

Andrzej ŚWIDERSKI<sup>1</sup>  
Arkadiusz JÓŹWIAK<sup>2</sup>  
Roland JACHIMOWSKI<sup>3</sup>

<sup>1</sup>Instytut Transportu Samochodowego, Warszawa, ul. Jagiellońska 80, 03-301 Warszawa, [andrzej.swiderski@its.waw.pl](mailto:andrzej.swiderski@its.waw.pl)

<sup>2</sup>Wojskowa Akademia Techniczna, Wydział Logistyki, Warszawa, ul. Gen. Witolda Urbanowicza 2, 00-908 Warszawa, [arkadiusz.jozwiak@wat.edu.pl](mailto:arkadiusz.jozwiak@wat.edu.pl)

<sup>3</sup>Politechnika Warszawska, Wydział Transportu, Warszawa, Plac Politechniki 1, 00-661 Warszawa, [rjach@wt.pw.edu.pl](mailto:rjach@wt.pw.edu.pl)

## EKSPLOATACYJNE MIARY JAKOŚCI POJAZDÓW W ZASTOSOWANIU DO OCENY USŁUG TRANSPORTOWYCH Z WYKORZYSTANIEM SZTUCZNYCH SIECI NEURONOWYCH

**Streszczenie:** Eksploatacyjne miary jakości pojazdów są istotnym elementem wykorzystywanym do oceny realizacji usług transportowych. W praktyce mamy do czynienia z wieloma metodami związanymi z eksploatacyjną oceną pojazdów. Scharakteryzowano je w artykule. Metody sztucznej inteligencji, a zwłaszcza sztuczne sieci neuronowe, również mogą być z powodzeniem wykorzystane do tego celu, a zwłaszcza przy podejmowaniu decyzji w procesach oceny jakości maszyn, w tym pojazdów samochodowych. Zastosowanie metod, które pozwalają wspomagać proces decyzyjny na podstawie faktów jest niezmiernie istotne z punktu widzenia wiarygodności i obiektywności oceny. Metody te mogą być również wykorzystane w odniesieniu do eksploatacji pojazdów w zastosowaniu do oceny usług transportowych. W artykule przedstawiono metodę wykorzystania sztucznych sieci neuronowych do eksploatacyjnej oceny pojazdów wykorzystywanych w usługach transportowych towarów. Podstawę weryfikacji metody stanowiły badania eksperymentalne przeprowadzone w przedsiębiorstwie produkującym produkty mleczarskie, współpracującym z firmami transportowymi, dostarczającymi wyroby do produkcji. Uzyskane wyniki potwierdziły z 99-procentowym prawdopodobieństwem wysoką skuteczność proponowanej metody w dokonywaniu oceny usług transportowych z wykorzystaniem eksploatacyjnych miar jakości pojazdów.

**Słowa kluczowe:** eksploatacja pojazdów, ocena usług transportowych, miary jakości, sztuczne sieci neuronowe

### 1. Wstęp

Eksploatacyjne miary jakości pojazdów samochodowych służą m.in. wykorzystaniu do oceny realizacji usług transportowych. Istotną grupą problemów dokonania takiej oceny jest dobór odpowiedniej metody. Eksploatacyjna ocena obiektu wymaga zdefiniowania miar (mierników, wskaźników) i określenia ich wartości. Właściwe wartościowanie miar eksploatacyjnych pojazdów jest jednym z kluczowych kryteriów prawidłowego funkcjonowania całego systemu transportowego [9]. Liczbowej oceny sprawności urządzeń dokonuje się w oparciu o wartości, które pochodzą z obserwacji urządzenia podczas eksploatacji [10]. Różnorodność miar eksploatacyjnych zależy oczywiście od typu obiektu (procesu) przy czym, zazwyczaj miary te posiadają różne miana i rzędy skali co powoduje, że są wzajemnie nieporównywalne [6,11]. Porównanie miar opisujących obiekt (proces) jest możliwe dopiero po ich normalizacji. Wśród grup cech obiektów technicznych istotnych dla ich eksploatacyjnej oceny (wyznaczania ich miar i wskaźników) wyróżniono m.in.[8]:

- stan techniczny obiektu, będący miarą możliwości użytkowania obiektu w czasie,

- niezawodność w ujęciu statystycznym,
- jakość, rozumianą jako zdolność obiektu do zaspokojenia określonych potrzeb,
- funkcjonalność opisującą obiekt w sferze kontaktów z człowiekiem,
- efektywność charakteryzującą wydajność obiektu,
- obsługiwalność charakteryzującą podatność obiektu na wykonywanie czynności obsługowych,
- diagnozowalność charakteryzującą podatność obiektu na pozyskiwanie informacji o stanie technicznym.

Wyznaczanie miar wyżej wymienionych grup cech obiektów wymaga stosowania modeli matematycznych. Do najczęściej wykorzystywanych modeli w tym zakresie zalicza się modele niezawodnościowe [8, 14], modele efektywności eksploatacyjnej OEE (Overall Equipment Effectiveness) oraz modele organizacyjno - techniczne KPI (Key Performance Indicators) [17].

Model niezawodnościowy pozwala na statystyczne wyznaczanie miar eksploatacyjnych. Podstawą miar niezawodnościowych w tym modelu jest funkcja niezawodności określana jako prawdopodobieństwo poprawnej pracy obiektu w założonym czasie [14]. W praktyce modele niezawodnościowe umożliwiają określenie wskaźników odnoszących się do obiektów eksploatacji w ujęciu technicznym oraz techniczno - organizacyjnym.

Modele efektywności eksploatacyjnej skupiają miary eksploatacji za pomocą dostępności obiektu, efektywności i jakości jego działania. Model organizacyjno - techniczny KPI (Key Performance Indicators) obejmuje zbiór kluczowych miar wydajności i efektywności. Miary te określone zostały w normie EN 15341:2007 (Maintenance - Maintenance Key Performance Indicators). Norma ta zawiera 72 wskaźniki wraz ze szczegółową interpretacją elementów, które się na nie składają [15].

