

Joanna Jasińska  
Zakład Systemów Jakości i Zarządzania

Andrzej Świdorski  
Zakład Systemów Jakości i Zarządzania

Witold Pokora  
Zakład Systemów Jakości i Zarządzania

## **NEURONOWY MODEL SZACOWANIA RYZYKA W REALIZACJI USŁUGI TRANSPORTOWEJ**

**Streszczenie:** W artykule przedstawiono koncepcję szacowania ryzyka w realizacji usługi transportowej z wykorzystaniem sztucznych sieci neuronowych. SSN są modelami matematycznymi realizującymi przetwarzanie informacji na wzór funkcjonowania neuronów w ludzkim mózgu. Zaprezentowany neuronowy model opiera się na rzeczywistych wynikach szacowania ryzyka w usługach transportowych. Wadami tej metody jest zebranie stosunkowo dużej liczby danych oraz pracochłonność etapu budowania sieci. Pomimo tego ograniczenia, stosowanie SSN w praktyce eliminuje błędy przypadkowe i umożliwia otrzymanie wiarygodnej oceny ryzyka niezbędnej do podejmowania decyzji o realizacji usługi transportowej.

**Słowa kluczowe:** ryzyko, identyfikacja ryzyka, szacowanie ryzyka, sztuczne sieci neuronowe.

### **1. WSTĘP**

Dynamika, zmienność i niestabilność sytuacji gospodarczo-politycznej może drastycznie wpłynąć na jakość usługi transportowej (UT). Świadomość istniejących i potencjalnych wartości ryzyka realizacji usługi zapewnia większą swobodę działania w kierunku konkretnych rozwiązań. Największym ryzykiem jest nie analizowanie ryzyka. Dlatego tak istotnego znaczenia nabiera umiejętność trafnego określania wszelkich uwarunkowań i aspektów mających wpływ na prawidłową, skuteczną i efektywną realizację UT. Wymaga to opracowania klarownych zasad i metod szacowania ryzyka i postępowania z nim. Ich zastosowanie umożliwi eliminację lub przynajmniej obniżenie jego wartości do poziomu akceptowalnego. Ocena ryzyka powinna być procesem ciągłym

i prowadzonym na wszystkich etapach realizacji UT. Najważniejszym i najtrudniejszym elementem oceny, rzutującym na późniejsze działania jest szacowanie ryzyka. Identyfikacja potencjalnych zagrożeń oraz ich źródeł i przyczyn wymaga dużej wiedzy i doświadczenia w zakresie zagadnień techniczno-logistycznych, organizacyjnych i marketingowych. Od wartości prawdopodobieństwa wystąpienia zagrożeń i ich skutków zależeć będzie klasyfikacja ryzyka pod kątem kryteriów akceptowalności, określenie priorytetów oraz zaangażowanie odpowiednich zasobów. Wyniki tej oceny zdeterminują podjęcie decyzji o realizacji UT, a w konsekwencji wdrożenie zaplanowanych działań prowadzących do obniżenia wartości ryzyka do poziomu akceptowalnego. Koszty potencjalnych strat, poniesionych wskutek niewłaściwie zrealizowanej UT są pochodną wykonanych działań korygujących. Dlatego tak istotne jest monitorowanie procesów realizacji UT w świetle wykonania zaplanowanych działań redukujących ryzyko. Dzięki temu możliwa jest bieżąca ocena i zainicjowanie zmian, w zależności od poziomu ryzyka. Monitorowanie powinno obejmować swym zakresem wszystkie zidentyfikowane poziomy ryzyka. Nawet te, o niskich wartościach, w tym szcążkowe, ponieważ mogą one zmieniać swoje wartości i znacząco wpływać na realizację UT.

Miernikiem skuteczności szacowania ryzyka jest bilans końcowy zysków i strat procesu realizacji UT przekładający się na zaufanie do przedsiębiorstwa transportowego oraz zadowolenie klienta.

## **2. METODYKA SZACOWANIA RYZYKA**

Szacowanie ryzyka bazujące na intuicji, bez stosowania jednoznacznych zasad identyfikacji, analizy, redukcji i monitorowania ryzyka może stanowić poważne zagrożenie dla efektywności i skuteczności prowadzonej działalności. W obecnych uwarunkowaniach gospodarczych trzeba wykształcić sprawny i obiektywny mechanizm zapobiegania ryzyku, aby stosunkowo szybko otrzymać rzetelne wyniki, na podstawie których podjęcie decyzji o realizacji UT stanie się łatwiejsze.

