

# **6. PROGNOZY OSTRZEGAWCZE WYSTĄPIENIA OPÓŹNIENIA TERMINU ZAKOŃCZENIA BUDOWY UZYSKANE ZA POMOCĄ SZTUCZNYCH SCIECI NEURONOWYCH**

**Hubert Anysz<sup>1</sup>**

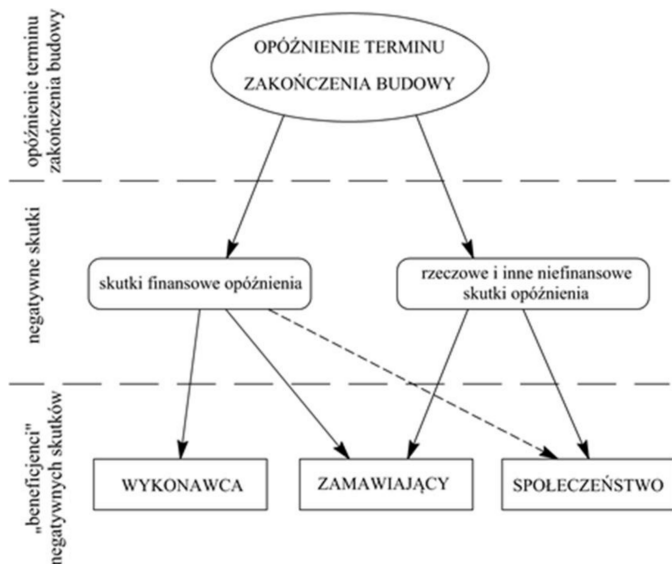
## **6.1. WPROWADZENIE**

Realizacja obiektu budowlanego, która jest oceniana – po jej zakończeniu – przez wszystkich interesariuszy jako sukces, powinna mieścić się w zaplanowanym limicie kosztów jak i czasu (Skorupka i in., 2012). Osiągnięcie rozumianego w ten sposób sukcesu, nie wynika z potrzeby prestiżu, ale jest współczesnym wymogiem efektywności. Przedsiębiorstwa, które nie działają w sposób efektywny przestają istnieć. Budownictwo – jako wyodrębniony dział gospodarki – cechuje specyficzny zestaw występujących łącznie uwarunkowań, tj. duże zapotrzebowanie na środki finansowe, silna zależność od warunków atmosferycznych, unikalny charakter każdego z budowanych obiektów, długi czas realizacji obiektów (Cieszyński, 2006; Marcinkowski, 2016). Z tych, wyżej wymienionych względów, tak trudnym jest wybudowanie obiektu za zaplanowaną cenę, w zaplanowanym czasie. Stąd wynika konieczność sporządzania szczegółowych projektów realizacji przedsięwzięcia i uwzględniania w nich możliwości wystąpienia utrudnień. Wiele z decyzji dotyczących planowanej budowy jest podejmowanych jeszcze przed przystąpieniem wykonawcy do realizacji obiektu. Prognozy opóźnienia terminu zakończenia budowy, zależne od przyjętego wariantu realizacji mogą stać się cenną informacją pozwalającą na wybór wariantu, w którym prawdopodobieństwo wystąpienia dużego opóźnienia jest niższe niż w pozostałych wariantach. Przeciwdziałanie opóź-

---

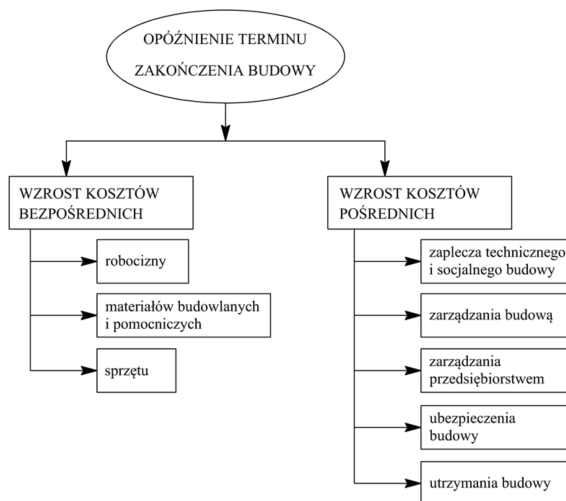
<sup>1</sup>Politechnika Warszawska, Wydział Inżynierii Lądowej, e-mail: h.anysz@il.pw.edu.pl

nieniem jest bardzo istotnym zagadnieniem ze względu na rozległe i dotkliwe ich skutki (rys. 1).



Rys. 1. Wpływ opóźnienia zakończenia budowy. Źródło: Anysz, 2017.

Późniejsze niż planowane zakończenie budowy obiektu sprawia, iż inwestor musi finansować budowę dłużej niż planował (co z reguły zwiększa jego koszty



Rys. 2. Wpływ opóźnienia zakończenia budowy na wzrost kosztów wykonawcy. Źródło: Anysz, 2017.

finansowe) i później zaczyna odnosić korzyści z nowego obiektu. Wydłużenie czasu trwania budowy zwiększa także właściwie wszystkie grupy kosztów (rys. 2), które ponosi wykonawca (Anysz, 2012).

W przypadku budowy obiektów finansowanych z budżetu państwa negatywne skutki opóźnień dotyczą także społeczności, której dany obiekt (droga, szpital, szkoła) ma służyć. Dla opóźnionych inwestycji drogowych możliwe jest obliczenie utraconych oszczędności, których nie uzyskano z powodu późniejszego niż planowano oddania drogi do użytku (IBDiM, 2008).

