

**Andrzej Świdorski, Ewa Dębicka**

Instytut Transportu Samochodowego

**Arkadiusz Jóźwiak, Szymon Mitkow**

Wojskowa Akademia Techniczna, Wydział Logistyki

# MODELOWANIE NEURONOWE W ZASTOSOWANIU DO OCENY RYZYKA W EKSPLOATACJI ŚRODKÓW TRANSPORTU

Rękopis dostarczono: marzec 2018

**Streszczenie:** W artykule przedstawiono problematykę wykorzystania modelowania matematycznego opartego na sztucznych sieciach neuronowych do oceny ryzyka w procesach eksploatacji środków transportu. Scharakteryzowano zagadnienia eksploatacji pojazdów, teorii ryzyka i jego oceny oraz modelowania neuronowego. Przedstawiono wyniki badań własnych, wspomaganym narzędziem informatycznym. Badania przeprowadzono, wykorzystując rzeczywistą ekspercką ocenę ryzyka realizowaną w ostatnich 10 latach w przedsiębiorstwach transportowych i produkcyjno-usługowych w ramach procesów certyfikacji realizowanych w Wojskowej Akademii Technicznej i Instytucie Transportu Samochodowego.

**Słowa kluczowe:** sztuczne sieci neuronowe, ryzyko, eksploatacja maszyn, środki transportu

## 1. WSTĘP

Starzenie się obiektu technicznego nie zawsze jest podatne na obserwację co może zwiększyć ryzyko wystąpienia uszkodzenia w procesie jego eksploatacji. Prawdopodobieństwo wystąpienia uszkodzenia można zmniejszyć wykonując profilaktyczne obsługiwania techniczne. Jednak takie działania nie dają pewności, że uszkodzenie nie wystąpi lub że wystąpi w określonym czasie. Moment wystąpienia uszkodzenia, jego miejsce i zakres nie są więc zdeterminowane. Tym samym nie jest zdeterminowany nie tylko okres zdatności obiektu technicznego (czas do uszkodzenia), ale także zakres i czas trwania obsługiwania technicznego. Stąd eksploatacja obiektu wiąże się z ryzykiem nieosiągnięcia przez nią zamierzonego celu [17]. Ryzyko jest pojęciem powszechnie znanym i przez wiele dyscyplin naukowych definiowanym, jednak nadal brakuje uniwersalnych rozwiązań problemów związanych z jego występowaniem i oceną. Dotyczy to również ryzyka w procesach eksploatacji środków transportu.

Przedsiębiorstwa zmuszone są do wypracowania własnych mechanizmów oceny ryzyka, a to jest możliwe tylko poprzez opracowanie właściwej procedury postępowania. W praktyce ocenę ryzyka prowadzi się w każdym procesie realizacyjnym. Dotyczy to też procesów eksploatacji środków transportu. Dlatego tak istotne jest opracowanie skutecznej metodyki, która dostarczy obiektywne dowody, że wyrób lub usługa spełnia określone wymagania. Stosowanie mierzalnych metod oceny ryzyka, pomaga przedsiębiorcom wywiązać się m.in. z terminów dostaw zgodnie z wymaganiami klienta oraz pozwala uniknąć przestojów w produkcji.

Rozpatrywanym problemem badawczym jest obserwacja autorów artykułu, że w praktyce eksploatacyjnej ryzyko ocenia się zwykle w sposób intuicyjny, choć niekiedy z zastosowaniem mierzalnych metod. Jednakże niekompletne dane i krótkie terminy realizacji kontraktów sprawiają, że ocena ryzyka dokonywana bywa w sposób chaotyczny, bez określonej procedury postępowania.

Celem artykułu jest zatem przedstawienie problematyki wykorzystania modelowania matematycznego, opartego na sztucznych sieciach neuronowych, do oceny ryzyka w procesach eksploatacji środków transportu. Postawiono tezę, że sieci neuronowe można wykorzystać do modelowania oraz do jednoznacznej i wiarygodnej oceny ryzyka w procesach eksploatacji środków transportu.