Mając opracowaną i zweryfikowaną procedurę opisującą kolejne etapy postępowania z ryzykiem, rodzi się pytanie, jakie zastosować metody? Mimo różnorodności metod opisanych w literaturze, odpowiedź nie jest ani prosta ani oczywista. Wykorzystanie dużej liczby metod może spowodować rozproszenie danych lub ich utratę. Wybór jednej, może okazać się niewystarczający dla przedstawienia przejrzystego, pełnego i logicznego obrazu ryzyka. Dochodzą do tego problemy związane z brakiem danych, wiedzy i doświadczenia oraz naciskiem spowodowanym krótkim terminem realizacji UT.

Ciągle pozostaje jeszcze pytanie, na ile uzyskane w wyniki z szacowania ryzyka potwierdzą rzeczywiste wartości ryzyka, uzyskane w trakcie realizacji UT. Jak ustrzec się błędów przypadkowych?

Rozwiązaniem tego problemu może być wykorzystanie jednej z nowoczesnych metod - sztucznych sieci neuronowych (SSN) zapewniających w znacznej mierze obiektywizację i weryfikację wyników. SSN są modelami matematycznymi realizującymi przetwarzanie informacji na wzór funkcjonowania neuronów w ludzkim mózgu. Cechą charakterystyczną SSN jest ich zdolność do uogólniania z tolerancją na braki i nieciągłości w zbiorze danych. Możliwość odwzorowania nieliniowego i łatwość „uczenia się” na podanych przez

użytkownika przykładach sprawia, że SSN mogą w pełni odzwierciedlać rzeczywiste wyniki szacowania ryzyka.

Określenie struktury SSN wymaga przeprowadzenia procesów uczenia i testowania na podstawie rzeczywistych danych z procesów realizacji UT. W tym celu konieczne jest zebranie i uporządkowanie danych z wykorzystaniem metod klasycznych, takich jak np.:

- schemat blokowy - graficzne przedstawienie kolejnych etapów procesu identyfikacji ryzyka w powiązaniu z obszarami zagrożeń,
- arkusz sprawdzający - zbieranie i uporządkowanie danych z pomiarów i obserwacji wstępnego przetwarzania informacji źródłowych o zagrożeniach,
- histogram - przedstawienie w postaci wykresu słupkowego zmienności określonego zbioru danych kierunku identyfikacji zagrożeń,
- karta kontrolna - identyfikowanie zagrożeń wynikających ze zmienności procesu realizacji usługi,
- diagram przyczynowo-skutkowy Ishikawy - uszeregowanie i klasyfikacja źródeł zagrożeń do właściwych grup,
- analiza drzewa (FTA) i (FTA) - przedstawienie w postaci drzewa kombinacji i wzajemnych zależności między potencjalnymi wadami a także sekwencji zdarzeń, które mają wpływ na realizację UT,
- FMEA – określenie przyczyn i skutków wystąpienia zagrożeń,
- analiza Pareto-Lorenza - zobrazowanie hierarchii ważności określonych grup zagrożeń, którymi należy zająć się w pierwszej kolejności.

Ryzyko realizacji UT rozpatrywano na poziomie planowania, zakupów i realizacji w pięciu aspektach:

- geograficznym, jako możliwość dostarczenia towaru/osób do określonego miejsca,
- terminowym, jako możliwości dostarczenia towaru/osób w określonym czasie,
- technicznym, jako możliwość dostarczenia towaru/osób z wykorzystaniem wymaganego środka transportu,
- jakościowym, jako możliwość dostarczenia towaru zachowaniem wymagań określonych przez klienta,
- kosztowym, jako możliwości dostarczenia towaru/osób po określonych kosztach.

Do obiektywizacji eksperckiej oceny stopnia zapewnienia jakości procesów szacowania ryzyka realizacji UT służy macierz ryzyka (tablica1).