Określenie wartości miar cech eksploatacyjnych obiektów umożliwia w dalszej kolejności dokonanie oceny zmian tych wartości w określonym czasie. Dokonywanie oceny obiektów czy procesów wiąże się z podjęciem decyzji. Decyzje zwykle mają prowadzić do zaspokojenia całego zbioru potrzeb decydenta co powoduje konieczność porównywania możliwych rozwiązań, wariantów pod względem wielu kryteriów charakteryzujących dany obiekt czy proces. Stąd podejmowanie złożonych decyzji wymaga zastosowania metod wielokryterialnej analizy (wielokryterialnego podejmowania decyzji, ang. MCDM Multi Criteria Decision Making). Metody te odgrywają ważną rolę m.in. w diagnozie istniejących obiektów czy rozwiązań organizacyjnych [22]. Z uwagi na fakt, iż cechy obiektów czy systemów wyrażane są zazwyczaj w różnych jednostkach miary, ich stany bezwzględnie nie mogą być ze sobą bezpośrednio porównywane. Dopiero podział zestawu cech charakteryzujących dany obiekt (system), ze względu na pożądane tendencje kształtowania się ich wartości, umożliwia ujednoczenie kryteriów cząstkowych i porównywanie tych cech. Metody wielokryterialnego wspomaganie decyzji można podzielić na wywodzące się z teorii użyteczności (m.in.: UTA, UTASTAR, AHP, ANP, SMART) oraz metody oparte na relacji przewyższania (m.in.: ELECTRE, PROMETHEE, ORESTE, REGIME), które wskazują, że ze względu na określone kryterium jedno rozwiązanie jest „co najmniej tak dobre” jak drugie rozwiązanie. Metoda UTA (fr. UTilités Additives) jest oparta na zasadzie agregacji/podziału. Wykorzystuje techniki programowania liniowego w celu optymalnego określenia addytywnych funkcji wartości/użyteczności tak, aby funkcje te były jak najbardziej spójne z preferencjami decydenta [24]. Rozwinięciem metody UTA jest metoda UTASTAR. Zastosowano w niej dodatkowo dwie funkcje błędu oznaczające naruszenie dolnego i górnego krańca funkcji użyteczności grupy alternatyw przez k-ty wariant decyzyjny [24].

Metoda AHP (ang. Analytic Hierarchy Process) jest ogólnym hierarchicznym podejściem do podejmowania wielokryterialnych decyzji, które pozwala łączyć kryteria kwantyfikowane z niekwantyfikowanymi oraz obiektywnie mierzalne z subiektywnymi [11, 17, 18]. Modelowanie za pomocą hierarchicznej analizy problemu AHP jest przydatne szczególnie wtedy, gdy nie jest znana zależność funkcyjna między elementami problemu decyzyjnego,

opisanego w postaci hierarchii czynników, natomiast jest możliwy do oszacowania efekt występowania danych własności i ich efektu praktycznego. Rozszerzeniem metody AHP jest metoda ANP (ang. Analytic Network Process) [1]. Można ją zastosować do rozwiązywania bardziej złożonych problemów decyzyjnych. Konstruowany jest system komponentów istotnych dla rozpatrywanego problemu decyzyjnego w postaci sieci. Uwzględniane są tutaj nie tylko zależności pomiędzy grupami elementów czy wewnątrz nich, lecz także sprzężenia zwrotne.

Metoda SMART (ang. Simple Multi - Attribute Rating Technique) jest metodą wielu etapów, w których identyfikowani są decydenci, możliwości działania, atrybuty istotne dla danego problemu decyzyjnego, wartości i wagi poszczególnych atrybutów, podejmowana jest decyzja oraz wykonywana jest analiza jej wrażliwości [4].

Metody ELECTRE (fr. ELimination Et Choix Traduisant la REalité) [3] mają bardzo szerokie zastosowanie w różnorodnych problemach decyzyjnych. Obejmują one grupę metod (m.in. ELECTRE I, IV, IS, II, III, IV, TRI) przystosowanych do rozwiązywania różnych problemów wielokryterialnego wspomaganie decyzji. Wybór konkretnej metody zależy z jednej strony od rodzaju problemu z jakim mamy do czynienia, z drugiej zaś od rodzaju danych jakimi dysponujemy. W metodach ELECTRE przyjmuje się aksjomat ograniczonej porównywalności wariantów, którego wyrazem jest uznanie czterech podstawowych relacji: I – równoważności, P – silnej preferencji, Q – słabej preferencji oraz R – nieporównywalności. Podstawową zasadą wykorzystywaną w metodach ELECTRE jest porównywanie każdego wariantu z wszystkimi pozostałymi. W ten sposób sprawdza się, czy można uznać dany wariant za mający przewagę nad każdym z pozostałych.

Metody PROMETHEE (ang. Preference Ranking Organization METHod for Enrichment Evaluations) stanowią grupę metod podobnie jak ELECTRE [2]. W metodach PROMETHEE wykorzystuje się informacje na temat stopnia preferencji danego wariantu w stosunku do pozostałych wariantów oraz informacje na temat stopnia, w jakim pozostałe warianty są bardziej preferowane do danego wariantu.

Metoda ORESTE została opracowana dla sytuacji, gdzie alternatywy są uporządkowane według każdego kryterium i same kryteria są uszeregowane według ich znaczenia [12]. W metodzie tej stosuje się niezależne rankingi dla kryteriów oraz dla alternatyw względem każdego z kryteriów.

Metoda REGIME [12] oparta jest na analizie przewyższania i może być postrzegana jako porządkowe uogólnienie metod porównania w parach takich jak analiza zgodności. Podstawą REGIME są współczynniki zgodności  $C_{il}$  zdefiniowane jako suma wag dla kryteriów, dla których alternatywa  $a_i$  jest przynajmniej tak dobra jak  $a_l$ . Celem tej metody jest określenie znaku różnicy  $C_{il} - C_{li}$ . Jeżeli znak tej różnicy jest dodatni to alternatywa  $a_i$  jest preferowana nad alternatywą  $a_l$  i odwrotnie (gdy znak jest ujemny).

Dobór metody jest bardzo istotny z punktu widzenia informacji wyjściowej po dokonaniu oceny. Zależy również od charakteru posiadanych informacji wejściowych, ich ilości oraz wspólnych zależności, jeśli takie występują oraz informacji (celu), jaką chce się uzyskać na wyjściu. Dlatego wykorzystywane do oceny wskaźniki i mierniki poszczególnych elementów eksploatacyjnej oceny pojazdów nie wyczerpują tematu, gdyż przedstawiają jedną zmienną. Nie odzwierciedlają wzajemnych relacji poszczególnych zmiennych i siły (wielkości) tej relacji.

