	Koszt [zł]	Prognoza	Z zapasem (+ 12%)	Koszt [zł]	Różnica [zł]
Detalista A	1000	1150	2300	1000	1120	2240	60
Detalista B	1500	1725	3450	1500	1680	3360	90
Hurtownik	2875	3306,25	6612,5	2800	3136	6272	340,5

Źródło: opracowanie własne.

Potencjalna redukcja kosztów wynosi 5% dla ostatniego ogniwa łańcucha, co może stanowić sporą różnicę. W celach kontrastu wykonano podobne obliczenia dla łańcucha dystrybucyjnego dużej wielkości. Wyniki przedstawiono w tabeli 2.

Tabela 2. Potencjalne korzyści z zastosowania SSN w celach prognozowania zapasu dla łańcucha dystrybucyjnego dużej wielkości

Table 2. Possible benefits of applying ANNs for forecasting stocks on a large distribution chain

Podmiot	Tradycyjne metody			Sztuczne sieci neuronowe			
	Prognoza [szt]	Z zapasem (+15%)	Koszt [zł]	Prognoza	Z zapasem (+12%)	Koszt [zł]	Różnica [zł]
Detalista A1	80 000	92 000	184 000	80 000	89 600	179 200	4 800
Detalista A2	110 000	126 500	253 000	110 000	123 200	246 400	6 600
Detalista A3	240 000	276 000	552 000	240 000	268 800	537 600	14 400
Detalista A4	90 000	103 500	207 000	90 000	100 800	201 600	5 400
Detalista B1	65 000	74 750	149 500	65 000	72 800	145 600	3 900
Detalista B2	130 000	149 500	299 000	130 000	145 600	291 200	7 800
Detalista B3	140 000	161 000	322 000	140 000	156 800	313 600	8 400
Detalista B4	95 000	109 250	218 500	95 000	106 400	212 800	5 700
Detalista C1	80 000	92 000	184 000	80 000	89 600	179 200	4 800
Detalista C2	140 000	161 000	322 000	140 000	156 800	313 600	8 400
Detalista C3	210 000	241 500	483 000	210 000	235 200	470 400	12 600
Detalista C4	65 000	74 750	149 500	65 000	72 800	145 600	3 900
Hurtownik A	598 000	687 700	1 375 400	582 400	652 288	1 304 576	70 824
Hurtownik B	494 500	568 675	1 137 350	481 600	539 392	1 078 784	58 566
Hurtownik C	569 250	654 637,5	1 309 275	554 400	620 928	1 241 856	67 419
Producent	1 911 012,5	2 197 664,38	4 395 328,75	1 812 608,0	2 030 120,96	4 060 241,92	335 086,83

Źródło: opracowanie własne.

¹⁰ Założenia opracowane samodzielnie na podstawie: http://www.cs.put.poznan.pl/rwalkowiak/pliki/logistyka/zadania_zaliczeniowe.pdf [dostęp 11.04.2017].

W tym wypadku redukcja kosztów może wynieść nawet 8% w skali tygodnia, co może przynieść niewyobrażalne korzyści dla przedsiębiorstwa w skali roku. Na podstawie obydwu rozpatrywanych przypadków można sformułować tezę, iż oszczędność wynikająca z dokładniejszej prognozy będzie tym większa dla ostatniego ogniwa, im większa liczba przedsiębiorstw wchodzących w skład łańcucha dystrybucyjnego.

Efekty stosowania sieci neuronowych

Przepływ informacji w łańcuchu dostaw stanowi kluczową rolę dla efektywnej realizacji procesów w nim zachodzących. Wpływa m.in. na częstotliwość dostaw oraz czas realizacji procesów. Wszelkie czynniki zakłócające jego przebieg mogą przyczynić się do nadwyżek lub deficytu poziomu zapasów, prowadząc do marnotrawstwa siły roboczej, czasu oraz zasobów. Wykorzystanie modelu sztucznych sieci neuronowych w procesach decyzyjnych odnoszących się m.in. do kontroli stanu zapasów przynosi wymierne korzyści. Jak wykazano, uczenie się sztucznych sieci neuronowych, w zależności od metody, konfiguracji sprzętowej oraz optymalizacji algorytmu, może zostać przyspieszone nawet o kilkanaście procent. Oczywiście należy również uwzględnić inne zalety stosowania tej metody, tj. mniejsze wartości błędu prognozowania w stosunku do metod tradycyjnych, trafniejsze zestawienia produktów proponowane klientom, łagodzenie efektu Forreстера poprzez usprawnienie przepływu bardziej precyzyjnych informacji. Korzystną cechą tego rozwiązania technologicznego jest również to, iż „sieci neuronowe mogą być stosowane z dużym prawdopodobieństwem odniesienia sukcesu wszędzie tam, gdzie pojawią się problemy związane z tworzeniem modeli matematycznych pozwalających odwzorować złożone zależności między pewnymi sygnałami wejściowymi a sygnałami wyjściowymi” [Tadeusiewicz 1998], gdzie niemożliwe jest zastosowanie prostego, liniowego algorytmu działania. Wszelkie dane wejściowe, również te niepełne lub uszkodzone, mogą być weryfikowane przez sieć na podstawie skojarzeń z innymi elementami systemu, gdyż model ten nie funkcjonuje liniowo. Jednakże należy pamiętać, iż wykorzystanie sieci neuronowych wiąże się nie tylko z korzyściami. Istnieje wiele komplikacji związanych z ich implementacją, tj. potrzeba odpowiedniego przygotowania danych, trudności związane z doбором odpowiednich struktur i parametrów algorytmów uczenia się sieci, spore nakłady czasowe związane z opracowaniem modelu oraz ograniczona zdolność bezpośredniej interpretacji jego współczynników [Kožuchowicz i Relich 2006]. Dodatkowo zdolność sieci do generalizacji wiedzy na nowe przypadki może okazać się niewystarczająca do analizy danych, gdyż proces uczenia się ogranicza się jedynie do minimalizowania oczekiwanego błędu sieci dla zbioru uczącego, tym samym spłaszczając powierzchnię rzeczywistego błędu [Bishop 1995]. Równocześnie, istnieje możliwość wystąpienia zjawiska przeuczenia się sieci, tj. nadmiernego dopasowania się jej do punktów uczących, któremu towarzyszy błędne działanie sieci dla danych nieprezentowanych w trakcie uczenia, występujące w przypadku zbyt długiego trwania procesu uczenia lub gdy zastosowana sieć jest nadmiernie złożona w porównaniu ze złożonością problemu lub liczbą dostępnych danych uczących¹¹.