W pracy wykorzystano następujące metody badawcze: dedukcję i indukcję, analizę systemową i modelowanie. Metoda dedukcji wykorzystywana została do analizy spostrzeżeń

i faktów wynikających z zastosowania modelu oceny ryzyka w eksploatacji środków transportu. Metoda indukcji posłużyła do formułowania wniosków na podstawie zebranych danych. Metoda analizy systemowej pozwoliła na określenie elementów oceny ryzyka i wzajemnych relacji przyczynowo - skutkowych. Metodę modelowania zastosowano w działaniach poznawczych, w których przeprowadzenie operacji badawczych na konkretnym procesie było niemożliwe lub niecelowe, a przedstawienie występujących zjawisk za pomocą wzorów matematycznych lub schematów opisowych staje się bardziej przejrzyste i korzystne dla ich analizy.

## **2. RYZYKO W PROCESACH EKSPLOATACJI ŚRODKÓW TRANSPORTU**

Eksploatacja, to zespół celowych działań organizacyjno - technicznych i ekonomicznych ludzi ze sprzętem oraz wzajemnych relacji występujących pomiędzy nimi od chwili przyjęcia sprzętu do wykorzystania zgodnie z przeznaczeniem, aż do jego likwidacji (wybrakowania) [8]. Do osiągnięcia pożądaných wskaźników eksploatacji wprowadza się następujące kierunki działań:

- odpowiednie strategie obsługiwań technicznych,
- odpowiednie procedury użycia środków transportu,
- odpowiednie przedsięwzięcia w zakresie modernizacji pojazdów.

W literaturze można spotkać się z określeniem ryzyka, jako zespół czynników, działań lub czynności powodujących szkody lub straty [4]. W obszarze środków transportu, z problemem ryzyka ściśle związana jest ich niezawodność i bezpieczeństwo [17]. Analiza niezawodności dostarcza ilościowego pomiaru w odniesieniu do możliwych uszkodzeń i wad [9]. W badaniach uszkodzeń elementów pojazdów wykorzystano wiedzę i metody z różnych dziedzin nauki, które umożliwiają określenie nie tylko stanu technicznego konstrukcji, ale też ocenę ryzyka. Pomocne w rozwiązywaniu problemów praktycznych z zakresu niezawodności i bezpieczeństwa środków transportu mogą być systemy symulacyjne oparte na tworzeniu modeli matematycznych z wykorzystaniem np. metod drzewa uszkodzeń czy Monte Carlo oraz metod sztucznej inteligencji.

Na podstawie dokonanego przeglądu stosowanych w literaturze definicji ryzyka, jak również doświadczenia autorów, na potrzeby artykułu przyjęto, że „*ryzyko jest iloczynem wartości skutku zagrożenia i prawdopodobieństwa jego wystąpienia*”.

Ryzyko jest obecne we wszystkich dziedzinach działalności. Może być nim obarczone każde przedsięwzięcie, również techniczne. Szczególnie dużą rolę odgrywa ono w procesach produkcji, dystrybucji, serwisu, ale też w procesach eksploatacji maszyn. Zatem sparymetryzowana ocena występującego ryzyka jest sprawą kluczową do podejmowania decyzji.

Literatura przedmiotu opisuje szeroko różne metody oceny ryzyka, zarówno jakościowe, jak i ilościowe. Opisane są różne metody oceny ryzyka. W artykule zaprezentowano metodę z wykorzystaniem sieci neuronowych. Sztuczne sieci neuronowe są szeroko stosowane w technice, głównie w diagnostyce maszyn [5]. Jednak algorytmy sztucznej inteligencji nie są jeszcze w tym obszarze przez naukowców i praktyków docenione. Dokonując analizy stanu, nie zauważono ich szerszego stosowania do oceny ryzyka w eksploatacji środków transportu.

Oceny ryzyka w procesach eksploatacji można dokonywać w różnych aspektach. Dla potrzeb rozwiązania postawionego problemu badawczego przyjęto w metodyce postępowania, że aspekty te obejmą następujące zagadnienia:

- terminy – możliwość realizacji kontraktu (zadania transportowego) w określonym czasie,
- koszty – możliwość zrealizowania zadania przy zachowaniu optymalnych kosztów,
- technologia – opanowanie właściwej technologii transportowej zapewniającej spełnienie wymagań, zapewnienie odpowiedniej dokumentacji eksploatacyjnej, ograniczenie liczby reklamacji i niezgodności,
- technika – możliwość dysponowania niezbędnym parkiem maszynowym, oprzyrządowaniem serwisowym oraz odpowiednim wyposażeniem do pomiarów i badań,
- kompetencje personelu – zapewnienie personelu o odpowiedniej wiedzy, doświadczeniu, umiejętnościach, wykazującego właściwy poziom odpowiedzialności za eksploatację środka transportu.