Do eksploatacyjnej oceny pojazdów można również wykorzystać metody, zaliczane do sztucznej inteligencji, w tym sztuczne sieci neuronowe.

Celem artykułu jest prezentacja możliwości wykorzystania sztucznych sieci neuronowych do:

- wspomaganie decyzji, związanych z eksploatacją pojazdów, wykorzystywanych w usługach transportowych, związanych z dostawami wyrobów do produkcji,

- prognozowania jakości i efektywności eksploatacyjnej pojazdów samochodowych w systemie usług transportowych.

Zastosowano takie metody badawcze, jak: analiza (wykorzystana do rozpoznania obszaru sztucznej inteligencji), modelowanie opisowe (posłużyło do sformułowania i opisanie zebranych informacji), modelowanie matematyczne, wykorzystujące sztuczne sieci neuronowe (do eksploatacyjnej oceny pojazdów samochodowych).

## 2. Aspekty eksploatacyjnej oceny usług transportowych

Usługi transportowe są niezmiennie istotnym elementem gospodarki i życia społecznego, umożliwiającym skuteczne ich funkcjonowanie. Rozwój społeczno - gospodarczy generuje potrzebę przemieszczania osób i/lub ładunków. Brak spójności między działalnością transportową i wytwórczą zdecydowanie osłabia możliwości rozwojowe. Dodatkowo, duża konkurencja w tym segmencie spowodowała, że najniższa cena przestała być gwarantem przewagi rynkowej. Rozważania te, to jedne z licznych aspektów powodujących zainteresowanie oceną usług transportowych w aspekcie eksploatacji pojazdów. Problem jakości w perspektywie dynamicznych zmian na rynku, staje się szczególnie ważny z takich względów, jak: nieustanny wzrost oczekiwań klientów, minimalizacja czasu trwania usługi, gwarancja najwyższej efektywności usługi, czy też bezpieczeństwo pojazdu i przewożonego towaru. Jednym z istotniejszych wymiarów oceny usługi transportowej jest ocena z punktu widzenia eksploatacji pojazdu. Ocena ta, to problem złożony ze względu na liczne kryteria, opisane atrybutami niemierzalnymi lub trudno mierzalnymi. Z reguły kryteria mają charakter heterogeniczny, co dodatkowo komplikuje wiarygodną ocenę. Problem ten rozwiązuje zastosowanie wielokryterialnych metod podejmowania decyzji w oparciu np. o metody heurystyczne czy teorie zbiorów rozmytych. Niestety, metody te ze względu na swoją konstrukcję matematyczną są trudne do implementacji. Z tego powodu poszukuje się prostych, praktycznych narzędzi, dających utylitarne korzyści. W sytuacji, kiedy występuje pełna znajomość reguł i mała złożoność problemu, zastosowanie znajdują dokładne algorytmy (np. modele liniowe). W przypadku częściowej lub całkowitej nieznajomości reguł i dużej złożoności problemu, zastosowanie znajdują sieci neuronowe. Ocena eksploatacyjna, ze względu na swoją złożoność i wieloaspektowość, należy do obszaru zastosowań sztucznej inteligencji.

Istnieje wiele kryteriów klasyfikacji usług transportowych. Do istotnych, które wpływają na obszary oceny, można zaliczyć: przedmiot przewozu (np. rynek przewozów pasażerskich, rynek przewozów towarowych), wykorzystywany rodzaj transportu, obszar działania (np. rynek lokalny, krajowy, międzynarodowy), siłę ekonomiczną podmiotów (rynek przewoźnika lub rynek użytkownika), itp.

W artykule podjęto próbę dokonania eksploatacyjnej oceny, której przedmiotem badań są pojazdy samochodowe.

Podstawowe cechy usług transportowych, to m.in.:

- złożoność - usługa transportowa składa się z bardzo dużej liczby elementów i relacji między tymi elementami,
- probabilizm - nie można przewidzieć wszystkich stanów i zdarzeń,
- dynamiczność - na bieżąco ingeruje się, zarówno w czasie, jak i w przestrzeni w proces realizacji usługi transportowej.

Do podstawowych uwarunkowań funkcjonowania usług transportowych można zaliczyć:

- aspekty ekonomiczno - prawne - np. system finansowy, akty prawne regulujące transport,

- aspekty techniczne - np. pojazdy, infrastruktura, urządzenia transportowe i przeładunkowe, wraz z wieloma aspektami eksploatacyjnymi,
- aspekty organizacyjne - np. zasady współpracy między przewoźnikiem a klientem, czas pracy przewoźnika.

Aspekty jakościowe realizacji usług transportowych stanowią odrębną grupę obszarów badawczych. Wyróżnić można trzy kategorie jakości [23]:

- postulowaną przez użytkowników, która określa ich żądania i życzenia dotyczące sposobu realizacji usługi transportowej,
- oferowaną przez przewoźników, czyli oferowaną podaż usług transportowych możliwych do realizacji przy aktualnym zasobie wiedzy, techniki i organizacji,
- realizowaną przez usługodawców.

Zagadnienia oceny usług transportowych rozpatruje się w różnych ujęciach. Najczęściej analizy tej dokonuje się ze względu na czas dostawy, bezpieczeństwo i niezawodność realizacji usługi oraz bezpieczeństwo i niezawodność samych pojazdów [5]. Z kolei Neo i inni dokonali analizy jakości usług świadczonych przez operatorów logistycznych i jako podstawowe wskaźniki oceny podali dokładność informacji, dokładność realizacji procesów kompletacji i terminową realizację dostaw [13].

Biorąc powyższe pod uwagę, oceny usługi transportowej można dokonać pod wieloma innymi aspektami, tj.: poniesionych kosztów, ryzyka, zasobów: ludzkich, informacyjnych czy eksploatowanych pojazdów. W zależności od wspomnianych wcześniej uwarunkowań i charakteru wykonywanej usługi aspekty te są różnie interpretowane. Chociaż w przypadku np. szacowania ryzyka, zaleca się przeprowadzenie tego procesu w określonej kolejności: określenie zakresu, identyfikacja zagrożeń i wstępne wyznaczenie konsekwencji, oszacowanie ryzyka, weryfikacja, dokumentowanie i uaktualnianie analizy [16].

