

Jarosław Stasiłowicz*

**WYKORZYSTANIE SIECI NEURONOWYCH DLA SZACOWANIA
CZASU TRWANIA ZADAŃ
WE WDROŻENIACH SYSTEMÓW INFORMATYCZNYCH**

Wstęp

Wdrożenia systemów informatycznych w organizacjach gospodarczych są przedsięwzięciami, które wiążą się z realizacją złożonych zadań projektowych¹. Oszacowanie czasu trwania zadań projektowych zależy od wielu czynników, przy czym istotną rolę odgrywają tzw. miękkie aspekty odnoszące się m. in. do ludzi, kultury organizacji, wsparcia dla procesów współpracy i komunikacji.

Zadania projektowe realizowane w organizacjach charakteryzują się dużą powtarzalnością, która sprawia, że czynniki związane z dostawcą systemów są dobrze znane i nie stanowią większego problemu w przeciwieństwie do mniej znanych czynników związanych z poszczególnymi firmami organizacji, tj. odbiorcami (użytkownikami) systemów. Prawidłowa (trafna) ich diagnoza i obiektywna ocena ich wpływu na przebieg prac jest kluczowym problemem w procesie szacowania dokładnych, czyli najbardziej zbliżonych do rzeczywistych, czasów trwania zadań.

Proces szacowania dokładnych czasów realizacji zadań wdrożeniowych nabiera szczególnego znaczenia w dużych organizacjach, ponieważ niedokładna estymacja czasu ich trwania w jednej firmie może opóźnić a nawet uniemożliwić wykonanie zaplanowanych prac wdrożeni-

* Autor przygotowuje rozprawę doktorską w Katedrze Informatyki Ekonomicznej pod kierunkiem prof. dra hab. Witolda Abramowicza.

¹ Zadanie projektowe to działanie, którego wynikiem jest osiągnięcie konkretnego celu. Charakteryzuje się m. in. zapotrzebowaniem na zasoby, uwarunkowaniami, tj. powiązaniem z innymi zadaniami, terminem wykonania i czasem realizacji. Przy czym czas realizacji zadania ma szczególne znaczenie, od dokładności jego oszacowania zależy stopień wykorzystania zasobów i możliwość realizacji zadań powiązanych, może mieć decydujący wpływ na osiągnięcie celu. Zadania projektowe składają się na proces. Każda instancja definicji procesu może składać się z innych zadań.

wych w pozostałych firmach organizacji, co z kolei może mieć znaczący wpływ na efektywność przedsięwzięcia wdrożeniowego, może nawet decydować o jego powodzeniu lub fiasku.

Celem opracowania, składającego się z trzech części, jest przedstawienie metody pozwalającej na obiektywne i dokładne szacowanie czasu trwania zadań w całym procesie wdrożeniowym.

W pierwszej części został przedstawiony przegląd najczęściej stosowanych metod szacowania czasu trwania zadań projektowych. W drugiej części zaprezentowano metodykę sztucznych sieci neuronowych. W ostatniej części przedstawiono metodę wykorzystania sztucznych sieci neuronowych w procesie estymacji czasu trwania zadań posługując się przykładem wdrożeń systemów informatycznych w sieci dilerskiej Audi i VW w Polsce.

1. Metody szacowania czasów realizacji zadań

1.1. Heurystyczne

Metody heurystyczne¹ są stosowane między innymi w procesie podejmowania decyzji oraz w prognozowaniu. Są metodami wykorzystującymi opinie ekspertów², określa się je również jako intuicyjne, bo opierają się na wyobraźni i zdrowym rozsądku³.

Opinie ekspertów zwykle są kreowane w oparciu o informacje o planowanym zadaniu, dostępności wymaganych zasobów i narzędzi, warunkach, w jakich zadanie będzie realizowane, kompetencje i ograniczenia wykonawców zadania. Istotne znaczenie odgrywają również wiedza niejawną, ukryta w podświadomości eksperta i archiwa projektów.

Niewątpliwą zaletą metod heurystycznych jest szeroki zakres ich zastosowania i duża przydatność, sprawdzają się szczególnie tam, gdzie nie jest możliwe opracowanie skutecznych algorytmów rozwiązania problemu. W literaturze przedmiotu za główne wady uważane są: zawodność, podatność na wpływ czynników niezależnych od osób rozwiązujących problem i subiektywność rozwiązań. Istotny jest również fakt, że wykonawcy zadania zwykle są ekspertami uczestniczącymi w procesie

¹ Słowo „heurystyczne” pochodzi od greckiego słowa „*heurisko*” – znajduję, odkrywam.

² Za eksperta w literaturze przedmiotu przeważnie uważa się osobę, która została zaproszona do udziału w procesie szacowania ze względu na swoje wiedzę, doświadczenie, intuicję i osobowość.

³ M. Cieślak, *Prognozowanie Gospodarcze. Metody i zastosowania*, Wydawnictwo Naukowe PWN, Warszawa 2005, s. 201-203.

szacowania czasu trwania zadania. Ich rutyna i nawyki mogą mieć negatywny wpływ na wartość szacowanego czasu. Nie bez znaczenia jest również kultura firmy realizującej zadania, np. złe praktyki z przeszłości mogą przyczynić się do tego, że osoby uczestniczące w procesie szacowania, chcąc zabezpieczyć swoje interesy, będą sztucznie zawyżać wartość szacowanego czasu.

1.2. PERT i CPM

Podstawą metody PERT (ang. *Program Evaluation Review Technique*) i CPM (ang. *Critical Path Method*) jest zbiór równań matematycznych znanych jako równania Rungego-Kutty. Opracowuje się najlepsze i najgorsze scenariusze, którym przypisuje się wagę zależną do najbardziej prawdopodobnego zbioru zdarzeń⁴. Ustala się czasy trwania dla każdego działania, wykorzystując trzy różne estymacje w formule obliczeniowej⁵:

- O: najbardziej optymistyczny szacunek,
- N: najbardziej prawdopodobny szacunek,
- P: najbardziej pesymistyczny szacunek.

Wartość oczekiwana czasu trwania (T_o) obliczana jest wg następującego wzoru:

$$T_o = (O + 4N + P) / 6 \quad (1.1)$$

PERT/CPM stosuje się przeważnie tam, gdzie:

- brak jest dostatecznych informacji niezbędnych do precyzyjnego oszacowania czasu, jaki zająć może dane zadanie,
- dane na temat historycznych działań są ograniczone,
- wykonawcy nie podejmują się oceny planowanego czasu trwania działań, których nigdy nie wykonywali.