Przyjmując powyższe ustalenie, w procesach eksploatacji środków transportu można dokonać następującego oznaczenia występujących ryzyk: w aspekcie terminowym ( $R_t^z$ ), w aspekcie technicznym ( $R_t^z$ ), w aspekcie technologicznym ( $R_m^z$ ), w aspekcie kompetencji personelu ( $R_k^z$ ) i w aspekcie kosztowym ( $R_c^z$ ).

W oparciu o przyjętą definicję ryzyka, jego wartość w procesie eksploatacji można obliczyć korzystając ze wzoru (1):

$$R_j^e = s_j^e \cdot p_j^e \quad (1)$$

gdzie:

$R_j^e$  - wartość ryzyka w procesie eksploatacji w  $j$ -tym aspekcie,

$s_j^e$  - wartość skutku zagrożenia w procesie eksploatacji w  $j$ -tym aspekcie,

$p_j^e$  - wartość prawdopodobieństwa wystąpienia zagrożenia w procesie eksploatacji w  $j$ -tym aspekcie.

Oszacowanie wartości skutków zagrożeń i prawdopodobieństwa ich wystąpienia, w poszczególnych aspektach oraz ustanowienie kryteriów akceptowalności ryzyka jest niezbędne przy podejmowaniu decyzji w procesach eksploatacji. Do obiektywizacji eksperckiej oceny ryzyka w procesach eksploatacji środków transportu służy macierz ryzyka (tablica 1).

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 |      |   |       |       |       |      |

Źródło: [16].

Poziom wartości 0,75 – 1 oznacza ryzyko wysokie, co w praktyce przekłada się na wysokie prawdopodobieństwo wystąpienia zagrożenia lub istotny skutek zagrożenia. Niski poziom ryzyka (0 - 0,25) występuje w przypadku małego prawdopodobieństwa wystąpienia zagrożenia i nieistotnej wartości skutku jego oddziaływania.

### 3. MODELOWANIE OCENY RYZYKA W PROCESIE EKSPLOATACJI ŚRODKÓW TRANSPORTU

W zarządzaniu ryzykiem wykorzystuje się różne metody modelowania. Dla przykładu [14]:

- modelowanie procesowe, wykorzystujące identyfikację mających zastosowanie w eksploatacji procesów i ich wzajemne powiązania,

- modelowanie matematyczne, ujmujące wszystkie istotne zjawiska w obiekcie modelowania w postaci relacji matematyczno – logicznych; jednym z rodzajów modelowania matematycznego jest modelowanie neuronowe (wykorzystujące sztuczne sieci neuronowe).

Dla potrzeb niniejszych rozważań przyjęto, że modelowanie jest procesem polegającym na dobieraniu do oryginału zamiennika, zwanego modelem, odwzorowującego badaną rzeczywistość, a następnie eksperymentowanie z nim. Modelowanie oceny ryzyka w procesach eksploatacji środków transportu charakteryzuje się koniecznością rozwiązywania problemów, które wymagają doświadczenia ekspertów, nabytego przez wieloletnią działalność w tym obszarze. Z tego powodu wykorzystać można modelowanie matematyczne z uwzględnieniem sztucznych sieci neuronowych. Modele neuronowe mogą bowiem bez trudu odwzorować zależności nieliniowe.

Model matematyczny oceny ryzyka w procesach eksploatacji środków transportu można zapisać funkcją  $\Gamma(t)$ , postaci [16]:

$$\Gamma(t) = f(y_1(t), y_2(t), \dots, y_m(t)) \quad (2)$$

gdzie:

- $\Gamma(t)$  - ocena ryzyka w chwili  $t$ ,
- $y_m(t)$  - ocena w chwili  $t$   $m$ -tego procesu związanego z wymaganiami dotyczącymi zarządzania ryzykiem w procesach eksploatacji, przy czym  $m=1,2,\dots,M$ .

Sztuczne sieci neuronowe umożliwiają uogólnianie wiedzy dla nowych i nieznanych wcześniej danych poprzez zdolność do aproksymacji wartości funkcji wielu zmiennych. Są modelami matematycznymi realizującymi przetwarzanie informacji na wzór funkcjonowania neuronów w ludzkim mózgu i mogą być wykorzystywane do rozwiązywania problemów decyzyjnych.