Ocenę usługi transportowej można przedstawić jako funkcję postaci:

$$R_n(t) = f(w_{n,1}(t), w_{n,2}(t), \dots, w_{n,k}(t)) \quad (1)$$

gdzie:  $R_n(t)$  - ocena  $n$ -tej usługi transportowej w czasie  $t$ ,

$w_{n,k}(t)$  - ocena  $k$ -tego wymagania  $n$ -tej usługi transportowej w czasie  $t$ .

Aspekty przedstawione wyżej mogą być opisane różnymi miarami w zależności, z którego punktu widzenia dokonuje się oceny. Natomiast istotne są niezawodne, eksploatowane w trakcie realizacji usługi transportowej pojazdy. Ich jakość zależy w głównej mierze od właściwej eksploatacji, która opisywana jest przez niezawodność i gotowość. Z kolei na gotowość pojazdu składają się takie elementy, jak: nieuszkodzalność, obsługiwalność i zapewnienie środków obsługi [15]. Dlatego, na potrzeby niniejszej pracy eksploatacyjną ocenę  $n$ -tej usługi transportowej zdefiniowano jako funkcję:

$$E_n(t) = f(w_{n,u}(t), w_{n,o}(t), w_{n,w}(t), w_{n,st}(t)) \quad (2)$$

gdzie:  $E_n(t)$  - eksploatacyjna ocena  $n$ -tej usługi transportowej w czasie  $t$ ,

$w_{n,u}(t)$  - ocena wymagania nieuszkodzalności pojazdu wykonującego  $n$ -tą usługę transportową w czasie  $t$ ,

$w_{n,o}(t)$  - ocena wymagania obsługiwalności pojazdu wykonującego  $n$ -tą usługę transportową w czasie  $t$ ,

$w_{n,w}(t)$  - ocena wymagania dotycząca wieku pojazdu wykonującego  $n$ -tą usługę transportową w czasie  $t$ ,

$w_{n,st}(t)$  - ocena wymagania stanu technicznego pojazdu wykonującego  $n$ -tą usługę transportową w czasie  $t$ .

Do dokonania oceny eksploatacyjnej usług transportowych, ze względu na swoją wielopłaszczyznowość, potrzebne są narzędzia, które odnajdą zależności między zbiorami zmiennych przy dużej złożoności problemu. Narzędziem tym mogą być sztuczne sieci neuronowe. Zatem w dalszej części artykułu przedstawiono modelowanie, z wykorzystaniem tego narzędzia, oceny eksploatacyjnej pojazdów w zastosowaniu do oceny usług transportowych oraz wyniki badań własnych.

### 3. Modelowanie neuronowe

Badania dotyczące możliwości i sposobu wykorzystania sztucznych sieci neuronowych do eksploatacyjnej oceny usług transportowych przeprowadzono na bazie usług świadczonych przez zewnętrznych przewoźników na rzecz przedsiębiorstwa produkującego i dostarczającego na rynek wyroby mleczarskie. Ocenie poddano usługi transportowe realizowane na rynku krajowym o zasięgu lokalnym z wykorzystaniem pojazdów samochodowych.

W celu zastosowania sieci neuronowych do dokonania eksploatacyjnej oceny usług transportowych określono zbiór sygnałów wejściowych, zarówno ilościowych (wyrażonych w postaci liczby), jak i jakościowych (wyrażonych w postaci opisu, słowa). Miary jakości pojazdów, opisujące wymagania eksploatacyjnej oceny usług transportowych przedstawiono w tabeli 1.

Tabela. 1. Opis wymagań eksploatacyjnej oceny usługi transportowej  $E_n$

Symbol wymagania oceny	Opis wymagania eksploatacyjnej oceny usługi transportowej $E_n$
$w_{n,u}(t)$	nieuszkodzalność pojazdu - liczba uszkodzeń występujących w jednostce czasu (np. w tygodniu, miesiącu, itp.),
$w_{n,o}(t)$	obsługiwalność pojazdu – liczba godzin pojazdu w stanie obsługi,
$w_{n,w}(t)$	wiek pojazdu - przedkłada się na pozostałe charakterystyki niezawodnościowe, dlatego wymaganie to ujęto w miarach jakości pojazdu,
$w_{n,st}(t)$	stan techniczny pojazdu - charakterystyka ta wynika m.in. z pozostałych wskaźników oceny niezawodności i oceniania jest przez eksperta organoleptycznie, przyjęto oceny: bardzo dobry stan techniczny pojazdu (bdb), zadawalający (zad), niezadawalający (nzad).

Źródło: opracowanie własne.

Dla potrzeb oceny jakości usługi transportowej  $E_n(t)$  wg wymagań  $w_{n,u}(t)$ ,  $w_{n,o}(t)$ ,  $w_{n,w}(t)$  i  $w_{n,st}(t)$ , dokonano ich parametryzacji zgodnie z ustaleniami podanymi w tabelach 2 - 5.

Tabela. 2. Sparametryzowana ocena wymagania  $w_{n,u}$  - nieuszkodzalność pojazdu

Lp.	Nieuszkodzalność pojazdu [liczba/miesiąc]	Sparametryzowana ocena jakości	Opisowa ocena jakości
1	0	1	wysoki poziom jakości
2	1	0,75	bardzo dobry poziom jakości
3	2	0,5	dobry poziom jakości
4	3	0,25	niski poziom jakości
5	4	0	nieakceptowalny poziom jakości

Źródło: opracowanie własne.

Tabela. 3. Sparametryzowana ocena wymagania  $w_{n,o}$  - obsługiwalność pojazdu

Lp.	Obsługiwalność pojazdu [liczba godzin]	Sparametryzowana ocena jakości	Opisowa ocena jakości
1	0	1	wysoki poziom jakości
2	0-1	0,75	bardzo dobry poziom jakości
3	2-5	0,5	dobry poziom jakości
4	6-10	0,25	niski poziom jakości
5	>10	0	nieakceptowalny poziom jakości

Zródło: opracowanie własne.

Tabela. 4. Sparametryzowana ocena wymagania  $w_{n,w}$  – wiek pojazdu

Lp.	Wiek pojazdu [w latach]	Sparametryzowana ocena jakości	Opisowa ocena jakości
1	0-5	1	wysoki poziom jakości
2	6-12	0,5	dobry poziom jakości
3	>12	0	nieakceptowalny poziom jakości

Zródło: opracowanie własne.