PERT/CPM uwzględnia dużą ilość czynników przy ustalaniu czasów trwania poszczególnych działań, przez co uzyskane dzięki tej metodzie wyniki są realistyczne⁶. Istnieje przeświadczenie, że zgromadzenie niezbędnych danych oraz obliczenia wymagają wielkiego wysiłku i dużej

⁴ C. L. Pritchard, *Zarządzanie ryzykiem w projektach. Teoria i praktyka*, WIG-PRESS Wydawnictwo Finansowe, Warszawa 2001, s. 187-194.

⁵ P. Dittmann, *Prognozowanie w przedsiębiorstwie. Metody i ich zastosowanie*, Oficyna ekonomiczna, Kraków 2004, s. 178. Institute for International Research, Certyfikowany IT Project Manager, 2005.

⁶ C. L. Pritchard, *Zarządzanie ryzykiem...*, op. cit., s. 193.

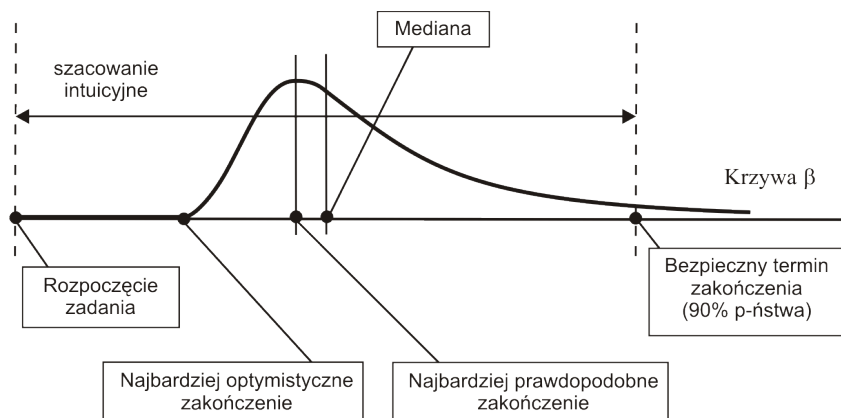
go nakładu czasu, jest to główna przyczyna wykorzystania tej metody w ograniczonym zakresie.

1.3. CCPM

Metoda *Critical Chain Project Management* wywodzi się z prac Eliyahu M. Goldratta i teorii zarządzania ograniczeniami TOC, ang. *Theory of Constraints*. Koncentruje się na dwóch typach ograniczeń, ograniczeniach przepustowości i ograniczeniach w postaci zachowań ludzi. Metoda oparta jest na wymienionych poniżej założeniach⁷:

- szacowanie czasu trwania działań jest zwykle bardzo konserwatywne, tzn. „bezpieczne”, zawierające nadmiarowy margines bezpieczeństwa, (schemat 1),

Schemat 1. Estymacja zadania a prawdopodobieństwo czasu zakończenia wg Krzywej gęstości prawdopodobieństwa β



Źródło: M. Hałas, *Jak Adam Smith opóźni Twój projekt? Czyli sens Łańcucha Krytycznego*, ODiTK 2004.

- praca zajmuje tyle czasu, ile na nią się przeznaczony – Prawo Parkinsona i ludzie często pracują zgodnie z Syndromem Studenta – zawsze mają jeszcze czas do rozpoczęcia zadania,
- reguła trzyminutowego jajka – nie jest dobrze kończyć zadanie przed upływem przeznaczonego na nie czasu. Pracownik wie, że wcześniejsze deklarowanie zakończenia zadania nie

⁷ J. Stawicki, K. Abramowski, *Krytyczna kwestia zachowań*, CXO 10/2003.

jest dla niego korzystne. Dlaczego? Następnym razem, gdy będzie musiał wykonać podobne zadanie, będzie musiał je wykonać w krótszym czasie,

- praca realizowana w trybie wielozadaniowym powoduje wydłużenie wszystkich realizowanych zadań. Powszechnie stosowaną praktyką jest praca nad wieloma zadaniami jednocześnie. Polega ona na tym, że wykonawca wielokrotnie przerywa wykonanie zadania, aby po pewnym czasie wrócić do niego. Każdy powrót związany jest z konsumpcją dodatkowego czasu, który jest poświęcony na przypomnienie wcześniej już wykonanych czynności. Ma to negatywny wpływ na długość realizacji zadania, a w przypadku niektórych prac, np. programisty, może zwielokrotnić czas rzeczywisty niezbędny na wykonanie zadania.

CCPM proponuje zmianę podejścia do zachowań pracowników, stylu i sposobu pracy, zaleca odejście od zasady „push”, tj. wpychania zadań do realizującego je systemu, na rzecz zasady „pull”, tj. zasady realizacji zadań wtedy, gdy jest to potrzebne z punktu widzenia zarówno możliwości wykonawczych, jak i celów całego systemu⁸.

1.4. Inne metody szacowania czasu trwania zadania

Ze względu na duże praktyczne znaczenie dokładności przewidywanych czasów trwania zadań, podejmowane są również próby wykorzystania innych metod, m. in.:

- metody analogowe,
- metody oparte na diagramach i stosowane w kontekście analizy ryzyka wykonania zadania w zadeklarowanym czasie, m. in. GERT (ang. *Graphical Evaluation and Review Technique*) i VERT (ang. *Venture Evaluation and Review Technique*),
- metody oparte na symulacjach, np. Monte Carlo.

1.5. Cechy charakterystyczne wymienionych metod

Przedstawione metody koncentrują się na „twardej” analizie, w tym specyfice zadań, kompetencjach i ograniczeniach wykonawcy, dostępnych zasobach i narzędziach. Natomiast w mniejszym stopniu zwracają uwagę

⁸ Institute for International Research, Certyfikowany IT Project Manager, 2005.

na tzw. „miękkie” aspekty zarządzania, uwzględniające styl zarządzania, atmosferę współpracy, relacje między pracownikami, dyspozycyjność i kompetencje pracowników, komunikację interpersonalną, asertywność, gotowość do wprowadzenia zmian, stosunek do nowych technologii i ekspertów i inne.

Wykorzystanie wymienionych metod jest ograniczone ze względu na stopień ich komplikacji, czasochłonność i wysokie koszty zastosowania.

2. Sztuczne Sieci Neuronowe (SSN)

Sztuczne sieci neuronowe (ang. *Artificial Neural Networks*) są uproszczonym modelem ludzkiego mózgu, narzędziami obliczeniowymi sztucznej inteligencji umożliwiającymi poprzez wyrafinowaną technikę modelowania odwzorowywanie bardzo złożonych funkcji¹.