Dla potrzeb rozwiązania postawionego problemu badawczego, do zbudowania i nauczenia sieci, wykorzystano wyniki badań przeprowadzonych w przedsiębiorstwach transportowych i produkcyjno-usługowych w procesach ich certyfikacji (realizowanych przez Wydział Logistyki Wojskowej Akademii Technicznej i Instytut Transportu Samochodowego). Wyniki tych badań uzyskano podczas rzeczywistej oceny ryzyka w odniesieniu do ok. 400 kontraktów na realizację usług transportowych przez badane przedsiębiorstwa w okresie 10 lat eksploatacji środków transportu. Ocena ryzyka była dokonywana przez ekspertów w wymienionych aspektach w następujących obszarach:

- $R^p$  – planowanie eksploatacji,
- $R^s$  – serwis,
- $R^z$  – zakupy.

Jednym z podstawowych warunków efektywnego uczenia sieci neuronowych jest wiarygodność i jakość danych wejściowych. Wymaga się, aby dane te były reprezentatywne tzn. zawierały różne przypadki, zarówno standardowe i niestandardowe, dzięki którym sieć prawidłowo rozpoznana kolejne przykłady. Jednocześnie zostanie podniesiony poziom jakości procesu uczenia sieci neuronowej, co przełoży się na wiarygodniejsze wyniki. Dlatego też w tablicy 2 zestawiono przykładowe dane, odpowiednio sparametryzowane przez ekspertów, z wykorzystaniem macierzy ryzyka (Tablica 1 i formuły 1).

W ostatniej kolumnie Tablica 2 przedstawiono ekspercką ocenę wartości ryzyka oszacowanego w konkretnych procesach eksploatacji w chwili  $t$ , która jest daną wyjściową z sieci neuronowej. W pozostałych kolumnach zawarto oceny cząstkowe, które stanowią dane wejściowe do sieci. W wierszach natomiast, zawarto oceny cząstkowe i ocenę ogólną z przykładowych zrealizowanych usług transportowych. Zebrane dane pozwoliły na rozpoczęcie poszukiwań najlepszej struktury sieci neuronowej, przy pomocy oprogramowania komputerowego.

Tablica 2.

## Wybrane dane do zbudowania sztucznej sieci neuronowej

| Nr kontraktu | Obszar planowania eksploatacji |                           |                               |                                      |                         | Obszar serwisu           |                           |                               |                                      |                         | Obszar zakupów           |                           |                               |                                      |                         | $R_f^f$ Ocena końcowa ryzyka |
|--------------|--------------------------------|---------------------------|-------------------------------|--------------------------------------|-------------------------|--------------------------|---------------------------|-------------------------------|--------------------------------------|-------------------------|--------------------------|---------------------------|-------------------------------|--------------------------------------|-------------------------|------------------------------|
|              | $R_c^p$ Aspekt terminowy       | $R_c^t$ Aspekt techniczny | $R_m^p$ Aspekt technologiczny | $R_k^p$ Aspekt kompetencji personelu | $R_k^p$ Aspekt kosztowy | $R_c^s$ Aspekt terminowy | $R_c^t$ Aspekt techniczny | $R_m^s$ Aspekt technologiczny | $R_k^s$ Aspekt kompetencji personelu | $R_k^s$ Aspekt kosztowy | $R_c^z$ Aspekt terminowy | $R_c^t$ Aspekt techniczny | $R_m^z$ Aspekt technologiczny | $R_k^z$ Aspekt kompetencji personelu | $R_k^z$ Aspekt kosztowy |                              |
| 1            | 0                              | 0                         | 0                             | 0                                    | 0                       | 0,187                    | 0                         | 0                             | 0,06                                 | 0                       | 0,562                    | 0                         | 0                             | 0                                    | 0                       | 0,45                         |
| 2            | 0                              | 0                         | 0                             | 0                                    | 0                       | 0,06                     | 0                         | 0                             | 0,06                                 | 0                       | 0,06                     | 0                         | 0                             | 0                                    | 0                       | 0,06                         |
| 3            | 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                          |
| 4            | 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                          |
| 5            | 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                          |
| 6            | 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                         |
| 7            | 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                         |
| 8            | 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                          |
| 9            | 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                            |
| 10           | 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                         |
| 11           | 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                          | 0,25                                 | 0,25                    | 0,25                         |
| 12           | 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                         |
| 13           | 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                    | 0,3                          |
| 14           | 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                    | 0,5                          |
| 15           | 0                              | 1                         | 0                             | 0                                    | 0                       | 0                        | 0                         | 0                             | 0                                    | 0                       | 0                        | 0                         | 0                             | 0                                    | 0                       | 0,95                         |
| 16           | 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                         |

Zródło: opracowanie własne.