Tablica 1

**Macierz ryzyka**

Skutek oddziaływania zagrożenia	1	0	0,25	0,5	0,75	1
	0,75	0	0,187	0,375	0,562	0,75
	0,5	0	0,125	0,25	0,375	0,5
	0,25	0	0,062	0,125	0,187	0,25
	0	0	0	0	0	0
		0	0,25	0,5	0,75	1
	Prawdopodobieństwo wystąpienia zagrożenia					

Kryteria akceptowalności ryzyka zależą przede wszystkim od możliwości spełnienia wymaganych parametrów UT oraz od wpływu na bezpieczeństwo i niezawodność środków transportu.

Wynikiem końcowym szacowania ryzyka jest podjęcie decyzji o:

- realizacji UT bez podejmowania działań redukujących,
- realizacji UT po przeprowadzeniu redukcji wartości ryzyka do poziomu akceptowalnego,
- rezygnacji z realizacji UT ze względu na niewspółmierne lub niemożliwe do wykonania działania redukujące oraz wysokie koszty ich przeprowadzenia.

W tabelicy 2. przedstawiono przykładową charakterystykę kryterialną, którą posługują się eksperci podczas szacowania ryzyka UT w aspekcie geograficznym. Podobne kryteria przyjęto podczas szacowania ryzyka w pozostałych aspektach.

Tablica 2

**Charakterystyka kryterialna szacowania ryzyka**

<b>Charakterystyka aspektu geograficznego</b>	
Przedsiębiorstwo transportowe nie posiada wymaganych środków transportu do przewozu osób i towarów w miejsca, o które pytają się zleceniodawcy. Na listach dostawców brak dostawców zewnętrznych dysponujących właściwymi środkami transportu. Planowanie UT nie jest dokumentowane. Wzrasta liczba usług niezgodnych z wymaganiami oraz liczba reklamacji i skarg klienta na jakość UT i przewożonych towarów.	0,75 ÷ 1
Dokumentacja wymaga uzupełnienia. Jednostkowe przypadki: reklamacji, braku środka transportu, nie udokumentowania planowania UT. UT niezgodne z wymaganiami wykrywane przed jej zrealizowaniem. Istnieją możliwości poprawy jakości UT.	0,375 ÷ 0,562
Przedsiębiorstwo transportowe posiada dobrze udokumentowane zrealizowane UT. Zakupy, w tym usług transportowych dobrze udokumentowane. Jednostkowe reklamacje. Małoznaczące wady UT.	0 ÷ 0,25

Poziom wartości 0,75 – 1 oznacza ryzyko wysokie, co w praktyce przekłada się na wysokie prawdopodobieństwo wystąpienia zagrożenia lub istotny skutek zagrożenia. Taka sytuacja może wynikać np. z problemów z jakością i terminowością realizacji UT, niewłaściwym nadzorowaniem procesów czy brakiem możliwości spełnienia wymagań jakościowych UT.

Ryzyko średnie w zakresie wartości od 0,375 do 0,562 dotyczy istotnego prawdopodobieństwa wystąpienia zagrożenia i umiarkowanego znaczenia skutków jego oddziaływania. Najczęściej identyfikuje się je w przypadku niestabilności procesów lub zidentyfikowania niekorzystnych trendów oddziałujących na procesy.

Niski poziom ryzyka (0 - 0,25) występuje w przypadku małego prawdopodobieństwa wystąpienia zagrożenia i nieistotnej wartości skutku jego oddziaływania. Ma to miejsce najczęściej, gdy znana jest zmienność procesu, przebieg jego jest ustabilizowany, a zagrożenia nie mają wpływu na terminowość realizacji UT.

## 2.1. Neuronowe modelowanie szacowania ryzyka

Do badań i neuronowego modelowania autorzy wykorzystali dane z auditów przeprowadzonych w ZSJZ (akredytowanej jednostce certyfikującej) w procesach certyfikacji w przedsiębiorstwach transportowych oraz z realizacji rzeczywistych UT. Do wyznaczenia modelu matematycznego szacowania ryzyka wykorzystano sieć jednokierunkową (perceptron wielowarstwowy). Obliczenia oparto na programie komputerowym JETNET 2.0 opracowanym w języku FORTRAN 77 [12], wykorzystującym algorytm momentowej metody wstecznej propagacji błędów [12, 16, 17].