Tabela. 5. Sparametryzowana ocena wymagania  $w_{n,st}$  – stan techniczny pojazdu

Lp.	Stan techniczny pojazdu	Sparametryzowana ocena jakości	Opisowa ocena jakości
1	bardzo dobry (bdb)	1	wysoki poziom jakości
3	zadawalający (zad)	0,5	dobry poziom jakości
5	nie zadawalający (nie)	0	nieakceptowalny poziom jakości

Zródło: opracowanie własne.

Do dokonywania oceny poszczególnych wymagań, eksperci przypisali wagi charakterystykom w skali (0-10), gdzie 0 oznacza mało istotne, 10 oznacza bardzo istotne. Wymaganiom przypisano następujące wartości wag:

- $w_{n,u}$  – 8,
- $w_{n,o}$  – 3,
- $w_{n,w}$  – 5,
- $w_{n,st}$  – 5.

Przy tak zdefiniowanych wymaganiach oceny eksploatacyjnej, użytkownicy pojazdów i eksperci dokonywali oceny poszczególnych wymagań. Zebrano dane z eksploatacji (z realizacji 812 usług transportowych zrealizowanych w ciągu 5 ostatnich lat dla potrzeb dostaw wyrobów do produkcji). Dane te stanowiły punkt wyjścia do rozpoczęcia badań (tabela 6). Na podstawie średniej ważonej poszczególnych wymagań dokonano eksploatacyjnej oceny jakości usług transportowych (pozytywna lub negatywna). Poziom jakości uznany jako zadawalający przyjęto na poziomie 0,6 i więcej.

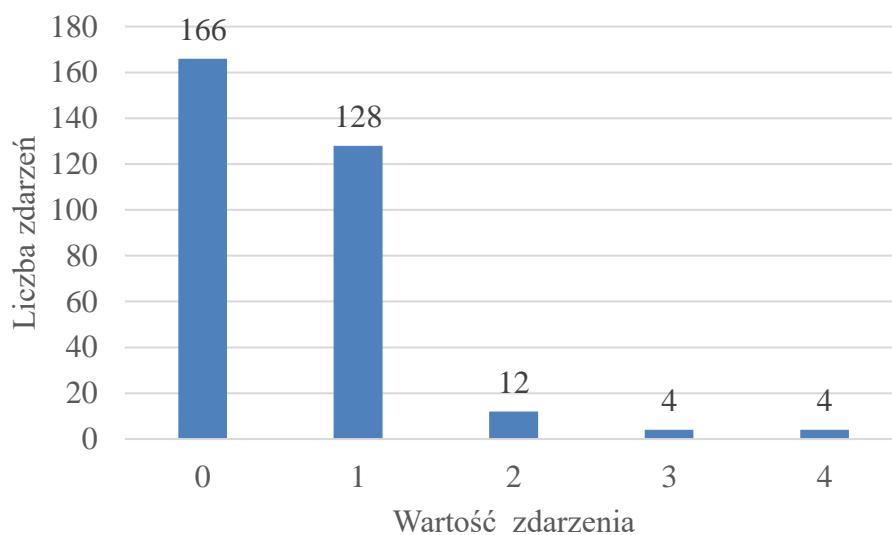
Tabela. 6. Przykładowe dane do uczenia sieci neuronowej

Lp.	Nieuszkodzalność pojazdu	Obsługiwalność pojazdu	Wiek pojazdu	Stan techniczny pojazdu	Ocena (średnia ważona)	Ocena
	liczba/miesiąc	liczba godzin/miesiąc	lata	bdb/zad/nz ad		
1.	0	0	1	bdb	<b>1,00</b>	<b>Pozytywna</b>
2.	1	1	3	bdb	<b>0,87</b>	<b>Pozytywna</b>
3.	0	0	6	bdb	<b>0,88</b>	<b>Pozytywna</b>

Lp.	Nieuszkodzalność pojazdu	Obsługiwalność pojazdu	Wiek pojazdu	Stan techniczny pojazdu	Ocena (średnia ważona)	Ocena
	liczba/miesiąc	liczba godzin/miesiąc	lata	bdb/zad/nz ad		
4.	1	1	6	bdb	<b>0,75</b>	<b>Pozytywna</b>
5.	1	1	7	zad	<b>0,63</b>	<b>Pozytywna</b>
6.	0	0	7	zad	<b>0,76</b>	<b>Pozytywna</b>
7.	1	6	8	zad	<b>0,56</b>	<b>Negatywna</b>
8.	0	0	8	zad	<b>0,76</b>	<b>Pozytywna</b>
9.	0	0	8	bdb	<b>0,88</b>	<b>Pozytywna</b>
10.	1	6	11	nzad	<b>0,44</b>	<b>Negatywna</b>
11.	0	0	11	nazd	<b>0,64</b>	<b>Pozytywna</b>
12.	2	8	12	zad	<b>0,46</b>	<b>Negatywna</b>
13.	0	0	13	zad	<b>0,64</b>	<b>Pozytywna</b>
14.	1	2	13	nazd	<b>0,36</b>	<b>Negatywna</b>

Źródło: opracowanie własne.


Poniżej przedstawiono strukturę otrzymywanych wyników badań, wg poszczególnych wymagań (rys. 1-4).




Rys. 1. Wyniki badań wymagania  $w_{n,u}$  – nieuszkodzalność pojazdu

Źródło: opracowanie własne.






Rys. 2. Wyniki badań wymagania  $w_{n,o}$  – obsługiwalność pojazdu  
 Źródło: opracowanie własne.



Rys. 3. Wyniki badań wymagania  $w_{n,w}$  – wiek pojazdu  
 Źródło: opracowanie własne.



Rys. 4. Wyniki badań wymagania  $w_{n,st}$  – stan techniczny pojazdu

Źródło: opracowanie własne.

Na podstawie powyższych danych otrzymano 540 ocen pozytywnych i 272 ocen negatywnych.