## 6.2. PRZYGOTOWANIE DO BUDOWY MODELU PROGNOSTYCZNEGO

Przewidywanie stanu i przebiegu przyszłych zdarzeń oparte na racjonalnych przesłankach określane jest jako prognozowanie (Cieślak, 1977; Filasiewicz 1977). Przedmiotem prognozowania są najczęściej zjawiska i procesy gospodarcze (Nowak, 1988). Stosując systematykę prognoz (Zeliaś i in., 2013) można stwierdzić, że prognozowanie terminu zakończenia budowy jeszcze przed wyborem wykonawcy robót będzie prognozą:

- krótko- lub średnioterminową (horyzont prognoz średnioterminowych określany jest na dwa, do pięciu lat),
- operacyjną,
- ostrzegawczą,
- punktową (w odróżnieniu od przedziałowej; prognozowana jest konkretna wartość, a nie przedział wartości)
- ex post (część danych historycznych nie jest wykorzystywana w procesie tworzenia modelu prognostycznego, a wykorzystywana jest do jego oceny)
- mikroekonomiczną.

W literaturze można znaleźć powtarzającą się kolejność działań niezbędnych do przygotowania użytecznych prognoz (Nowak, 1998, Zeliaś i in., 2013). Obejmuje ona następujące etapy:

- zidentyfikowanie obiektu gospodarczego, użytkownika prognoz,
- określenie celu prognozowania,
- zdefiniowanie zjawiska gospodarczego – przedmiotu prognoz,
- wskazanie czynników wpływających na prognozowane zjawisko,
- ustalenie okresu prognozy,
- wybór danych wejściowych,
- zebranie danych statystycznych,
- wybór narzędzia prognostycznego.

Po wykonaniu wszystkich powyższych czynności można dopiero przystąpić do etapu obliczeniowego.

### 6.2.1. ZJAWISKO GOSPODARCZE, UŻYTKOWNIK PROGNOZY, OKRES I CEL PROGNOZY

Zjawiskiem gospodarczym – przedmiotem analiz – jest budowa dróg ekspresowych i autostrad w Polsce. Opóźnienia odnotowywane na tych budowach nie są niczym niespotykanym w budownictwie, jednak ze względu na charakter tych inwestycji informacja o niedotrzymaniu terminu ich zakończenia jest powszechna. Badania nad przyczynami opóźnień i samo prognozowanie zawężono do tej gałęzi budownictwa ze względu na oczekiwanie, iż prognozy dotyczące opóźnień w realizacji innego typu obiektów (mieszkalnych budynków wielorodzinnych, czy hal produkcyjnych) mogą wymagać zastosowania innego zestawu predyktorów, niż dla obiektów drogowych.

Założono, że budowany model prognostyczny będzie mógł być wykorzystywany przez zamawiających wykonanie (lub zaprojektowanie i wybudowanie) dróg ekspresowych i autostrad na etapie wyboru wykonawcy robót, czyli jeszcze przed przystąpieniem do realizacji zadania.

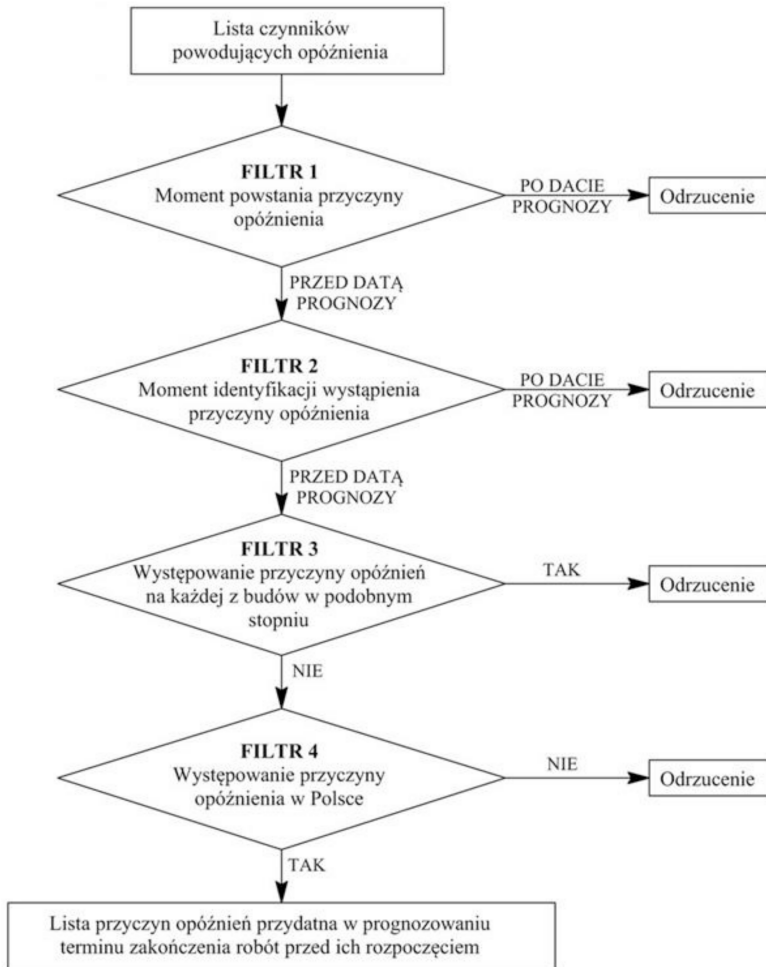
Prognoza opóźnienia terminu zakończenia budowy odcinka drogi, zależna m.in. od potencjału technicznego, zasobów jakimi dysponuje oferent, a także od proponowanej ceny za wykonanie prac może posłużyć zamawiającemu jako jedno z kryteriów wyboru wykonawcy. W ramach tego kryterium, najwyżej punktowane powinny być oferty, których parametry użyte w modelu dałyby najmniejsze prognozowane opóźnienia terminu zakończenia robót. Drugim możliwym zastosowaniem takich prognoz jest przypadek, gdy dla danych z każdej ze złożonych ofert model pokazywałby bardzo duże prognozowane opóźnienie. To dla zamawiającego oznaczałoby, że prawdopodobnie należy zmienić inne (niż sam wykonawca) parametry planowanej budowy np. wydłużyć planowany czas trwania budowy lub podzielić zadanie na krótsze odcinki.