Modelowanie przeprowadzono w odniesieniu do oceny szacowania ryzyka wykonanej w czasie  $t$  (rys. 1) w oparciu o regułę (1):

$$\Gamma(t) = f(\gamma_1(t), \gamma_2(t), \dots, \gamma_M(t)) \quad (1)$$

gdzie:

$\Gamma(t)$  - funkcja oceny szacowania ryzyka,

$\gamma_m(t)$  - ocena spełnienia  $m$ -tego wymagania dotyczącego szacowania ryzyka, przy czym  $m = 1, 2, \dots, M$ ,



Rys. 1. Model oceny szacowania ryzyka

W tabelicy 3. przedstawiono przykładowe dane wykorzystane do zbudowania SSN.

Tablica 3

Wybrane dane do zbudowania SSN

Proces planowania					Proces realizacji					Proces zakupów					Ocena końcowa ryzyka
Terminy	Koszty	Jakość	Technika	Geografia	Terminy	Koszty	Jakość	Technika	Geografia	Terminy	Koszty	Jakość	Technika	Geografia	
0	0	0	0	0	0,187	0	0	0,06	0,562	0	0	0	0	0	0,45
0	0	0	0	0	0,06	0	0	0,06	0	0,06	0	0	0	0	0,06
0,06	0,06	0,06	0,06	0	0,562	0,06	0,06	0,06	0	0,562	0,125	0,06	0,06	0	0,6
0,06	0,06	0,06	0,06	0	0,25	0,06	0,06	0,06	0	0,187	0,06	0,06	0,06	0	0,2
0,06	0,06	0,06	0,06	0	0,75	0,06	0,06	0,06	0	0,75	0,06	0,06	0,06	0	0,8
0,06	0,06	0,06	0,06	0	0,06	0,06	0,06	0,06	0	0,06	0,06	0,06	0,06	0	0,06
0,562	0,25	0,25	0,25	0	0,562	0,25	0,25	0,25	0	0,75	0,25	0,75	0,75	0	0,95
0,375	0,187	0,125	0,125	0	0,375	0,187	0,187	0,187	0	0,375	0,125	0,375	0,375	0	0,4
0,75	0,25	0,125	0,125	0	0,75	0,562	0,125	0,125	0	0,75	0,375	0,562	0,562	0	1
0,5	0	0,5	0,25	0,5	0,25	0,125	0,25	0,25	0,25	0,25	0,187	0,187	0,25	0,125	0,65

0,125	0,25	0,125	0,25	0,25	0,187	0,187	0,25	0,125	0,125	0,25	0,25	0,25	0,187	0,187	0,25	0,25
0	0	0,125	0,125	0,25	0,187	0,25	0,187	0	0	0	0,187	0,187	0,187	0,187	0,25	0,25
0	0	0	0	0,125	0,187	0,187	0,25	0,125	0,125	0,125	0,125	0,25	0,187	0,25	0,25	0,3
0,375	0,375	0,5	0,25	0,25	0,25	0,375	0,5	0,5	0,5	0,25	0,25	0,25	0,25	0,25	0,25	0,5
0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0,95
0,06	0,06	0,06	0,06	0,06	0,06	0,06	0,06	0,06	0,06	0,06	0,06	0,06	0,06	0,06	0,06	0,06
0,25	0	0	0	0,25	0,25	0,125	0,25	0,125	0,25	0,125	0,25	0,125	0,25	0,125	0,25	0,25
0	0	0	0	0	0	0,125	0,125	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0,25	0,25	0,25	0,25	0,125	0,25	0,125	0,125	0,125	0,125	0,125	0,125	0,125	0,125	0,125	0,125	0,25
0	0	0	0	0,125	0,75	0	0	0	0	0	0	0,125	0,25	0,25	0,25	0,7
0,125	0,125	0,25	0,5	0,25	0,125	0,125	0,125	0,125	0,125	0,125	0,125	0,125	0,125	0,125	0,125	0,2
0,562	0,25	0,25	0,25	0	0,562	0,25	0,25	0,25	0	0,75	0,25	0,75	0,75	0,75	0	0,95
0,187	0,25	0,125	0,125	0	0,375	0,25	0,125	0,125	0	0,375	0,375	0,187	0,187	0	0,45	