Spośród wielu rodzajów sieci neuronowych oraz wielu algorytmów ich uczenia w dalszych badaniach wykorzystano perceptron wielowarstwowy (Multilayer Perceptron) i algorytmy uczące: metoda najszybszego spadku, metoda gradientów sprzężonych; metodę BFGS (*Broyden – Fletcher – Goldfarb – Shanno*). Wykorzystana sieć neuronowa należy do grup:

- tzw. sieci nadzorowanych, gdzie proces uczenia odbywa się pod nadzorem nauczyciela (wśród sygnałów wychodzących jest sygnał wzorcowy),
- sieci jednokierunkowych, gdzie przepływ sygnałów (informacji) odbywa się w jedną stronę (od wejścia do wyjścia sieci neuronowej).

Wykorzystując program komputerowy Statistica 12 dokonano oceny usług transportowych z wykorzystaniem zdefiniowanych wcześniej eksploatacyjnych miar jakości pojazdów.

Określono zatem następujące sygnały:

- wejściowe ilościowe:  $w_{n,u}(t)$ ,  $w_{n,o}(t)$ ,  $w_{n,w}(t)$ ,
- wejściowe jakościowe:  $w_{n,st}(t)$ ,
- wyjściowe ilościowe:  $E_n(t)$ .

Wraz ze wskazaniem danych wejściowych, zdefiniowano wielkości zbiorów. Określono, że:

- 80 % - danych stanowić będzie zbiór uczący wykorzystywany do modyfikacji wag,
- 10 % - zbiór testowy przeznaczony do bieżącego monitorowania procesu uczenia,
- 10 % - zbiór walidacyjny do oceny jakości sieci po zakończeniu procesu uczenia.


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 uczenia sieci neuronowej wykorzystując zgromadzone dane. Przykładowe wyniki tego procesu przedstawiono w tabeli 7.

Przy tak określonych wymaganiach i przeprowadzeniu procesu uczenia, struktura najlepszej sieci przyjęła postać MLP 6-3-1, co oznacza 6 neuronów w warstwie wejściowej, 3 neurony w warstwie ukrytej i 1 neuron w warstwie wyjściowej (rys. 5).



Rys. 5. Struktura badanej sieci MLP 6-3-1

Źródło: opracowanie własne.

Jakość uczenia sieci MLP 6-3-1 została oszacowana na poziomie 99,6% prawdopodobieństwa wskazania poprawnej oceny (odpowiedzi), jakość testowania na poziomie 99,7%, co oznacza, że prawie wszystkie próby w tym zbiorze zostały prawidłowo przyporządkowane i jakość walidacji określono na poziomie 99,4%. Najlepszym algorytmem uczenia okazał się algorytm BFGS 148 (liczba 148 oznacza, liczbę epok, jakich sieć potrzebowała do przeprowadzenia procesu uczenia i odnalezienia najlepszej sieci, w której błąd uczenia był najmniejszy).

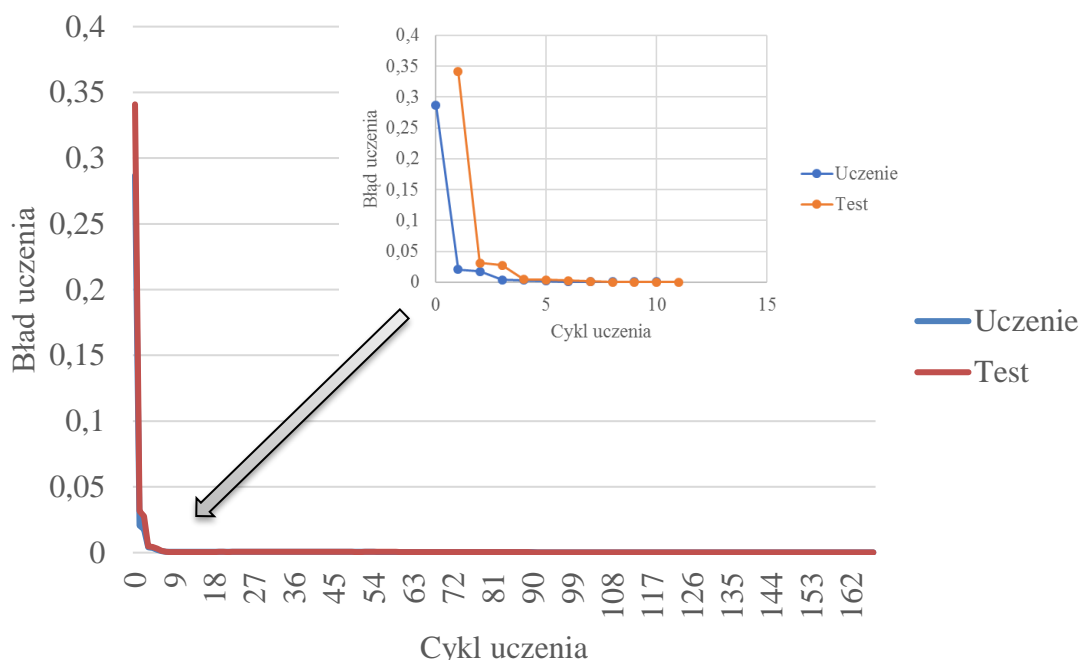
Tabela. 7. Przykładowe wyniki procesu uczenia sieci neuronowej