Wstępna analiza realizowanych odcinków dróg i autostrad pokazała, że planowany czas ich realizacji waha się od kilku do kilkudziesięciu miesięcy. Uwzględniając także czas realizacji obiektów drogowych po upływie planowanych terminów ich zakończenia można z pewnością określić horyzont prognoz jako średnioterminowy (2 do 5 lat).

### 6.2.2. IDENTYFIKACJA CZYNNIKÓW WPŁYWAJĄCYCH NA OPÓŹNIENIA

Można znaleźć wiele prac krajowych (Leśniak i Plebankiewicz, 2010; Leśniak, 2012; Czarnigowska i Sobotka, 2010 i 2013; Czarnigowska i in., 2006; Dytczak i in., 2014) i zagranicznych (m.in. Ogunlana i in., 1996; Abisunga i in., 2014; Sambasivan i in., 2007), których autorzy poszukiwali przyczyn opóźnień w realizacji kontraktów budowlanych dokonując analiz i badając opinie zaangażowanych w realizację obiektów budowlanych inwestorów, wykonawców, inspektorów nadzoru. Także autor niniejszego rozdziału podejmował tę tematykę przeprowadzając badania wśród inżynierów zrzeszonych w Mazowieckiej Izbie Inżynierów Budow-

nictwa (Anysz i Zbiciak; 2013). Wszystkie zidentyfikowane przyczyny opóźnień zostały zebrane w rozprawie doktorskiej (Anysz, 2017). Ich liczba – 142 – była zbyt duża, by wszystkie mogły stanowić zmienne niezależne prognoz. Poddano je więc procesom filtracji opisanym na rys. 3. Znaczna liczba przyczyn powstawania opóźnień została odrzucona ze względu na moment identyfikacji przyczyn. Do wykonania prognoz przed wyborem wykonawcy robót nieprzydatne są czynniki identyfikowane zwykle podczas realizacji obiektu. Odrzucono także te, które nie różnicowały budów (np. doświadczenie inwestora; zamawiającym wszystkich odcinków dróg ekspresowych i autostrad w Polsce jest skarb państwa reprezentowany przez Generalną Dyрекcję Dróg Krajowych i Autostrad – GDDKiA) lub



Rys. 3. Wpływ opóźnienia zakończenia budowy na wzrost kosztów wykonawcy.  
Źródło: Anysz, 2017.

nie występowały w Polsce (np. zagrożenia militarne). Z listy 19-tu nieodrzuconych czynników wybrano 12 najbardziej istotnych, dla których możliwe było – w dającym się przewidzieć czasie – zebranie konkretnych wartości. Wybrane do dalszych analiz czynniki – przyczyny powstawania opóźnień – przypisano do czterech następujących grup czynników:

- warunki kontraktowe,
- cechy planowanego obiektu
- makroekonomiczne,
- cechy wykonawcy.

Predyktory zebrane w tabeli 1 nie są wprost czynnikami wskazywanymi przez respondentów opisanych wcześniej badań, a ich reprezentacją. Sposób w jaki stworzono reprezentację oryginalnych czynników może ilustrować następujący przykład: dla trzech czynników mogących powodować opóźnienia budowy wskazywanych w badaniach tj.

- dużego natężenia ruchu drogowego na budowie i związanych z tym ograniczeń,
- ograniczonego dostępu do placu budowy,
- ograniczonego terenu budowy,

wybrano predyktor „Typ kontraktu (budowa lub modernizacja, remont)”. W przypadku budowy nowych odcinków dróg krajowych i autostrad, uciążliwości związane z dużym natężeniem ruchu drogowego, czy ograniczonym dostępem do placu budowy są odczuwane w znacznie mniejszym stopniu. Na remontowanych,

Tabela 1.

Czynniki powodujące opóźnienia przyjęte do dalszych analiz. Źródło: Anysz, 2017.