W wierszach zawarto wyniki cząstkowe szacowania ryzyka (dane wejściowe do SSN) w zależności od aspektu, zaś w ostatniej kolumnie zawarta jest ocena końcowa ryzyka (dane wyjściowe z SSN) dla poszczególnych procesów realizacji UT. Od jakości przygotowania danych zależy wyznaczenie właściwego modelu matematycznego odwzorowującego rzeczywiste oceny szacowania ryzyka. Poprawność uczenia SSN mierzona była błędem uczenia oraz % zdarzeń pozytywnych w zależności od wartości: współczynnika uczenia  $\eta$ , momentum  $\alpha$ , liczby iteracji, liczby warstw ukrytych i liczby neuronów w nich zawartych (tablica 4).

Tablica 4


Wybrane wyniki modelowania SSN

L.p.	$\alpha$	$\eta$	N	Liczba neuronów w warstwach:				% zdarzeń pozytywnych	$\chi^2_{sr} 10^2$		
				WE	WY	Ukrytych					
						1.	2.			3.	4.
1.	0,5	0,05	$10^7$	15	1	15	10	5	3	100	0,0003
2.	0,5	0,05	$10^7$	15	1	15	10	5	-	100	0,0005
3.	0,5	0,05	$10^7$	15	1	10	10	5	-	100	0,0011
4.	0,5	0,05	$10^7$	15	1	15	8	-	-	100	0,0002
5.	0,5	0,05	$10^7$	15	1	10	10	-	-	100	0,0004
6.	0,5	0,05	$10^7$	15	1	10	-	-	-	100	0,0004
7.	0,5	0,10	$10^6$	15	1	15	10	5	3	93,16	0,36
8.	0,8	0,05	$10^6$	15	1	15	10	5	3	99,66	0,030
9.	0,5	0,10	$10^6$	15	1	15	10	5	-	100	0,008
10.	0,5	0,05	$10^6$	15	1	15	10	5	-	100	0,011
11.	0,6	0,05	$10^6$	15	1	15	10	5	-	100	0,010
12.	0,8	0,05	$10^6$	15	1	15	10	5	-	100	0,006
13.	0,5	0,05	$10^6$	15	1	10	10	5	-	100	0,011
14.	0,5	0,10	$10^6$	15	1	15	8	-	-	100	0,006
15.	0,5	0,05	$10^6$	15	1	15	8	-	-	99,66	0,019
16.	0,6	0,05	$10^6$	15	1	15	8	-	-	100	0,013
17.	0,8	0,05	$10^6$	15	1	15	8	-	-	100	0,005
18.	0,5	0,10	$10^6$	15	1	10	-	-	-	100	0,010
19.	0,5	0,05	$10^6$	15	1	10	-	-	-	100	0,013
20.	0,6	0,05	$10^6$	15	1	10	-	-	-	100	0,011
21.	0,8	0,05	$10^6$	15	1	10	-	-	-	100	0,008
22.	0,5	0,05	$10^5$	15	1	10	10	-	-	96,78	0,15
24.	0,5	0,05	$10^5$	15	1	10	10	5	-	89,92	0,40
25.	0,5	0,05	$10^5$	15	1	15	8	-	-	96,78	0,17
26.	0,5	0,05	$10^5$	15	1	10	10	-	-	96,78	0,15
27.	0,5	0,05	$10^5$	15	1	10	-	-	-	99,38	0,16

Na podstawie przedstawionych wyników stwierdzono, że najlepiej odwzorowującą rzeczywiste oceny z szacowania ryzyka jest sieć liniowa, jednokierunkowa, wielowarstwowa, z liczbą iteracji  $N=10^7$ .

Tak nauczone SSN poddano testowaniu. Istota testowania polega na określeniu wartości sygnałów wejściowych i wyjściowych, które nie zostały wykorzystane do uczenia sieci.

O pozytywnym wyniku uczenia SSN świadczy wykres uczenia (rys. 2).