ID	Nazwa sieci	Jakość uczenia	Jakość testowania	Jakość walidacji	Algorytm uczenia	Funkcja błędu	Aktywacja ukryta	Aktywacja wyjściowa
1	MLP 6-5-1	0,988	0,992	0,989	BFGS 55	SOS	Logistyczna	Logistyczna
2	MLP 6-4-1	0,988	0,992	0,989	BFGS 98	SOS	Logistyczna	Tanh
3	MLP 6-6-1	0,984	0,990	0,991	BFGS 10	SOS	Liniowa	Liniowa
4	MLP 6-7-1	0,984	0,991	0,990	BFGS 8	SOS	Liniowa	Liniowa
5	MLP 6-8-1	0,983	0,991	0,991	BFGS 10	SOS	Liniowa	Liniowa
6	MLP 6-4-1	0,983	0,992	0,991	Najszybszego spadku 30	SOS	Tanh	Liniowa
7	MLP 6-4-1	0,987	0,993	0,989	BFGS 47	SOS	Logistyczna	Wykładnicza
8	MLP 6-8-1	0,987	0,992	0,987	BFGS 48	SOS	Logistyczna	Logistyczna
9	MLP 6-7-1	0,990	0,993	0,989	BFGS 63	SOS	Logistyczna	Liniowa
10	MLP 6-3-1	0,996	0,997	0,994	BFGS 148	SOS	Tanh	Liniowa
11	MLP 6-8-1	0,983	0,991	0,991	BFGS 9	SOS	Liniowa	Liniowa
12	MLP 6-4-1	0,985	0,992	0,988	Gradienty sprzężone 27	SOS	Tanh	Liniowa
13	MLP 6-6-1	0,977	0,984	0,990	BFGS 12	SOS	Logistyczna	Sinus
14	MLP 6-4-1	0,981	0,984	0,990	BFGS 23	SOS	Sinus	Sinus
15	MLP 6-6-1	0,981	0,988	0,990	BFGS 23	SOS	Sinus	Sinus
16	MLP 6-10-1	0,996	0,995	0,997	BFGS 87	SOS	Tanh	Liniowa
17	MLP 6-5-1	0,991	0,995	0,990	BFGS 86	SOS	Tanh	Tanh
18	MLP 6-8-1	0,985	0,992	0,988	BFGS 16	SOS	Wykładnicza	Logistyczna
19	MLP 6-14-1	0,991	0,993	0,990	BFGS 47	SOS	Tanh	Wykładnicza
20	MLP 6-1-1	0,976	0,983	0,990	BFGS 16	SOS	Liniowa	Sinus
21	MLP 6-1-1	0,985	0,992	0,987	BFGS 39	SOS	Wykładnicza	Wykładnicza

Źródło: opracowanie własne.

#### 4. Weryfikacja wybranej sieci neuronowej MLP 6-3-1

O pozytywnym wyniku uczenia sieci neuronowej świadczy m.in. wykres uczenia (rys. 6), z którego wynika, że najlepszą strukturę sieci odnaleziono w 148 epoce, w której udział błędnych odpowiedzi wynosi poniżej 1 %, a błąd został oszacowany na poziomie 0,0002.



Rys. 6. Wykres uczenia sieci neuronowej MLP 6-3-1  
Źródło: opracowanie własne.


Macierz pomyłek przedstawiono w tabeli 8. Wskazuje ona dokładnie, ile przypadków danej oceny zostało zakwalifikowanych przez sieć do oceny pozytywnej (powyżej progu 0,6) lub negatywnej (poniżej progu 0,6). Z tabeli 8 wynika, iż na 432 oceny pozytywne, sieć prawidłowo przyporządkowała 408 wskazań, natomiast prawidłowo wskazała wszystkie oceny negatywne.

Tabela. 8. Macierz pomyłek sieci neuronowej MLP 6-3-1

Lp.		Decyzja - negatywna	Decyzja - pozytywna	Decyzja - wszystkie
1	Razem	220	432	652
2	Poprawne	220	408	628
3	Niepoprawne	0	24	24
4	Poprawne (%)	100%	94%	96%
5	Niepoprawne (%)	0%	6%	4%

Źródło: opracowanie własne.

Kolejną istotną cechą badanej sieci neuronowej jest rozkład reszt przedstawiony na rys. 7, czyli różnic między zmienną wyjściową i jej predykcją.



Rys. 7. Rozkład reszt sieci neuronowej MLP 6-3-1

Źródło: opracowanie własne.

Z histogramu można odczytać, iż reszty mają rozkład normalny wokół zera z naciskiem na wartości ujemne. Zdecydowana większość ocen została dokonana z błędem na poziomie -0,03-0.

Ostatnim etapem weryfikacji sieci neuronowej są przewidywania dla nowych danych wejściowych. Prób, które do tej pory nie pojawiły się w żadnym zbiorze. Aby otrzymać nowe eksploatacyjne oceny jakości usługi transportowej, uzupełniono wartości wszystkich sygnałów wejściowych do sieci neuronowej, na podstawie których został wygenerowany sygnał wyjściowy, czyli eksploatacyjna ocena (ilościowa) usługi transportowej. Po wprowadzeniu danych do sieci, otrzymano wyniki końcowe. Tabela 9 zawiera przewidywania dla nowych danych na podstawie sieci neuronowej MLP 6-3-1.

Tabela. 9. Przewidywania dla nowych danych sieci MLP 6-3-1

Lp.	Nieuszkodzalność pojazdu	Obsługiwalność pojazdu	Wiek pojazdu	Stan techniczny pojazdu	Ocena końcowa
1	0	0	3	bdb	0,99
2	1	5	3	bdb	0,863
3	1	2	5	zad	0,726
4	2	10	7	zad	0,552
5	1	5	10	nzad	0,458

Źródło: opracowanie własne.

Uzyskane wyniki wskazują na możliwość wykorzystania sieci neuronowych, w tym przypadku jednowarstwowej sieci wielowarstwowej do dokonywania eksploatacyjnej oceny jakości usług transportowych. Zarówno liczba, jak i rodzaj danych (ilościowe lub jakościowe) nie wpływają na osiągnięcie wysokich wyników na poziomie 98-99% skuteczności. Na podstawie zgromadzonych danych z przeszłości, sieć neuronowa umożliwia podejmowanie decyzji, generowanie oceny z bieżącej lub przyszłej eksploatacji.

## 5. Podsumowanie

W literaturze przedmiotu badań zdefiniowanych jest wiele różnych metod i modeli (najczęściej wielokryterialnych) do dokonywania oceny eksploatacji pojazdów i systemów technicznych. Scharakteryzowano je we wstępie artykułu. Są one w praktyce powszechnie wykorzystywane. Doświadczenie autorów oraz przeprowadzona analiza stanu wskazuje, że sieci neuronowe nie są jeszcze wykorzystywane powszechnie do eksploatacyjnej oceny pojazdów w zastosowaniu do usług transportowych. Sieci neuronowe są stosowane w eksploatacji, lecz w innym zakresie [7, 19, 20, 21].

Uzyskane wyniki przeprowadzonych badań w przedsiębiorstwie produkującym wyroby mleczarskie oraz w firmach transportowych kooperujących z tym przedsiębiorstwem wskazują na możliwość zastosowania sztucznych sieci neuronowych do dokonywania oceny pojazdów wykorzystywanych przy realizacji usług transportowych, z wykorzystaniem eksploatacyjnych miar jakości. W przypadku negatywnych ocen istnieje możliwość bezwzględnego podjęcia działań naprawczych. Na tej podstawie można prognozować przyszłe przewidywania dla danych z bieżącej eksploatacji.