Lp.	Czynniki powodujące opóźnienia przyjęte do dalszych analiz	Grupa czynników
1	Trymestr roku, w którym dana budowa została rozpoczęta	Warunki kontraktowe
2	Wartość kontraktu	Warunki kontraktowe
3	Zakres kontraktu („projektuj i buduj” lub „buduj”)	Warunki kontraktowe
4	Planowany czas realizacji obiektu	Warunki kontraktowe
5	Typ kontraktu (budowa lub modernizacja, remont)	Cechy obiektu
6	Długość odcinka drogi, na którym zaplanowano prace	Cechy obiektu
7	Inflacja w roku poprzedzającym rok rozpoczęcia budowy (wskaźnik cen robót budowlano-mont.)	Makroekonomiczne
8	Wskaźnik bezrobocia w roku poprzedzającym rok rozpoczęcia budowy	Makroekonomiczne
9	Sprzedaż produkcji budowlano-montażowej w roku poprzedzającym rok rozpoczęcia budowy	Makroekonomiczne
10	Liczba partnerów konsorcjum wykonawcy	Cechy wykonawcy
11	Łączna, roczna sprzedaż partnerów konsorcjum w roku poprzedzającym rok rozpoczęcia budowy	Cechy wykonawcy
12	Łączne, średniomiesięczne zatrudnienie u partnerów konsorcjum w roku poprzedzającym rok rozpoczęcia budowy	Cechy wykonawcy

czy modernizowanych odcinkach dróg bardzo istotnym czynnikiem wpływającym w znacznym stopniu na organizację budowy jest konieczność zapewnienia przejezdności modernizowanych odcinków.

### 6.2.3. ZEBRANIE DANYCH STATYSTYCZNYCH

Zebrane dane statystyczne zbierano dla 156 kontraktów dotyczących budowy lub modernizacji dróg ekspresowych i autostrad w Polsce, których realizacja zakończyła się w latach 2009–2013. Źródłem informacji były:

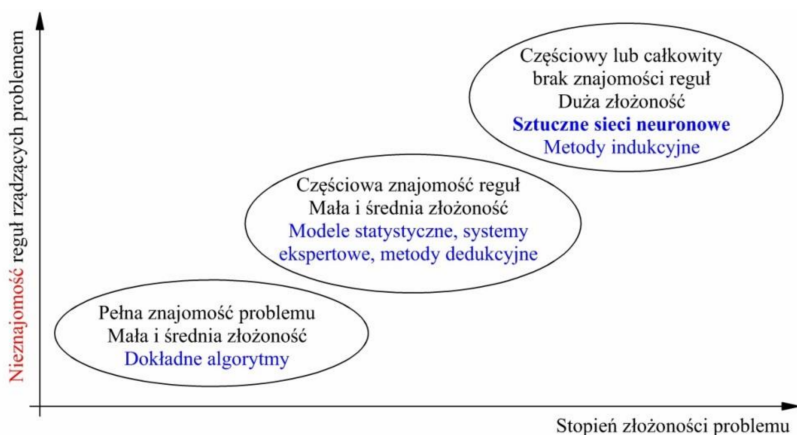
- dane przygotowane przez GDDKiA,
- dane udostępniane przez Główny Urząd Statystyczny (GUS),
- witryny internetowe GDDKiA i tytułów prasowych (przeglądane w celu odnalezienia informacji o rzeczywistym terminie zakończenia budowy odcinków dróg),
- witryny internetowe przedsiębiorstw realizujących kontrakty drogowe na zlecenie GDDKiA,
- komercyjna baza danych udostępniona przez Infocredit (z siedzibą w Warszawie).

Skorzystanie z komercyjnej bazy danych okazało się koniecznością. Przyjęte predyktory (nr 11 i 12 z tabeli 1) zostały uznane jako istotnie wpływające na opóźnienie, a witryny internetowe przedsiębiorstw tylko w niektórych przypadkach zawierały poszukiwane informacje. Przedsiębiorstwa mające siedzibę w Polsce mają obowiązek składania sprawozdań finansowych w sądzie rejestrowym, gdzie można je przeglądać. Zagraniczne podmioty – które także realizowały badane odcinki dróg – takiego obowiązku nie mają. Skorzystanie z komercyjnej bazy danych znacznie przyspieszyło proces zbierania danych, tym bardziej, że i tak – poszukując pozostałych danych – konieczne było sprawdzenie ponad 500 witryn internetowych. Pełnych danych nie udało się – mimo wysiłków – zebrać dla wszystkich badanych realizacji. Poza tym z dalszych badań wyłączono także te przypadki, gdzie opóźnienie wynosiło ponad 100% planowanego na realizację czasu, po sprawdzeniu, że ich przyczyną były wyjątkowe okoliczności (np. protesty ekologów). Ostatecznie baza danych o zrealizowanych odcinkach dróg krajowych i autostrad obejmowała 127 rekordów.

### 6.2.4. WYBÓR NARZĘDZIA PROGNOSTYCZNEGO

Zarówno w pracach Bartkiewicza (2000), jaki i Tadeusiewicza (2000) można znaleźć informację, iż sztuczne sieci neuronowe są jednym z najlepszych narzędzi do modelowania zjawisk o dużej złożoności, w których bardzo mała jest znajomość reguł rządzących procesem (rys. 4). Budowa odcinków dróg ekspresowych i autostrad jest bez wątpienia procesem złożonym. Zależności rzeczywistego czasu

trwania budowy od jednego tylko z czynników nie są silne. Wśród wybranych predyktorów najsilniejszą liniową korelację z rzeczywistym czasem realizacji budowy wykazywał planowany cykl budowy.



Rys. 4. Cechy zjawisk, dla modelowania których sztuczne sieci neuronowe dają dobre wyniki.  
Źródło: Bartkiewicz, 2000; Tadeusiewicz, 2000.