#### 4. WYNIKI BADAŃ

Z pośród wielu rodzajów modeli sieci neuronowych w badaniach wykorzystano perceptron wielowarstwowy (Multilayer Perceptron), sieci neuronowe o radialnych funkcjach bazowych RBF. Zdecydowano się wybrać te rodzaje sieci, ze względu na fakt, iż rozwiązują one problemy liniowe i nieliniowe, uzyskują wyniki na poziomie >90% skuteczności, jak również okazały się wystarczające do rozwiązania postawionego problemu. Zastosowano algorytmy uczące: metoda najszybszego spadku, metoda gradientów sprzężonych; metodę BFGS (*Broyden – Fletcher – Goldfarb – Shanno*).

Wykorzystując program komputerowy Statistica 12 dokonano oceny ryzyka z wykorzystaniem zdefiniowanych wcześniej obszarów i aspektów ryzyka.

Następnie sprecyzowano podstawowe parametry sieci, tj.:

- typ sieci (perceptron wielowarstwowy - MLP),
- minimalną liczbę neuronów ukrytych,
- maksymalną liczbę neuronów ukrytych,
- liczbę sieci uczących,
- liczbę sieci zachowanych,
- funkcję aktywacji neuronów ukrytych,
- funkcję aktywacji neuronów wyjściowych,
- wartości redukcji wag dla warstwy ukrytej i warstwy wyjściowej.

Po zdefiniowaniu danych i parametrów sieci przeprowadzono proces jej uczenia wykorzystując zgromadzone dane. Przykładowe wyniki tego procesu przedstawiono w Tablica 3.

Tablica 3.

**Przykładowe wyniki procesu uczenia sieci neuronowej**

| ID | Nazwa sieci | Jakość uczenia | Jakość testowania | Jakość walidacji | Algorytm uczenia | Funkcja błędu | Aktywacja (ukryte) | Aktywacja (wyjściowe) |
|----|-------------|----------------|-------------------|------------------|------------------|---------------|--------------------|-----------------------|
| 1  | MLP 15-1-1  | 0,931083       | 0,911852          | 0,916937         | BFGS 16          | SOS           | Wykładnicza        | Liniowa               |
| 2  | MLP 15-17-1 | 0,979049       | 0,970945          | 0,972700         | BFGS 76          | SOS           | Sinus              | Liniowa               |
| 3  | MLP 15-19-1 | 0,982698       | 0,980754          | 0,979320         | BFGS 81          | SOS           | Tanh               | Sinus                 |
| 4  | RBF 15-26-1 | 0,906437       | 0,890736          | 0,904472         | RBFT             | SOS           | Gaussa             | Liniowa               |
| 5  | RBF 15-18-1 | 0,895259       | 0,888949          | 0,908324         | RBFT             | SOS           | Gaussa             | Liniowa               |
| 6  | RBF 15-26-1 | 0,942438       | 0,931143          | 0,938709         | RBFT             | SOS           | Gaussa             | Liniowa               |
| 7  | RBF 15-19-1 | 0,821700       | 0,787289          | 0,792973         | RBFT             | SOS           | Gaussa             | Liniowa               |
| 8  | RBF 15-13-1 | 0,407937       | 0,513046          | 0,577352         | RBFT             | SOS           | Gaussa             | Liniowa               |
| 9  | RBF 15-23-1 | 0,914057       | 0,885796          | 0,910540         | RBFT             | SOS           | Gaussa             | Liniowa               |
| 10 | RBF 15-8-1  | 0,847965       | 0,829239          | 0,810854         | RBFT             | SOS           | Gaussa             | Liniowa               |
| 11 | RBF 15-30-1 | 0,919841       | 0,892732          | 0,909191         | RBFT             | SOS           | Gaussa             | Liniowa               |
| 12 | RBF 15-30-1 | 0,948536       | 0,921539          | 0,948110         | RBFT             | SOS           | Gaussa             | Liniowa               |
| 13 | RBF 15-20-1 | 0,977318       | 0,974517          | 0,978673         | RBFT             | SOS           | Gaussa             | Liniowa               |
| 14 | RBF 15-30-1 | 0,923014       | 0,898747          | 0,913834         | RBFT             | SOS           | Gaussa             | Liniowa               |
| 15 | MLP 15-11-1 | 0,999880       | 0,999873          | 0,999843         | BFGS 53          | SOS           | Logistyczna        | Sinus                 |
| 16 | MLP 15-22-1 | 0,927999       | 0,897803          | 0,915771         | BFGS 12          | SOS           | Liniowa            | Logistyczna           |
| 17 | RBF 15-13-1 | 0,056235       | -0,237473         | -0,347333        | RBFT             | SOS           | Gaussa             | Liniowa               |
| 18 | MLP 15-17-1 | 0,931999       | 0,913343          | 0,918417         | BFGS 15          | SOS           | Liniowa            | Wykładnicza           |