2.1. Właściwości i zastosowania SSN

Jednym z pierwszych i ważniejszych modeli neuronu jest neuron *McCullocha-Pittsa*. Stan takiego neuronu o numerze i -tym jest w tym modelu opisany następującymi zależnościami²:

$$\sigma_i(t) = f(e_i(t) - T_i), \quad (2.1a)$$

$$e_i(t) = \sum_{j=1}^n w_{ij} \sigma_j(t-1), \quad (2.1b)$$


gdzie: $\sigma_i(t)$ jest stanem i -tego neuronu w czasie t , przy czym czas jest wielkością dyskretną $t = 0, 1, 2, 3, \dots$, f – funkcja aktywacji neuronu, $e_i(t)$ jest nazywane polem lokalnym działania na i -ty neuron w chwili t , pochodzącym od wszystkich n neuronów połączonych z i -tym neuronem, T_i – progiem zadziałania i -tego neuronu, w_{ij} – siłą połączenia synaptycznego między i -tym a j -tym neuronem, $\sigma_j(t-1)$ – stanem j -tego neuronu

¹ W. Duch i in., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2000, s. 4.

² R. A. Kosiński, *Sztuczne sieci neuronowe, dynamika nieliniowa i chaos*, WNT, Warszawa 2004, s. 31.

w chwili wcześniejszej, tj. $(t - 1)$. Podstawowy model sztucznego neuronu został przedstawiony na schemacie 2.

Schemat 2. Model sztucznego neuronu



Źródło: opracowanie własne na podstawie: Duch i in, 2000, s. 16, Kosiński, 2004, s. 32.

Dla opisu działania neuronu, przyjęto, że funkcja aktywacji ma postać funkcji unipolarnej (Heaviside'a):

$$f(x) = \begin{cases} 0 & \text{dla } x \leq 0 \\ 1 & \text{dla } x > 0. \end{cases} \quad (2.2)$$

Neuron z funkcją aktywacji Heaviside'a jest neuronem dwustanowym, tj. przyjmuje wartości binarne $[0, 1]$, przy czym $\sigma_i = 0$ oznacza, że neuron jest w stanie spoczynku, natomiast $\sigma_i = 1$ oznacza neuron w stanie zapłonu (wzbudzonym). Może być interpretowany w kategoriach określonej decyzji, np. obiekt należy do rozpoznawanej klasy lub do niej nie należy. Możliwa jest także interpretacja oparta na logice matematycznej, wówczas sygnał $\sigma_i = 1$ można interpretować jako „prawdę”, a sygnał $\sigma_i = 0$ jako „fałsz”³. Jak wynika z zależności (2.1) neuron przechodzi w chwili t w stan wzbudzony, gdy pole lokalne e_i przekracza wartość progu T_i . Wartości pola lokalnego są wynikiem sumowania stanów wszystkich n neuronów poprzedzających (*presynaptycznych*), w chwili $(t-1)$, dołączonych do danego i -tego neuronu. Wkład każdego z neuronów presynaptycznych do stanu rozpatrywanego neuronu zależy od siły (war-

³ R. Tadeusiewicz, *Sieci neuronowe*, Akademicka Oficyna Wydawnicza RM, Warszawa 1993, s. 51. D. Witkowska, *Sztuczne sieci neuronowe i metody statystyczne*, C. H. Beck, Warszawa 2002, s. 5.

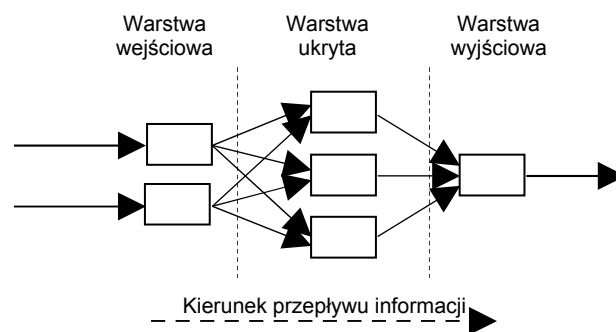
tości) połączenia synaptycznego w_{ij} , które może być różne dla każdej pary neuronów $i-j$. Wartość progu T_i jest parametrem charakteryzującym i -ty neuron.⁴

Zachowanie neuronu i tym samym całej sieci neuronowej jest w znacznym stopniu uzależnione od typu użytej funkcji aktywacji, która może przybierać zarówno postać liniową, jak i postaci nieliniowe, w których charakter zależności wiążącej sygnał wyjściowy z sygnałami wejściowymi może być praktycznie dowolny. Obecnie szerokie zastosowanie znajdują funkcje: logistyczna i tangens hiperboliczny.

Wpływ pojedynczych neuronów na pracę mózgu jest znikomo mały. Wykonanie przez człowieka najprostszyc zadań wiąże się z pobudzeniem milionów neuronów w odpowiednim obszarze mózgu. Podobnie, możliwości gromadzenia i przetwarzania informacji, jakie posiadają pojedyncze sztuczne neurony są ograniczone, dlatego w praktyce stosuje się sieci neuronowe tworzone przez połączone ze sobą neurony⁵.

SSN najczęściej konstruuje się w oparciu o strukturę warstwową. Wejścia neuronów pierwszej warstwy neuronów są wejściami sieci i ta warstwa nosi nazwę *warstwy wejściowej*. Wyjścia neuronów warstwy ostatniej, *warstwy wyjściowej*, są jednocześnie wyjściami sieci. Pomiedzy warstwami wejściową i wyjściową (zewnętrznymi) sieci w praktyce często umieszcza się tzw. *warstwy ukryte*. Przykładowa struktura sieci jednokierunkowej wielowarstwowej została przedstawiona na schemacie 3.

Schemat 3. Przykład struktury SSN jednokierunkowej wielowarstwowej



Źródło: opracowanie własne.

⁴ R. A. Kosiński, *Sztuczne sieci neuronowe...*, op. cit., s. 32-33.

⁵ Ibidem, s. 39. D. Witkowska, *Sztuczne sieci neuronowe...*, op. cit., s. 8.

Ostateczna topologia SSN jest podyktowany charakterem rozwiązywanego problemu i zależy od wyników procesu uczenia sieci, którego celem jest uzyskanie zgodności odpowiedzi sieci neuronowej z wartościami dokładnymi, czyli najbardziej zbliżonymi do rzeczywistych.