Skuteczność zastosowania sztucznych sieci neuronowych (SSN) do modelowania zjawisk w budownictwie została potwierdzona w wielu pracach. Zastosowanie SSN do modelowania kosztów (Sodikov, 2005; ElSavy i in., 2001; Juszczyk, 2010), do modelowania czasów procesów budowlanych (Rogalska, 2016), do modelowania produktywności maszyn budowlanych pozwalającej na obliczenie czasu wykonania robót (Hoła i Schabowicz, 2010) były inspiracją i przykładem skuteczności zastosowania narzędzia jakim są SSN do modelowania złożonych, budowlanych procesów. Także autor w swych badaniach wykorzystywał prognostyczne własności SSN (Anysz i in., 2013 i 2014). Większa dokładność – wykonanych za pomocą SSN – oszacowań kosztu wzniesienia budynków szkół, niż w przypadku wykorzystania rachunku regresji, czy maszyny wektorów nośnych (ang. Support Vector Machine, SVM) została potwierdzona m.in. w pracy Kima i in. (2013).

## 6.3. PROGNOZOWANIE Z WYKORZYSTANIEM SSN

### 6.3.1. PRZYGOTOWANIE DANYCH

Sztuczne sieci neuronowe, wykorzystując heurystyczne algorytmy, poszukują takich współczynników (wag) połączeń między neuronami, które zastosowane powodują minimalizację błędów prognoz. W neuronach warstw ukrytych i w warstwie wyjściowej realizowane są przekształcenia. Funkcja aktywacji neuronu (w warstwowych sztucznych sieciach neuronowych) ma dziedzinę tworzoną przez



wartości wielomianów konstruowanych na podstawie wartości z wyjść neuronów warstwy poprzedniej oraz optymalizowanych przez sieć wartości wag. Mając powyższe na względzie, a także uwzględniając doświadczenia z praktycznych zastosowań SSN, badacze stwierdzili, że niezbędna jest standaryzacja danych wejściowych i wyjścia z SSN (m.in. Osowski, 2006; Rutkowski, 2012). Wtedy, na starcie obliczeń, istotność wszystkich zmiennych niezależnych jest dla SSN taka sama. I wartość kontraktu (wartości niektórych sięgają miliardowych kwot) i wskaźnik inflacji (setne części jedności) ważą na wyniku tak samo. Dopiero w procesie doboru wag ich wpływ jest różnicowany. Najczęściej stosowaną metodą standaryzacji danych jest metoda liniowa-maksimum z zastosowaniem następującej zależności:

$$a_i = \frac{a_{0i}}{\max a_{0i}}, \quad (1)$$

gdzie:

$a_i$  – dana wejściowa typu  $a$  z  $i$ -tego zestawu danych wejściowych, po standaryzacji,

$a_{0i}$  – dana wejściowa typu  $a$  zaobserwowana podczas  $i$ -tego procesu,

$i$  – kolejny numer obserwacji z wszystkich  $m$  procesów.

Po stwierdzeniu, że rodzaj standaryzacji danych wejściowych może mieć wpływ na uzyskaną dokładność prognoz (Anysz i in., 2016), postanowiono sprawdzić w obliczeniach także inne metody standaryzacji – liniowe: wektorowa, manhattan, Weitendorfa oraz nieliniowe: Peldschusa (Kaftanowicz i Krzemiński, 2015) i logarytmiczną (Zawadskas i Turskis, 2008).

Przygotowane dane należało także podzielić na trzy następujące grupy:

- dane uczące (służące SNN do znalezienia optymalnych wag),
- dane walidacyjne (na ich podstawie heurystyczny algorytm uczący decyduje czy osiągnięte zostały optymalne wartości wag),
- dane testowe (służące do określania błędów prognoz).

Podziału tego dokonano w sposób losowy i tylko jeden raz. Niezależnie od metody standaryzacji te same 40 rekordów z bazy danych stanowiło podstawę do obliczenia błędów uzyskiwanych prognoz i nie brało udziału w procesie uczenia sieci.

Dane wejściowe – oprócz procesu standaryzacji – wymagały jeszcze jednego zabiegu mającego na celu zwiększenie dokładności prognoz (z tych samych względów co proces standaryzacji). Dane, które miały postać kategorii np. zakres kontraktu: „buduj” lub „projektuj i buduj”, wprowadzano w postaci dwóch liczb (dwa neurony wejściowe zamiast jednego). W przypadku, gdy dany kontrakt zrealizowany był w formule „buduj” wejście „buduj” przyjmowało wartość 1, a wejście „projektuj i buduj” wartość 0. Podobnie zrobiono z danymi dotyczącymi trymestru roku, w którym rozpoczęto realizację oraz z typem zadania (budowa vs przebudowa, modernizacja). W efekcie 12 typów informacji wprowadzane było do sieci poprzez 16 neuronów warstwy wejściowej.

### 6.3.2. OKREŚLENIE WYJŚCIA Z SSN – ZMIENNEJ ZALEŻNEJ

Założeniem prowadzonych analiz było uzyskanie prognoz opóźnień terminów zakończenia budowy odcinków dróg krajowych i autostrad. Na podstawie (Hagan i in., 2016) oraz (Osowski, 1996) stwierdzono, że korzystniej na wyjściu z sieci jest stosować liczby wyłącznie dodatnie. Jednoczesne występowanie liczb i dodatnich, i ujemnych stwarza także problem przy zastosowaniu niektórych metod standaryzacji (wyjście z sieci także podlegało standaryzacji). Postanowiono więc prognozować nie opóźnienie, a czas realizacji obiektów. Uzyskanie na ich podstawie prognoz opóźnienia wymaga jedynie zastosowania następującej formuły:

$$d_i = t_i^{pr} - t_i^{pl}, \quad (2)$$

gdzie:

$d_i$  – prognozowana wartość opóźnienia zakończenia wykonania  $i$ -tego kontraktu,  
 $t_i^{pr}$  – prognozowany czas realizacji  $i$ -tego kontraktu (uzyskiwany z obliczeń SSN),  
 $t_i^{pl}$  – planowany czas trwania  $i$ -tego kontraktu (stanowiący jedną z danych wejściowych).