Źródło: opracowanie własne.

Wraz z określeniem danych wejściowych, zdefiniowano wielkość zbioru uczącego. Określono, że:

- 80 % danych stanowić będzie zbiór uczący wykorzystywany do modyfikacji wag,

- 10 % danych stanowiąc będzie zbiór testowy przeznaczony do bieżącego monitorowania procesu uczenia,
- 10 % danych stanowiąc będzie zbiór walidacyjny do oceny jakości sieci po zakończeniu uczenia.

Struktura najlepszej sieci przyjęła postać MLP 15-11-1, co oznacza 15 neuronów w warstwie wejściowej, 11 neuronów w warstwie ukrytej i 1 neuron w warstwie wyjściowej z funkcją błędu sumy kwadratów (SOS, *ang.* sum-of-squares) i algorytmem uczącym radialnej funkcji bazowej pod napięciem RBFT (*ang.* radial basis functions under tension). O pozytywnym wyniku uczenia sieci neuronowej świadczy m.in. wykres uczenia (rys. 1), z którego wynika, że najlepszą strukturę sieci odnaleziono w 53 epoce, w której błąd został oszacowany na poziomie 0,00011.



Rys. 1. Wykres uczenia sieci neuronowej MLP 15-11-1


Źródło: opracowanie własne.

W przypadkach uczenia i testowania sieci dokładność odwzorowania wartości ocen jest porównywalna. Można zatem uznać, iż model matematyczny dokonywania oceny ryzyka w procesach eksploatacji środków transportu, oparty na wielowarstwowej sztucznej sieci neuronowej, poprawnie odwzorowuje rzeczywiste wartości tych ocen.

Rys. 2 przedstawia wykres rozrzutu zmiennej zależnej i jej predykcji, który również świadczy o wysokiej jakości sieci.

Z wykresu można odczytać, na ile dokładnie sygnały wyjściowe sieci neuronowej odzwierciedlają rzeczywistą wartość zmiennej wyjściowej – ocenę ryzyka.





Rys. 2. Wykres rozrzutu zmiennej zależnej sieci neuronowej MLP 15-11-1  
 Źródło: opracowanie własne.

## 5. PODSUMOWANIE

W ramach badań, których przykładowe wyniki przedstawiono w niniejszym artykule, na przykładzie eksploatacji środków transportu wykorzystywanych w przedsiębiorstwach transportowych i produkcyjno - usługowych udowodniono, że sieci neuronowe można wykorzystać do modelowania i jednoznacznej oraz wiarygodnej oceny ryzyka w eksploatacji maszyn.

Przeprowadzone badania potwierdziły, że:

- stosowanie przyjętego modelu neuronowego oceny ryzyka w procesach eksploatacji środków transportu gwarantuje uzyskanie wiarygodnych, spójnych i powtarzalnych wyników oceny,
- wykorzystanie sztucznych sieci neuronowych zapewnia rozwiązanie problemów związanych z nieliniowością i wieloaspektowością oceny ryzyka w procesach eksploatacji środków transportu,
- sztuczne sieci neuronowe wymagają od odbiorcy niższego poziomu wiedzy teoretycznej do zbudowania modelu, niż w przypadku stosowania tradycyjnych metod, np. komputerowej identyfikacji obiektów i procesów, metod statystycznych, czy metod z zakresu inżynierii jakości.