Powszechną metodą uczenia (trenowania) SSN jest metoda uczenia z nauczycielem (ang. *supervised learning*). Proces uczenia sieci z nauczycielem (uczenie nadzorowane) polega na podawaniu na wejście sieci przykładowych zbiorów danych z jednoczesnym dostarczeniem informacji o oczekiwanym sygnale na wyjściu sieci. Wagi neuronów są odpowiednio modyfikowane po wyliczeniu różnicy między odpowiedzią sieci a wartością oczekiwaną.

W procesie uczenia nadzorowanego ciąg uczący ma postać:

$$U = [\langle X_{(1)}, Z_{(1)} \rangle, \langle X_{(2)}, Z_{(2)} \rangle, \dots, \langle X_{(p)}, Z_{(p)} \rangle] \quad (2.3)$$

gdzie:

$\langle X_{(r)}, Z_{(r)} \rangle$ - pary danych podawanych na wejściu i wyjściu sieci w r -tym kroku procesu uczenia sieci,

p – liczba prezentacji w ciągu uczestniczącym biorących udział w procesie uczenia sieci.

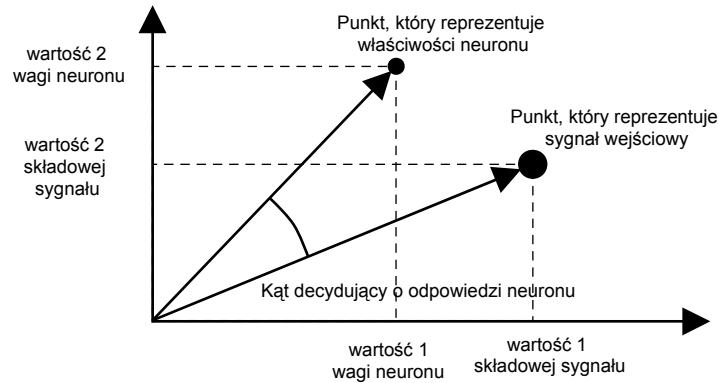
Pojedynczy neuron w typowych przypadkach realizuje (z matematycznego punktu widzenia) operację iloczynu skalarnego wektora sygnałów wejściowych oraz wektora wag. W efekcie odpowiedź neuronu zależy od wzajemnych stosunków geometrycznych pomiędzy wektorami sygnałów i wektorami wag⁶. Przykładowy układ wektora wag i wektora sygnału wejściowego neuronu został zaprezentowany na schemacie 4.

Przy pełnej zgodności kierunków wektora sygnału wejściowego i wektora wag, przy kącie między wektorami równym zero, sygnał odpowiedzi neuronu będzie miał najwyższą wartość.

Najbardziej znanym i najchętniej stosowanym algorytmem uczenia SSN jest klasyczny algorytm wstecznej propagacji błędów, BP (ang. *backpropagation*), który polega na adaptacji błędu neuronu wyjściowego do oszacowania błędów neuronów warstwy poprzedzającej, z których sygnały zostały podane na wejście neuronu wyjściowego.

⁶ W. Duch i in., *Sieci neuronowe...*, op. cit., s. 20.

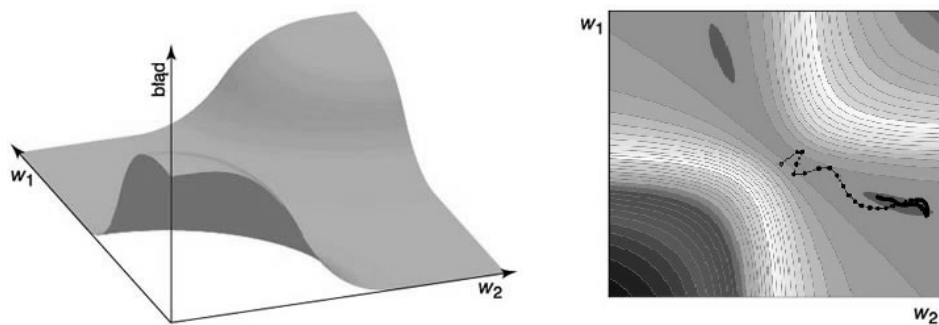
Schemat 4. Przykład układu wektora wag i wektora sygnału wejściowego neuronu



Źródło: opracowanie własne na podstawie: Duch i in., 2000, s. 21.

Realizacja algorytmu uczenia sieci sprowadza się do powtórzenia procedury dla określonej liczby iteracji lub do momentu osiągnięcia zbieżności z zadaniem kryterium⁷. Graficzny przebieg procesu uczenia sterowany algorytmem wstecznej propagacji błędów, z minimum osiągniętym po 91 iteracjach został przedstawiony na schemacie 5.

Schemat 5. Przykładowy przebieg procesu uczenia sterowany algorytmem wstecznej propagacji błędów



Źródło: Tadeusiewicz, <http://aneksy.pwn.pl/efw/?id=579>.

Istotną cechą SSN jest zdolność do rozwiązywania zadań zdefiniowanych formalnie niezbyt dokładnie i/lub precyzyjnie. Sieci takie

⁷ Ibidem, s. 25.

mają zdolność do generalizacji, potrafią prawidłowo działać nawet przy pewnym poziomie uszkodzeń, a także mimo częściowo błędnej informacji wejściowej. Zalety sieci neuronowych są szczególnie widoczne, jeśli dane, z których są generowane wnioski są przygotowywane w oparciu o ludzkie opinie, które mogą być obciążone dużymi błędami, a także mogą być natury „miękkiej”.

SSN ze względu na swoje właściwości znajdują zastosowanie w bardzo wielu dziedzinach życia. W literaturze przedmiotu najczęściej wymieniane są poniższe kierunki wykorzystania⁸: predykcja, klasyfikacja, analiza i kojarzenie danych, filtracja danych, optymalizacja.

Obecnie modele SSN znajdują zastosowanie m. in. w rozwiązaniu wymienionych poniżej zagadnień ekonomiczno-społecznych⁹: analizie rynków kapitałowych, modelowaniu kursów wymiany walut, badaniu kondycji finansowej firm i określaniu prawdopodobieństwa bankructwa, prognozowaniu przepływów pieniężnych, prognozowaniu szeregów mikroekonomicznych (PKB, inflacji, stopy bezrobocia).