W obliczeniach zastosowano także inny rodzaj wyjścia z sieci. Było nim opóźnienie względne  $d_i^w$  zdefiniowane jako:

$$d_i^w = \frac{t_i^{rz}}{t_i^{pl}}, \quad (3)$$

gdzie:  $t_i^{rz}$  – rzeczywisty czas realizacji  $i$ -tego kontraktu.

W tym przypadku prognozy uzyskane SSN dotyczyły opóźnienia względnego, które – w celu uzyskania prognozy wyrażonej w dniach – należało przeliczyć posługując się poniższą formułą:

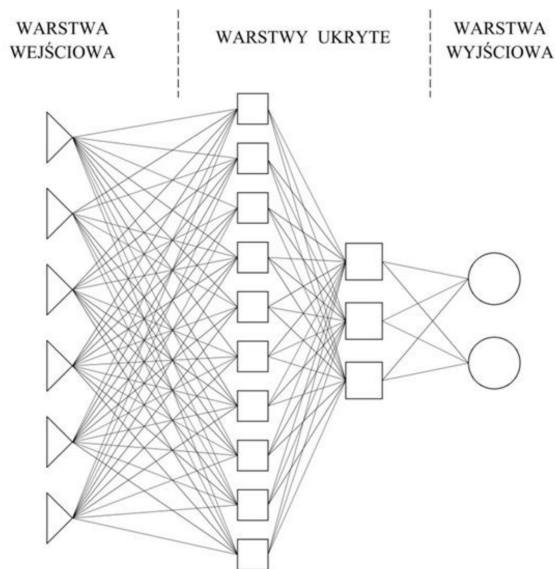
$$d_i = t_i^{pl} * (d_i^{wpr} - 1), \quad (4)$$

gdzie:  $d_i^{wpr}$  – prognozowane opóźnienie względne  $i$ -tego kontraktu.

Oczywiście w obydwu przypadkach wyjście z sieci było standaryzowane tymi samymi metodami, co dane wejściowe.

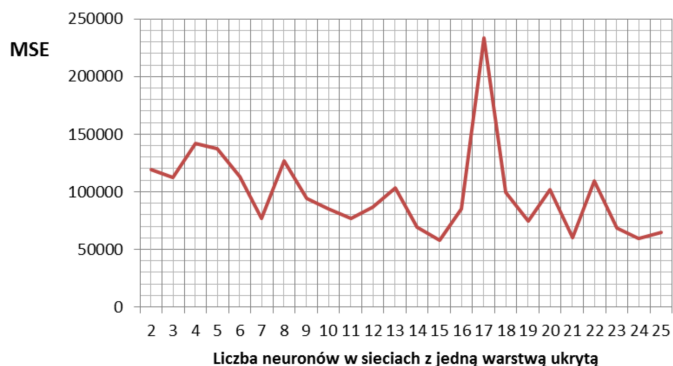
### 6.3.3. WYBÓR TYPU, TOPOLOGII I PARAMETRÓW SSN, WSTĘPNE OBLICZENIA

Do obliczeń zastosowano pakiet MATLAB (R2015a) z przybornikiem Neural Networks. Na podstawie prac Hagana i in. (2016), Osowskiego (1996), materiałów Statsoftu stwierdzono, iż z dwóch typów SSN najczęściej stosowanych do prognozowania typów sieci (Statsoft) tj. sieci warstwowych (MLP ang. multi-layer perceptron; patrz rys. 5) i sieci o radialnych funkcjach bazowych (RBF ang. radial basis functions) z sigmoidalnymi funkcjami aktywacji, lepsze wyniki uzyskuje się stosując sieci MLP ze względu na ich lepsze zdolności do generalizacji.




Rys. 5. Przykład sieci MLP z 6-ciu wejściami, dwoma warstwami ukrytymi (10 neuronów w pierwszej warstwie ukrytej, 3 neurony w drugiej) i dwoma wyjściami. Źródło: Anysz, 2017.

W pierwszym etapie obliczeń postanowiono zastosować wszystkie 12 typów danych wejściowych, wyjście w postaci rzeczywistego (dla próby uczącej, a dla testowej prognozowanego) czasu trwania budowy, standaryzację liniową-maksimum, logistyczną funkcję aktywacji oraz algorytm uczący Lavenberga-Marquardta. Badano sieci o jednej i dwóch warstwach ukrytych z różną liczbą neuronów w każdej z warstw. Wyniki (w postaci wartości błędu średniokwadratowego liczonego dla próby testowej, a oznaczanego MSE ang. mean squared error) przedstawiono na rys. 6 i rys. 7. Oprócz stwierdzenia, że błąd MSE obliczonych prognoz jest dość



Rys. 6. MSE w zależności od liczby neuronów w jednej warstwie ukrytej. Źródło: Anysz, 2017.

duży i nie ma wyraźnego globalnego minimum, ani dla sieci z jedną, ani z dwoma warstwami ukrytymi, należy też zauważyć, że nie ma wyraźnej różnicy w minimum MSE pomiędzy jedno- i dwuwarstwowymi sieciami. Powyższe ustalenie jest spójne z teorią Kołomogorowa, która stwierdza, że większość funkcji da się zamodelować siecią z jedną warstwą ukrytą, a dwie warstwy stają się dopiero niezbędne przy zagadnieniach dyskretnych (Osowski, 1996; Rybarczyk, 2008). Na tej podstawie w dalszych obliczeniach postanowiono stosować jedynie sieci z jedną warstwą ukrytą.