Zaproponowane eksploatacyjne miary jakości wynikały z potrzeb badanego przedsiębiorstwa. W praktyce mogą być one dobierane w różny sposób, w zależności od celu prowadzonych analiz.

Sieci neuronowe okazały się więc przydatne jako narzędzie do:

- wspomagania decyzji, związanych z eksploatacją pojazdów, wykorzystywanych w usługach transportowych, związanych z dostawami wyrobów do produkcji,
- prognozowania jakości i efektywności eksploatacyjnej pojazdów samochodowych w systemie usług transportowych.

Zatem cel przeprowadzonych badań został osiągnięty.

Zastosowanie sieci neuronowych w eksploatacji może być szersze. Na przykład do oceny ryzyka nie tylko eksploatacyjnego, ale też związanego z niezawodnością i bezpieczeństwem użytkowania pojazdów (nie tylko samochodowych) i innych maszyn oraz z bezpieczeństwem realizacji samych usług transportowych.

Przykład obliczeniowy zaprezentowany w artykule oddaje zatem istotę zastosowania sztucznych sieci neuronowych do oceny zagadnień związanych z eksploatacją. Jest to jeden z możliwych punktów wyjścia do prowadzenia dalszych badań w perspektywie zastosowania sieci neuronowych w tym obszarze.

## LITERATURA:

- [1] Adamus W., Gręda A., Wspomaganie decyzji wielokryterialnych w rozwiązywaniu wybranych problemów organizacyjnych i menedżerskich, „Badania operacyjne i decyzje” 2005, Nr 2.
- [2] Brans J.P., Mareschal B., Promethee methods, [in:] Figueira J., Greco S., Ehrgott M. (ed.), Multiple Criteria Decision Analysis: State of the Art Surveys, Springer Verlag, Boston, Dordrecht, London, 2005.
- [3] Figueira J., Mousseau V., Roy B. ELECTRE methods, [in:] J. Figueira, S. Greco, and M. Ehrgott (eds.), Multiple Criteria Decision Analysis: State of the Art Surveys, Springer Verlag, Boston, Dordrecht, London, 2005.
- [4] Goodwin P., Wright G., Analiza decyzji, Wolters Kluwer Polska, Warszawa 2011 Hurley W.J., The analytic hierarchy process: a note on an approach to sensitivity which preserves rank order, „Computers & Operations Research” 2001, No. 28.

- [5] Grigoroudis E., Siskos Y., A survey customer satisfaction barometers: Some results from the transportation-communications sector. *European Journal of Operational Research* 152, 2004, pp. 334-353.
- [6] Jacyna-Gołda I, Lewczuk K., The method of estimating dependability of supply chain elements on the base of technical and organizational redundancy of process. *Eksploatacja i Niezawodność – Maintenance and Reliability* 2017; 19 (3): 382–392, <http://dx.doi.org/10.17531/ein.2017.3.9>.
- [7] Karpenko M., Sepehri (2002), Neural network classifiers applied to condition monitoring of a pneumatic process valve actuator. *Engineering Applications of Artificial Intelligence*, Vol. 15, No. 3, pp. 273-283.
- [8] Kaźmierczak J., *Eksploatacja systemów technicznych*. Gliwice: Wydawnictwo Politechniki Śląskiej, 2000.
- [9] Knopik L, Migawa K., Multi-state model of maintenance policy. *Eksploatacja i Niezawodność – Maintenance and Reliability* 2018; 20 (1): 125–130, <http://dx.doi.org/10.17531/ein.2018.1.16>.
- [10] Kornacki A., Sokołowska E., The estimation of smooth operation time until failure with the application of the Akaike Information Criterion (AIC). *Eksploatacja i Niezawodność - Maintenance and Reliability* 2010; 1 (45): 69-76.
- [11] Loska A., Exploitation assessment of selected technical objects using taxonomic methods, *Eksploatacja i Niezawodność - Maintenance and Reliability* 2013, vol 15, No.1.
- [12] Martel J.M., *Other Outranking Methods*, [w:] *Multiple Criteria Decision Analysis: State of the Art Surveys*, J. Figueira, S. Greco, and M. Ehrgott, editors, Springer Verlag, Boston, Dordrecht, London, 2005.
- [13] Neo H.-Y., Xie M., Tsui K.\_l., Service quality analysis: case study of a 3PL company. *International Journal of Logistics Systems and Management* 1(1), 2004, p. 64-80.
- [14] Niebel W.B. *Engineering Maintenance Management*. Second edition. New York: Marcel Dekker Inc., 1994.
- [15] PN-EN 15341:2007 - Maintenance - Maintenance Key Performance Indicators.
- [16] PN-EN 60300-1:2015 Dependability management – Part 1: Guidance for management and application.
- [17] Saaty T. *Decision making for Leaders The Analytic Hierarchy Process for decisions in a complex world*, University of Pittsburgh, RWS Publications, Pittsburgh 2001.
- [18] Saaty T. *The Analytic Hierarchy Process*. RWS Publications. Pittsburgh 1998.
- [19] Samanta B. (2004), Gear Fault Detection Using Artificial Neural Network and Support Vector Machines with Genetic Algorithms. *Mechanical Systems and Signal Processing*, Vol. 18, pp. 625-644.
- [20] Samanta B., Al-Balushi K.R. (2003) Artificial neural network based fault diagnostics of rolling element bearings using time-domain features. *Mechanical Systems and Signal Processing*, Vol. 17, Issue 2, pp. 317-328.
- [21] Samanta B., Al-Balushi K.R., Al-Araimi S.A. (2001), Use of genetic algorithm and artificial neural network form gear condition diagnostics. *Proc. of COMADEM*, University of Manchester, pp. 449-456.
- [22] Szudrowicz M., Layered composite increasing the resistance of patrol and intervention vehicles to the impact of improvised explosive devices (iEd) from below. *Eksploatacja i Niezawodność – Maintenance and Reliability* 2018; 20 (1): 9–15, <http://dx.doi.org/10.17531/ein.2018.1.2>.
- [23] Świdorski A, *Modelowanie oceny jakości usług transportowych*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa, 2011.
- [24] Yannis Siskos, Evangelos Grigoroudis, Nikolaos F Matsatsinis, *Multiple criteria decision analysis: State of the art surveys*, Springer New York, 2005.