Rys. 2. Wybrany wykres uczenia SSN (SSN poz. 2, tablica 4)

### 3. PODSUMOWANIE

Przeprowadzone badania oraz modelowanie szacowania ryzyka realizacji UT z wykorzystaniem sztucznych sieci neuronowych wykazały, że model matematyczny dokonywania oceny szacowania ryzyka w procesach realizacji UT, oparty na liniowej sztucznej sieciach neuronowej, odwzorowuje rzeczywisty model dokonywania oceny. SSN wymagają niższego poziomu wiedzy teoretycznej od odbiorcy do zbudowania modelu, niż w przypadku stosowania tradycyjnych metod, np. komputerowej identyfikacji obiektów i procesów, metod statystycznych, czy metod z zakresu inżynierii jakości.

#### Bibliografia

1. Cholewicka-Goździk K.: „Kompleksowa ocena jakości. Metody, przykłady”, PWE, Warszawa, 1984.
2. Gierszewska., G. Romanowska M.: „Analiza strategiczna przedsiębiorstwa”, PWE, Warszawa, 1998.
3. Hamrol A., Mantura W.: „Zarządzanie jakością. Teoria i praktyka”, PWN, Warszawa – Poznań 1999.
4. Iwasiewicz A. „Zarządzanie jakością”, PWN, Warszawa-Kraków 1999.
5. Jasińska J., Świdorski A.: „Problemy oceny ryzyka w procesach realizacji wyrobów w aspekcie wymagań AQAP”, Problemy Jakości, 1/2006.
6. Jasińska J.: „Model zarządzania ryzykiem w procesach realizacji wyrobów obronnych”, Praca dyplomowa, AON, Warszawa, 2005.
7. Jedynak P., Szydło S.: „Zarządzanie ryzykiem”, Wydawnictwo im. Ossolińskich, Wrocław, 1997.

8. Jędralska K.: „Zachowanie przedsiębiorstw w sytuacjach niepewnych i ryzykownych”, AE, Katowice, 1992.
9. Kaczmarek T.: „Zarządzanie ryzykiem handlowym, finansowym i produkcyjnym”, ODDK, Gdańsk, 2002.
10. Kaczmarek T.: „Ryzyko i zarządzanie ryzykiem. Ujęcie interdyscyplinarne”, Difin, Warszawa, 2005.
11. Łańcucki J.: „Podstawy kompleksowego zarządzania jakością”, Akademia Ekonomiczna, Poznań 2001.
12. Lonnbald L., Petersom C., Rognvaldsson T.: Pattern recognition in high energy physics with artificial neural networks – JETNET 2.0. Computer Physics Communications 70, 1992.
13. Pritchard C.L. „Zarządzanie ryzykiem w projektach. Teoria i praktyka”, WIG-Press, Warszawa 2002
14. Świdorski A.: „Konceptcja wspomagania procesu decyzyjnego w certyfikacji systemów zarządzania z wykorzystaniem sztucznych sieci neuronowych”. Problemy Jakości nr 6/2006, Warszawa 2006.
15. Świdorski A.: „Wykorzystanie sztucznych sieci neuronowych w certyfikacji systemów zarządzania jakością”. „Innowacyjność w kształtowaniu jakości usług i usług” pod redakcją Jerzego Żuchowskiego, Politechnika Radomska, Polska Akademia Nauk, Radom 2006.
16. Świdorski A.: „Risk estimation in quality management with using artificial neural networks”. Filozofia TQM w zrównoważonym rozwoju (pod redakcją Jerzego Żuchowskiego), Politechnika Radomska, Polska Akademia Nauk, Radom 2008.
17. Świdorski A.: „Neural modeling of process risk estimation in quality management”. Polish Journal of Commodity Science nr 4 (17), Radom 2008.
18. Tarczyński W., Mojsiewicz M.: „Zarządzanie ryzykiem”, PWE, Warszawa 2001.

## **NEURAL MODEL OF RISK ESTIMATION IN THE TRANSPORT SERVICE REALIZATION**

**Abstract:** The article presents the idea of risk estimation in transport service realization with the use of artificial neural networks. ANN is a mathematical model which processes information by simulating the functioning of neurons in a human brain. The presented neural model is based on actual results of risk estimation in transport services. A relatively large amount of data and a labour-consuming stage of creating the network constitute a disadvantage of this method. Nevertheless, using ANN practically eliminates incidental errors and enables to obtain a reliable risk assessment necessary for taking decisions on transport service realization.

**Keywords:** risk, risk identification, risk estimation, artificial neural networks