3. Koncepcja wykorzystania SSN w procesie szacowania czasu trwania zadań wdrożeniowych realizowanych w sieci dilerskiej Audi i Volkswagen w Polsce

Wdrożenia systemów informatycznych w sieci dealerskiej Audi i VW w Polsce są niezwykle złożonymi przedsięwzięciami. W ich realizację zaangażowanych jest kilkadziesiąt firm i setki osób. Duża skala przedsięwzięcia przy jednocześnie ograniczonym dostępie do zasobów, w szczególności do wyspecjalizowanych zespołów wdrożeniowych (specjalistów), sprawia, że działania realizowane w poszczególnych firmach są od siebie mocno zależne. Opóźnienia zadań realizowanych w jednej firmie mogą przyczynić się do opóźnień a nawet odwołania zadań w kolejnych firmach organizacji.

Takie same zadania w różnych firmach dilerskich mogą być zrealizowane w różnym czasie. Jest to związane przede wszystkim z dużą różnorodnością firm¹ i ich istotnym wpływem na przebieg prac. Najważ-

⁸ R. Tadeusiewicz, *Sieci neuronowe...*, op. cit., s. 16-18.

⁹ M. Rekowski, *Wskaźniki wyprzedzające jako metoda prognozowania koniunktury w Polsce*, WAE w Poznaniu, Poznań 2003, s. 108.

¹ Firmy dilerskie są niezależnymi podmiotami gospodarczymi realizującymi obok celów organizacji również własne cele, często związane z innymi markami a także branżami. Różnice wynikają m. in. ze skali prowadzonej działalności, struktury, metod pracy, in-

niejszym elementem środowiska (firmy), w którym realizuje się zadania wdrożeniowe, są osoby bezpośrednio lub pośrednio z nimi związane. Dlatego, na etapie planowania prac wdrożeniowych, niezwykle ważnym elementem jest poprawna identyfikacja tych osób, które mogą mieć wpływ na ich przebieg. Brak informacji m. in. o panującej w firmie atmosferze współpracy, relacjach między pracownikami, dyspozycyjności, kompetencjach, asertywności, komunikacji interpersonalnej, itp., może być powodem wzrostu ryzyka wystąpienia poważnych zakłóceń w trakcie realizacji prac i tym samym wzrostu czasu ich trwania.

Pomimo dużej różnorodności firm istnieje potrzeba dokonania pewnych ich uogólnień ze względu na możliwość wystąpienia zdarzeń mogących mieć negatywny wpływ na realizację prac wdrożeniowych².

W sieci dilerskiej Audi i VW w Polsce firmy ze względu na ryzyko wystąpienia istotnych zagrożeń w trakcie realizacji prac wdrożeniowych zwykle dzieli się na trzy grupy: o niskim, średnim i wysokim ryzyku wdrożenia.

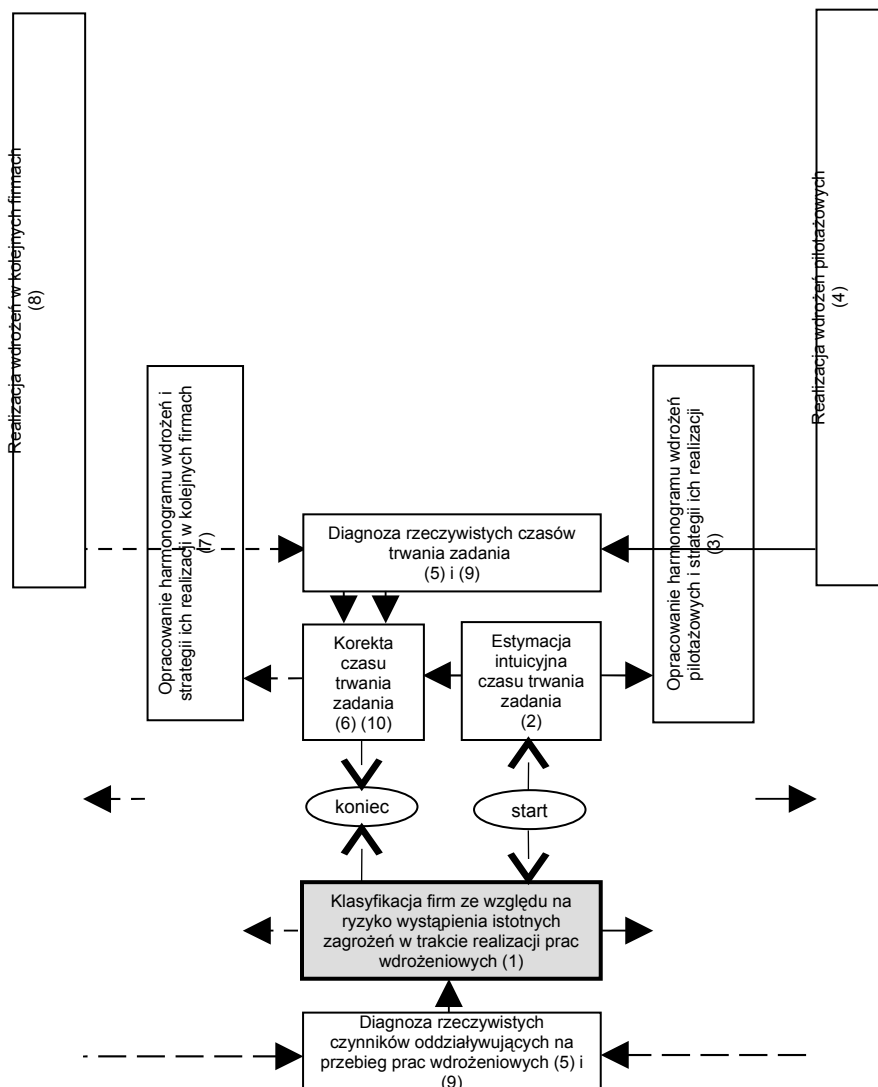
Klasyfikacja firm organizacji nie byłaby możliwa bez kompletnej i aktualnej informacji o istotnych czynnikach mogących mieć negatywny wpływ na przebieg prac w poszczególnych firmach. Najczęściej stosowanymi i jednocześnie najbardziej efektywnymi i skutecznymi metodami pozyskiwania informacji o środowisku wdrożeniowym są: analiza zrealizowanych wdrożeń (przegląd danych historycznych i rozmowy z członkami zespołów wdrożeniowych), rozmowy z osobami współpracującymi z firmami, analiza danych gromadzonych w ramach obsługi o charakterze hot-line, organizowanie spotkań i audytów przedwdrożeniowych, informacje pozyskane w trakcie realizacji prac pilotażowych.

Proces szacowania czasów trwania zadań wdrożeniowych realizowanych w sieci dealerskiej Audi i VW w Polsce został zaprezentowany na schemacie 6.