Rys. 7. MSE w zależności od liczby wag neuronów w sieci z dwiema warstwami ukrytymi. Źródło: Anysz, 2017.

#### 6.3.4. OPTIMALIZACJA TOPOLOGII I PARAMETRÓW SSN

Bardzo duża liczba kombinacji (ponad 7 tysięcy), wynikająca z przyjętych do badań następujących parametrów sieci:

- liczba neuronów w warstwie ukrytej (od 2 do 25),
- 6 metod standaryzacji danych wejściowych,
- 2 rodzaje wyjścia z sieci (prognozowany czas trwania budowy lub opóźnienie względne),
- 3 rodzaje funkcji aktywacji w warstwie ukrytej (logistyczna, tangens hiperboliczny, liniowa),
- 3 rodzaje funkcji aktywacji w warstwie wyjściowej,
- 3 algorytmy uczące (Lavenberga–Marquardta, gradientów sprzężonych, wstecznej propagacji błędów),

wymusiła konieczność automatyzacji obliczeń. Posługując się składnią Matlaba napisano skrypty, dzięki którym możliwe było sprawdzenie wszystkich kombinacji powyższych parametrów i topologii sieci. Wyniki prognoz i ich błędy zapisywane były w odrębnych plikach umożliwiającym ich późniejsze przeglądanie i sortowanie.

### 6.3.5. OPTIMALIZACJA LICZBY TYPÓW DANYCH WEJŚCIOWYCH – ZMIENNYCH ZALEŻNYCH

W celu uzyskania jak najdokładniejszych prognoz, w oparciu o stwierdzenia znalezione w pracy Bartkiewicza (2000) postanowiono sprawdzić także działanie sieci z ograniczoną liczbą predyktorów (tj. zmniejszoną liczbą typów danych wejściowych). Zabieg ten miał wykluczyć spotykane czasem zjawisko uczenia się sieci głównie na podstawie tych danych wejściowych, które są ze sobą silnie skorelowane i pomijania (w optymalizacji wag) pozostałych typów danych. W tab. 2 zestawiono wyniki obliczeń wzajemnych korelacji liniowych wszystkich 16-tu predyktorów.

Tabela 2.

Wartości współczynników korelacji liniowej predyktorów. Źródło: Anysz, 2017.

N	16	15	14	13	12	11	10	9	8	7	6	5	4	3	2
1	0,03	0,06	0,01	0,05	<b>-0,50</b>	0,04	<b>0,52</b>	-0,15	0,15	-0,15	0,15	0,03	0,06	-0,40	-0,48
2	-0,05	-0,08	-0,10	-0,02	0,11	0,01	-0,17	0,04	-0,04	-0,02	0,02	-0,04	-0,05	<b>-0,62</b>	
3	0,02	0,04	0,09	-0,02	0,33	-0,05	-0,29	0,09	-0,09	0,15	-0,15	0,01	-0,01		
4	<b>0,64</b>	0,41	0,35	0,38	0,05	-0,08	0,05	-0,39	0,39	0,27	-0,27	<b>0,70</b>			
5	0,41	0,28	0,19	0,31	0,06	-0,03	0,03	-0,05	0,05	0,21	-0,21				
6	-0,21	-0,11	-0,13	-0,16	-0,18	0,25	0,06	-0,03	0,03	<b>-1,00</b>					
7	0,21	0,11	0,13	0,16	0,18	-0,25	-0,06	0,03	-0,03						
8	0,29	0,31	0,23	0,13	0,02	-0,17	0,20	<b>-1,00</b>							
9	-0,29	-0,31	-0,23	-0,13	-0,02	0,17	-0,20								
10	0,01	0,10	-0,04	0,01	-0,34	-0,15									
11	-0,08	-0,17	-0,16	0,04	-0,31										
12	-0,03	0,14	0,15	-0,05											
13	0,24	0,08	-0,07												
14	0,26	<b>0,83</b>													
15	0,27														

gdzie: N – Nr kolumny danych wejściowych

W powyższym zestawieniu wyłuszczone te wartości, których wartość bezwzględna jest większa od 0,5. Otrzymano w ten sposób podpowiedź, które z predyktorów można (prawdopodobnie) bez szkody dla dokładności prognoz wyeliminować.

Wykonano także drugie sprawdzenie dotyczące wyboru predyktorów wykorzystując udostępniany program (Saha) do obliczeń sztucznymi sieciami neuronowymi (na bazie Microsoft Excel). Sprawdzano kombinacje każdych dwóch predyktorów. Do wariantu z dwoma predyktorami dającymi najmniejszy MSE dodawano kolejno wszystkie pozostałe. Procedurę powtarzano zwiększając liczbę predyktorów, a obliczenia prowadzono do momentu, aż dodanie kolejnego predyktora nie powodowało obniżenia wartości błędu prognoz.

Na podstawie wyżej opisanych obliczeń postanowiono ograniczyć liczbę predyktorów pozostawiając następujące:

- wartość kontraktu,
- długość odcinka drogi,
- zakres kontraktu („buduj” vs „projektuj i buduj”),
- typ kontraktu (budowa vs remont, modernizacja, przebudowa),
- sumaryczne średnie zatrudnienie w przedsiębiorstwach konsorcjum wykonawcy,
- planowany czas realizacji obiektu.