Dalsze badania powinny być, zdaniem autorów, ukierunkowane na opracowanie metodyki wykorzystania sztucznych sieci neuronowych (i innych algorytmów sztucznej inteligencji m.in. z obszaru uczenia maszynowego *ang. machine learning*) do wspomagania podejmowania decyzji w takich obszarach związanych z ryzykiem, jak np.:

- niezawodność i bezpieczeństwo systemów transportowych,
- badania kontrolne pojazdów.

## Bibliografia

- [1] Heilpen S. *Podjęmowanie decyzji w warunkach ryzyka i niepewności*. Wrocław: Wydawnictwo Akademii Ekonomicznej, 2001.
- [2] Jacyna M., *Modelowanie i ocena systemów transportowych*. Warszawa: Oficyna Wydawnicza Politechniki Warszawskiej, 2009.
- [3] Jacyna-Golda I, Lewczuk K. The method of estimating dependability of supply chain elements on the base of technical and organizational redundancy of process, *Eksplatacja i Niezawodność – Maintenance and Reliability 2017*; 19(3): 382-392.
- [4] Kaczmarek T. *Zarządzanie zdylwersyfikowanym ryzykiem w świetle badań interdyscyplinarnych. Typologia i semantyka*. Warszawa: Wyższa Szkoła Zarządzania i Marketingu, 2003.
- [5] Karpenko M, Sepehri N. Neural network classifiers applied to condition monitoring of a pneumatic process valve actuator. *India: Engineering Applications of Artificial Intelligence 2002*; 15(3), 273-283.
- [6] Khakzad N, Khan F, Amyotte P. Dynamic risk analysis using bow-tie approach. *Reliability Engineering & System Safety 2012*; 104, 36-44.
- [7] Nałęcz M. *Biocybernetyka i inżynieria biomedyczna sieci neuronowe*. Warszawa: Akademicka Oficyna Wydawnicza EXIT; 6, 2000.
- [8] Niziński S. *Eksplatacja obiektów technicznych*. Radom: Wydawnictwo Instytutu Technologii Eksploatacji, 2002.
- [9] PN-EN 60300-1:2015 *Dependability management – Part 1: Guidance for management and application*.
- [10] Rutkowski L. *Metody i techniki sztucznej inteligencji*. Warszawa: PWN, 2005.
- [11] Samanta B, Al-Balushi KR. Artificial neural network based fault diagnostics of rolling element bearings using time-domain features. *Mechanical Systems and Signal Processing 2003*; 17(2), 317-328.
- [12] Ścieszka SF, Żołnierz M. *Eksplatacja maszyn. Cz.2. Budowa systemu i zarządzanie systemem eksploatacji*. Gliwice: Wydawnictwo Politechniki Śląskiej, 2012.
- [13] Sienkiewicz P, Górny P, Spustek H. *Ryzyko w dowodzeniu, zarządzaniu i inżynierii systemów, Metodologia analizy i oceny ryzyka, Modele podejmowania decyzji w warunkach niepełnej i niepewnej informacji*. Warszawa: Akademia Obrony Narodowej, 2001.
- [14] Sienkiewicz P. *Teoretyczne podstawy zarządzania ryzykiem*. Zeszyty naukowe Akademii Obrony Narodowej 2007; 2(67).
- [15] Sugier J, George J, Anders GJ. Modelling and evaluation of deterioration process with maintenance activities. *Eksplatacja i Niezawodność – Maintenance and Reliability 2013*; 15(4), 305-311.
- [16] Świdorski A. *Modelowanie oceny jakości usług transportowych*. *Prace Naukowe Politechniki Warszawskiej – Transport 2011*; 81.
- [17] Szymanek A. *Bezpieczeństwo i ryzyko w technice*. Radom: Politechnika Radomska, 2006.
- [18] Vileiniskis M, Remenyte-Priscott R. Quantitative risk prognostics framework based on Petri Net and Bow-Tie models. *Reliability Engineering & System Safety 2017*; 165, 62-73.

## NEURAL MODELING USED FOR RISK ASSESSMENT IN THE OPERATION OF TRANSPORT MEANS

**Abstract:** The article presents the problem of the use of mathematical modeling based on artificial neural networks for risk assessment in the processes of transport means operation. The issues of vehicle operation, risk theory and its evaluation as well as neural modeling have been described. The results of own research, supported by an IT tool, are presented. The research was conducted using real expert risk assessment carried out in the last 10 years at the transport and production-service enterprises as part of the certification processes carried out at the Military University of Technology and the Motor Transport Institute.

**Key words:** artificial neural networks, risk, machine operation, transport means