Schemat 6. Schemat procesu szacowania czasu trwania zadania

frastruktury, wyposażenia, położenia geograficznego a także z kultury organizacji, nastawienia do konkurencji wewnątrz organizacji, czynników związanych z pracownikami.

² Ograniczenia związane z organizacją i dostępnością zasobów uniemożliwiają indywidualną obsługę wdrożeń w poszczególnych firmach, dlatego istnieje potrzeba klasyfikacji firm ze względu na czynniki mogące mieć wpływ na przebieg prac i przygotowanie dla wydzielonych grup odpowiednich strategii ich obsługi.



Źródło: opracowanie własne.

Klasyfikacja firm ze względu na ryzyko wystąpienia istotnych zagrożeń w trakcie realizacji prac wdrożeniowych (1) i szacowanie czasów trwania zadań (2) realizowane są metodami eksperckimi, opisanymi w punkcie 1 opracowania. W oparciu o przeprowadzoną klasyfikację i estymację czasów trwania zadań eksperci przygotowują plan wdrożeń pilotażowych (3), które następnie są realizowane we współpracy z odpo-

wiednio dobranymi firmami³. Wdrożenia pilotażowe (4) są źródłem informacji o rzeczywistych czasach trwania zadań a także o dodatkowych czynnikach, które mogą mieć wpływ na wykonanie zadań (5). Pozyskane dodatkowe informacje mogą być wykorzystane do korekty pierwotnie estymowanych czasów (6) i klasyfikacji firm (1). Kolejnym etapem procesu szacowania czasu trwania zadań jest opracowanie harmonogramów wykonania zadań i strategii ich realizacji w pozostałych firmach (7). Realizacja wdrożeń w kolejnych firmach (8) jest źródłem nowych informacji (9), które mogą być wykorzystane, o ile zaistnieje taka potrzeba, do dalszych korekt (10) lub mogą być zarchiwizowane na potrzeby przyszłych prac wdrożeniowych.

Istotnym problemem przedstawionego schematu postępowania jest duża subiektywność otrzymywanych wyników, która jest spowodowana przede wszystkim tym, że w procesie uczestniczy niewiele osób i że stosowane metody nie uwzględniają w wystarczającym stopniu czynników związanych z pracownikami firm, którzy są zaangażowani w wykonanie prac.

Przedstawiona poniżej koncepcja proponuje uzupełnienie przedstawionego schematu postępowania metodą klasyfikacji realizowaną z wykorzystaniem sieci wielowarstwowego perceptronu MLP (ang. *Multilayer Perceptron*).

Ponieważ krytycznym elementem projektowania sieci neuronowych jest wybór zmiennych wejściowych, metoda zakłada, że osoby zaangażowane w realizację zadań wdrożeniowych można scharakteryzować za pomocą wymienionych poniżej trzech wymiarów postaw i zachowań, a każdy z nich można opisać za pomocą dwóch przeciwstawnych typów⁴.

Wymiar postawy – nastawienia i stosunku do współpracy, opisany typami: otwarty - zamknięty. Typ otwarty: nie ogranicza się wyłącznie do własnego interesu, jest zainteresowany bliską i partnerską współpracą, akceptuje obowiązujące procedury i procesy, aktywnie uczestniczy w realizowanych projektach, chętnie dzieli się dobrymi praktykami, jest otwarty na poszukiwanie i stosowanie nowych rozwiązań i technologii. Typ zamknięty: koncentruje się wyłącznie na własnym interesie, cechuje go roszczeniowy charakter współpracy, niechętnie akceptuje obowiązują-

³ Ze względu na potrzebę pozyskania dodatkowych informacji, dobrą praktyką jest przeprowadzenie wdrożeń pilotażowych w różniących się od siebie firmach organizacji.

⁴ Zaproponowana klasyfikacja została przygotowana w oparciu o metodę Myers i Briggs, która klasyfikuje ludzi za pomocą wymiarów zachowań ludzkich.

ce procedury i procesy, przyjmuje zachowawczą postawę w stosunku do realizowanych projektów, niechętnie dzieli się dobrymi praktykami, jest bierny w stosunku do nowych rozwiązań i technologii.

Wymiar kompetencji – wiedzy i doświadczenia, opisany typami: kompetentny - niekompetentny. Typ kompetentny: posiada kompletną wiedzę i doświadczenie, dobrze zna realizowane procesy i procedury, umiejętnie wykorzystuje zalecane narzędzia i systemy. Typ niekompetentny: nie posiada dostatecznej wiedzy i doświadczenia, słabo zna realizowane procesy i procedury, nie stosuje lub ma problemy z właściwym wykorzystaniem zalecanych narzędzi i systemów.

Wymiar stylu – związany ze sposobem zarządzania i podejmowania decyzji, opisany typami: konstruktywny - niekonstruktywny. Typ konstruktywny: funkcjonuje w sposób uporządkowany i sprofilowany, posiada jasno sprecyzowane i jawne cele, krytyczny ale kreatywny, prowadzi dyskusje w sposób wyważony, uporządkowany, precyzyjny i na dużym poziomie szczegółowości, decyzje uzależnia od dokładnej i szczegółowej analizy problemu. Typ niekonstruktywny: funkcjonuje w sposób niesprofilowany i chaotyczny, ma problemy z definiowaniem celów, zwykle nie ujawnia wszystkich zamiarów, przeważnie ogranicza się do krytyki, dyskusje prowadzi w sposób emocjonalny, wielowątkowy, niemerytoryczny, zwykle improwizuje i posługuje się nieprecyzyjnymi sformułowaniami, zwleka z podejmowaniem decyzji, często ich unika.

Na podstawie przedstawionych wymiarów można utworzyć osiem kombinacji typów postaw i zachowań osób zaangażowanych w realizację prac wdrożeniowych. Na przykład, osoby mogą być typem OKK, czyli otwartym, kompetentnym i konstruktywnym (charakterystycznym dla osób, z którymi realizacja zadań nie napotyka na trudności uniemożliwiające wykonanie zadań w oszacowanym czasie), typem ZNN, czyli zamkniętym, niekompetentnym i niekonstruktywnym (charakterystycznym dla osób, z którymi występują duże problemy już na etapie planowania wdrożenia), itd.