¹¹ http://www.statsoft.pl/textbook/glosfra_stat.html?http%3A%2F%2Fwww.statsoft.pl%2Ftextbook%2Fglosp.html%23Overlearning [dostęp 07.04.2017].

Konsekwencją stosowania SSN może okazać się w przyszłości redukcja siły roboczej. Z punktu widzenia przedsiębiorstwa jest to korzystne, gdyż minimalizuje koszty utrzymania pracownika, jednakże z perspektywy rynkowej może przyczynić się do wzrostu bezrobocia.

Wnioski

1. Wykorzystanie sztucznych sieci neuronowych sprawdza się w wielu obszarach logistyki, ze względu na swoje unikalne zdolności do „uczenia się” jest w stanie ulepszać procesy decyzyjne i minimalizować marnotrawstwo zasobów.
2. Sztuczne sieci neuronowe mogą wyprzeć pracę ludzką w niektórych obszarach działalności przedsiębiorstwa, np. przypadek Amazona, gdzie wyeliminowano zasoby ludzkie analizujące związki pomiędzy produktami wyszukiwanymi/kupowanymi przez użytkowników w celu ich proponowania, gdyż algorytmy były w stanie w lepszy sposób analizować związki oraz wysyłać propozycje zwrotne.
3. Wykazano, iż wykorzystanie sztucznych sieci neuronowych może się przyczynić do potencjalnej redukcji kosztów dla ostatniego ogniwa łańcucha dystrybucyjnego na poziomie nawet 8%.
4. Sztuczne sieci neuronowe mogą stać się przyszłym standardem logistyki, gdyż wychodzą poza dotychczas stosowane wzorce oraz uczenie maszynowe, są odpowiedzią na rozwój gospodarczy oraz wzrost zapotrzebowania na dobra konsumpcyjne przy jednoczesnym poszanowaniu czynników ekologicznych.
5. Technologia sztucznych sieci neuronowych nie zagraża całkowitemu wyparciu siły roboczej, gdyż nie jest jeszcze na tyle zaawansowana, sprecyzowana i rozpowszechniona, by zastąpić swój pierwowzór. Ponadto, ludzki mózg, w odróżnieniu od modeli matematycznych i informatycznych, ma również zdolność myślenia abstrakcyjnego

Literatura

- Bishop C., 1995: *Neural Networks for Pattern Recognition*, Oxford University Press.
- Domański R., 2014: Zjawisko Forrestera w sieciach dystrybucji – ciekawostka historyczna, czy wciąż aktualny problem?, [źródło elektroniczne] <http://www.blog.wsl.com.pl/naukowy-punkt-widzenia/items/zjawisko-forrestera-w-sieciach-dystrybucji-ciekawostka-historyczna-czy-wciaz-aktualny-problem> [dostęp: 28.04.2017].
- Gibilisco S., (red.), 1994: *The McGraw-Hill Illustrated Encyclopedia of Robotics & Artificial Intelligence*
- Kuźdowicz P., Relich M., 2006: Zastosowanie sztucznych sieci neuronowych i analizy dyskryminacyjnej do ustalenia polityki cenowej w średnim przedsiębiorstwie, [źródło elektroniczne] http://mit.weii.tu.koszalin.pl/MIT1/Modele%20inzynierii%20teleinformatyki%201_10%20Relich%20Kuzdowicz.pdf [dostęp: 11.04.2017].
- Osowski S., 2000: *Sieci neuronowe do przetwarzania informacji*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa
- Stefanowski J., 2006: Sztuczne sieci neuronowe, [źródło elektroniczne] <http://www.cs.put.poznan.pl/jstefanowski/aed/TPDANN.pdf> [dostęp: 04.04.2017].

- Szymonik A., 2017/2018: Efekt byczego bicza, [źródło elektroniczne] <http://www.gen-prof.pl/zzild12.pdf> [dostęp: 07.04.2017].
- Tadeusiewicz R., 1993: Sieci neuronowe, Akademicka Oficyna Wydawnicza, Warszawa.
- Tadeusiewicz R., 1998: Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami, Akademicka Oficyna Wydawnicza PLJ, Warszawa.
- Vogels W., 2016: MXNet Deep Learning Framework of Choice at AWS, [źródło elektroniczne] <http://www.allthingsdistributed.com/2016/11/mxnet-default-framework-deep-learning-aws.html> [dostęp 07.04.2017]

Adres do korespondencji:

Krzysztof Koper
Uniwersytet Ekonomiczny w Katowicach
Wydział Ekonomii
1 Maja 50, 40-287 Katowice
e-mail: krzysztofkoper@outlook.com

Magdalena Tuora
magdalenuora@gmail.com