Biorąc pod uwagę przedstawione wymiary, wektor sygnałów wejściowych sieci należy utworzyć ze zmiennych reprezentujących sytuację danej firmy, odpowiednio:

- neuron nr 1, wymiar postawy kadry zarządzającej, przyjmuje wartość: 1 – dla typu otwartego, 0 – dla typu zamkniętego,

- neuron nr 2, wymiar kompetencji kadry zarządzającej, przyjmuje wartość: 1 – dla typu kompetentny, 0 – dla typu niekompetentny,
- neuron nr 3, wymiar stylu kadry zarządzającej, przyjmuje wartość: 1 – dla typu konstruktywny, 0 – dla typu niekonstruktywny,
- neuron nr 4, wymiar postawy pracowników operacyjnych, przyjmuje wartość: 1 – dla typu otwartego, 0 – dla typu zamkniętego,
- neuron nr 5, wymiar kompetencji pracowników operacyjnych, przyjmuje wartość: 1 – dla typu kompetentny, 0 – dla typu niekompetentny,
- neuron nr 6, wymiar stylu pracowników operacyjnych, przyjmuje wartość: 1 – dla typu konstruktywny, 0 – dla typu niekonstruktywny,
- neuron nr 7, wymiar postawy osoby odpowiedzialnej w firmie za prace wdrożeniowe, przyjmuje wartość: 1 – dla typu otwartego, 0 – dla typu zamkniętego,
- neuron nr 8, wymiar kompetencji osoby odpowiedzialnej w firmie za prace wdrożeniowe, przyjmuje wartość: 1 – dla typu kompetentny, 0 – dla typu niekompetentny,
- neuron nr 9, wymiar stylu osoby odpowiedzialnej w firmie za prace wdrożeniowe, przyjmuje wartość: 1 – dla typu konstruktywny, 0 – dla typu niekonstruktywny,
- neuron nr 10, dostępność i dyspozycyjność służb informatycznych, przyjmuje wartość: 1 – jeżeli firma ma własne służby, 0 – jeżeli firma korzysta z usług firm zewnętrznych,
- neuron nr 11, wymiar postawy służb informatycznych firmy, przyjmuje wartość: 1 – dla typu otwartego, 0 – dla typu zamkniętego,
- neuron nr 12, wymiar kompetencji służb informatycznych firmy, przyjmuje wartość: 1 – dla typu kompetentny, 0 – dla typu niekompetentny,
- neuron nr 13, wymiar stylu służb informatycznych firmy, przyjmuje wartość: 1 – dla typu konstruktywny, 0 – dla typu niekonstruktywny,
- neuron nr 14, ocena współpracy z zespołem hot-line, przyjmuje wartość: 0 – w przypadku braku zastrzeżeń, 1 – w przy-

padku zastrzeżeń nieistotnych, 2 – w przypadku dużych zastrzeżeń.

Warstwa wyjściowa, ze względu na proponowaną technikę reprezentacji zmiennych wyjściowych, *jeden-z- N^5* , będzie zbudowana z trzech neuronów. Zmienne na wyjściu poszczególnych neuronów powinny przyjmować wartości reprezentujące klasy firm, w których wdrożenia są obciążone określonym ryzykiem. Po podaniu sieci odpowiednich zmiennych wejściowych, na jej wyjściu będzie oczekiwana jedna z trzech w wymienionych odpowiedzi:

1) w przypadku klasy niskiego ryzyka:

- neuron nr 1, zmienna wyjściowa przyjmowałaby wartość 1,
- neuron nr 2, zmienna wyjściowa przyjmowałaby wartość 0,
- neuron nr 3, zmienna wyjściowa przyjmowałaby wartość 0,

2) w przypadku klasy średniego ryzyka:

- neuron nr 1, zmienna wyjściowa przyjmowałaby wartość 0,
- neuron nr 2, zmienna wyjściowa przyjmowałaby wartość 1,
- neuron nr 3, zmienna wyjściowa przyjmowałaby wartość 0,

3) w przypadku klasy wysokiego ryzyka:

- neuron nr 1, zmienna wyjściowa przyjmowałaby wartość 0,
- neuron nr 2, zmienna wyjściowa przyjmowałaby wartość 0,
- neuron nr 3, zmienna wyjściowa przyjmowałaby wartość 1.

Z określeniem liczby neuronów warstw ukrytych jest taki problem, że o ile w przypadku warstwy wejściowej i wyjściowej liczba neuronów jest ściśle powiązana z warunkami zadania, to w warstwach ukrytych może być ona dowolna. Przeważnie dobiera się je na drodze eksperymentów w procesie uczenia sieci. Istotnymi kryteriami wyboru osta-

⁵ Technika kodowania zakładająca, że jeden neuron odpowiada tylko jednej z N możliwych wartości reprezentowanej zmiennej (klas).

tecznego modelu powinny być efektywność i skuteczność sieci a także koszty jej przygotowania i wykorzystania.

Charakter zadania i dostępność do zmiennych zarówno wejściowych jak i wyjściowych umożliwiają przeprowadzenie procesu uczenia sieci z nauczycielem. Ze względu na ograniczoną liczbę prezentacji w ciągu uczącym, którego struktura została omówiona w p. 2 opracowania, metoda zakłada, że proponowany ciąg zostanie sieci zaprezentowany wielokrotnie z zachowaniem losowej zmiany kolejności przykładów występujących w ciągu. Kontrola postępów algorytmu uczenia sieci, z wykorzystaniem metody wstecznej propagacji błędów, zostanie zrealizowana w oparciu o proces walidacji, który polega na tym, że pewna liczba przypadków uczących zostanie zaliczona, przed rozpoczęciem procesu uczenia, do oddzielnej grupy. Dane z wydzielonej grupy nie będą bezpośrednio stosowane w trakcie uczenia sieci, natomiast będą wykorzystane do przeprowadzenia niezależnej kontroli postępów algorytmu uczenia. Dla zwiększenia poziomu zaufania do modelu, ze zbioru uczącego, przed rozpoczęciem procesu uczenia, zostanie wydzielony dodatkowo trzeci zbiór przypadków – tzw. zbiór testowy. Ostateczna postać modelu, nauczonego za pomocą zbioru uczącego i sprawdzonego za pomocą zbioru walidacyjnego, zostanie przetestowana za pomocą zbioru testowego.

Wiarygodność wyników proponowanej metody będzie bezpośrednio zależała od jakości wprowadzanych zmiennych. Jest to największe ograniczenie związane z trudnością gromadzenia solidnych i wiarygodnych danych. Ważne jest, aby pomiar wskaźników wymiarów postaw i zachowań był realizowany z odpowiednią częstością, gdyż poszczególne cechy są zmienne w czasie, co jest związane ze zmianami zachodzącymi w organizacji, na które wpływ mają m. in. rotacja personelu, szkolenia, nowe doświadczenia.

Zbadanie przydatności zaproponowanej metody wymaga przeprowadzenia odpowiednich eksperymentów. Autor w oparciu o dane historyczne zgromadzone w trakcie prac wdrożeniowych zrealizowanych w sieci dilerskiej Audi i Volkswagen w Polsce zaimplementuje sieci neuronowe a następnie sprawdzi ich działanie w trakcie realizacji kolejnych wdrożeń systemów informatycznych.

Podsumowanie

Duża dynamika rynku i nowe możliwości związane z szybkim rozwojem technologii sprawiają, że kluczowym czynnikiem decydującym o pozycji

przedsiębiorstwa na rynku jest jego zdolność do szybkiej reakcji na zachodzące zmiany, m. in. wybór w odpowiednim momencie a następnie poprawne wdrożenie i umiejętne wykorzystanie systemów informatycznych wspomagających działalność biznesową.

Wdrożenia systemów informatycznych w dużych organizacjach gospodarczych, ze względu na skalę, zróżnicowanie firm i istotny wpływ pracowników firm na przebieg prac, są niezwykle złożonymi przedsięwzięciami. Właściwa identyfikacja tzw. czynników ludzkich mogących mieć wpływ na czas realizacji zadań wdrożeniowych a następnie oszacowanie dokładnych czasów realizacji prac decydują o efektywności i skuteczności wdrożeń.

Znane metody estymacji czasów trwania zadań mimo wielu zalet nie są pozbawione wad. Ich podstawowe ograniczenia wynikają z tego, że koncentrują się przede wszystkim na kompetencjach i ograniczeniach wykonawcy, a także na dostępnych narzędziach i zasobach, jednocześnie nie przywiązując wystarczającej uwagi do otoczenia, w którym zadania są definiowane a następnie realizowane.

Przedstawiona metoda może stanowić cenne uzupełnienie znanych metod szacowania czasu realizacji zadań realizowanych w trakcie wdrożeń systemów informatycznych. Wykorzystanie SSN w procesie estymacji może przyczynić się do wzrostu obiektywności procesu i do zwiększenia dokładności estymowanych zmiennych. Dodatkowo, zdobyta wiedza w trakcie realizacji procesu może posłużyć wykonawcy do opracowania skuteczniejszych strategii obsługi prac wdrożeniowych w poszczególnych firmach organizacji, może być wykorzystana do efektywnej i skutecznej kontroli realizacji zadań, dzięki niej wykonawca może mieć większy wpływ na odpowiednie osoby (czynniki) tak, by mogły one wykonać zadania z sukcesem.

The use of artificial neural networks for the estimation of the task duration time in implementation of information systems

Summary

The great market dynamics and new possibilities connected with the rapid development of the technology cause that a key factor deciding about a position of the company on the market is its ability to make a quick response to some changes, among other things, a choice made in the right moment, next, a correct implementation and a professional use of information systems supporting some business activity.

Implementation of the information systems in some big companies is an extremely complex undertaking due to the range, variety of companies and an essential influence of company employees on the course of action. The correct identification of so called human factors that can influence the time of realization of implementation tasks and next, estimation of the exact time of task realization decide about efficiency and effectiveness of the implementation. The known methods of estimation of the task duration time, despite some advantages, are not deprived of drawbacks. Their basic limitations stem from the fact they concentrate, first of all, on some competences and constraints of an executor and also on available devices and sources. At the same time they do not pay enough attention to an environment in which the tasks are defined and next realized.

The presented concept can constitute a valuable supplement to the known methods of estimation of the time realization of tasks realized during the information systems' implementation. The use of artificial neural networks in the estimation process can contribute to an increase in the objectivity of the process and to the growth of the accuracy of estimated variables. Moreover, the knowledge acquired during a realization of the process can be used by an executor to work out some efficient strategies of implementation activities in particular branches of an enterprise and can contribute to an efficient and effective control of the task realization. Also, thanks to it an executor can have a greater influence on particular staff (factors) so that they help to carry out tasks successfully.

Researching the usefulness of the proposed concept requires conducting some appropriate experiments. The author, on the basis of historical data collected in the course of implementation activities executed in the dealership Audi and Volkswagen in Poland, will implement neural networks and then will check their use during execution of some next implementation of information systems.

Bibliografia

A Guide to the Project Management Body of Knowledge, Project Management Institute, Third Edition 2004.

Cieślak M., *Prognozowanie gospodarcze. Metody i zastosowania*, Wydawnictwo Naukowe PWN, Warszawa 2005.

Dittmann, P., *Prognozowanie w przedsiębiorstwie. Metody i ich zastosowanie*, Oficyna Ekonomiczna, Kraków 2004.

Duch, W., Korbicz, J., Rutkowski, L. Tadeusiewicz, R., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2000.

Frame, D. J., *Zarządzanie projektami w organizacjach*, WIG-PRESS Wydawnictwo Finansowe, Warszawa 2001, tytuł oryginału: *Managing Projects in Organizations. How to Make the Best Use of Time, Techniques, and People*.

Gładysz B., Kuchta D., Mechliński T., *Estimation of project task duration time by means of fuzzy numbers*, TNOiK, Bydgoszcz 2005.

- Kosiński R. A., *Sztuczne sieci neuronowe, dynamika nieliniowa i chaos*, WNT, Warszawa 2004.
- Lula P., Tadeusiewicz R., *Wprowadzenie do sieci neuronowych*, StatSoft Polska, Kraków 2001.
- Potok T.E., Vouk M.A. *A Model of Correlated Team Behavior in a Software Development Environment*, Proceedings of the Application-Specific Systems and Software Engineering Technology Symposium, 3/99.
- Pritchard, C. L., *Zarządzanie Ryzykiem w projektach. Teoria i praktyka*, WIG-PRESS Wydawnictwo Finansowe, Warszawa 2001, tytuł oryginału: *Risk Management Concepts and Guidance*.
- Rekowski M., *Wskaźniki wyprzedzające jako metoda prognozowania koniunktury w Polsce*, Wydawnictwo Akademii Ekonomicznej w Poznaniu, Poznań 2003.
- Stawicki J., Hałas M., *Skuteczna i szybka realizacja projektu*, ODITK, Warszawa 2004.
- Stefanowicz B., *Systemy eksperckie*, Wyższa szkoła informatyki stosowanej i zarządzania, Warszawa 2003.
- Tadeusiewicz R., *Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami*, Akademicka Oficyna Wydawnicza, Warszawa 1998.
- Witkowska D., *Sztuczne sieci neuronowe i metody statystyczne*, C. H. Beck, Warszawa 2002.