Wartości tak wybranych predyktorów wprowadzane były do SSN ośmioma neuronami wejściowymi (zakres kontraktu i typ kontraktu wymagały zastosowania 2 wejść dla każdej z tych cech). Obliczenia – tak jak przy 16-tu neuronach wejściowych – wykonano dla wszystkich możliwych kombinacji parametrów i topologii sieci (opisanych w ppkt. 3.4 niniejszego rozdziału) z wykorzystaniem wcześniej napisanych skryptów.

### 6.3.6. ANALIZA OTRZYMANYCH WYNIKÓW

Topologię i parametry najlepiej prognozujących sztucznych sieci neuronowych typu MLP zebrano w tabeli 3. Kryterium oceny był najmniejszy błąd prognoz, jednak błędy te można obliczać w różny sposób. Do oceny jakości prognoz punktowych powszechnie stosowany błąd średniokwadratowy (MSE) lub jego pierwiastek (RMSE). Można także stosować inne miary np. średni błąd względny (MAPE ang. mean absolute percentage error) lub maksymalny błąd względny

Tabela 3.

SSN o najmniejszych błędach prognoz (wartości błędów policzone dla próby testowej).

Źródło: Anysz, 2017.

Liczba neuronów w warstwie ukrytej	Funkcja aktywacji dla warstwy ukrytej	Funkcja aktywacji dla warstwy wyjściowej	Algorytm uczenia	Rodzaj standaryzacji danych	Liczba predyktorów	Rodzaj wyjścia sieci (zmienna zależna)	MSE	MAPE	max APE
9	liniowa	tangens hiperboliczny	wstecznej propagacji błędów	Weitenberga	8	opóźnienie względne	19829	0,1497	<b>0,2773</b>
5	tangens hiperboliczny	tangens hiperboliczny	Lavenberga-Marquardt'a	Liniowa-maksimum	8	opóźnienie względne	<b>10298</b>	0,1529	0,8352
14	liniowa	tangens hiperboliczny	gradientów sprzężonych	Liniowa-maksimum	8	czas trwania budowy	13883	<b>0,1180</b>	0,3240

(max APE ang. maximum absolute percentage error), które także określają dokładność prognoz. Do tabeli 3 zostały wybrane 3 sieci o najmniejszych błędach (dla każdego z 3 rodzajów błędów: MSE, MAPE, max APE). Należy zaznaczyć, że w celu zapewnienia porównywalności różnych typów błędów, dla sieci prognozujących opóźnienie względne wyniki prognoz były przeliczane na prognozy czasu realizacji obiektu i dopiero wtedy obliczane były wartości błędów.

Uwagę zwraca przede wszystkim fakt, iż wśród znalezionych sieci nie ma jednej, dla której wszystkie trzy sposoby liczenia błędów byłyby najniższe. Drugim ważnym ustaleniem jest, że wśród najlepiej prognozujących sieci są tylko te, w których ograniczono o połowę liczbę predyktorów. W literaturze (np. Rogalska, 2016) można znaleźć informację, że średni błąd względny prognoz (MAPE) w wysokości 12% sprawia, iż przydatność takich prognoz jest na granicy odrzucenia ich wykorzystania. Jednakże, w ocenie uzyskanych wyników należy wziąć pod uwagę moment wykonywania prognozy – przed wyborem wykonawcy kontraktu, czyli przed rozpoczęciem robót budowlanych. Tym samym na powstawanie opóźnień terminu zakończenia budowy ma wpływ ponad sto innych czynników (niż użyte w modelu), których identyfikacja jest możliwa dopiero w trakcie realizacji budowy. Zaskoczeniem jest też, iż czysto matematyczne podejście do prognozowania było przyczyną odrzucenia predyktora, jakim była początkowo roczna łączna sprzedaż przedsiębiorstw tworzących konsorcjum wykonawcze. Lepszym (w zbudowanym modelu prognostycznym) parametrem do oceny takiego konsorcjum (czy też wykonawcy oferującego samodzielne wykonanie kontraktu) okazało się średnioroczne zatrudnienie w przedsiębiorstwie niż parametr finansowy. Oczywiście ma to swoje uzasadnienie. Przedsiębiorstwo zatrudniające większą liczbę pracowników może szybciej zareagować na powstające w trakcie budowy opóźnienia w realizacji (zwiększając zatrudnienie na danej budowie) niż to przedsiębiorstwo, które nie ma dodatkowych pracowników, których mogłoby przesunąć na budowę doznającą opóźnień, a posiada jedynie środki finansowe na wynajęcie dodatkowych pracowników.

Do praktycznego zastosowania zbudowanego modelu wskazane było wypracowanie decyzji, którą ze znalezionych sieci przyjąć jako zalecaną do prognoz, tj. który z typów błędów przyjąć jako podstawowy do ocen uzyskanych prognoz. Zastosowano w tym celu opracowany przedziałowy sposób oceny punktowych prognoz (Anysz i in., 2016a), którego podstawą jest zasada minimalizacji strat decydenta (Zeliaś i in., 2013) wykorzystującego prognozy do podjęcia decyzji. Zdefiniowano dwa dychotomiczne podzbiory prognoz trafnych i nietrafnych (rys. 8). Jako prognozy trafne określono te, które zawierają się w domkniętym przedziale pomiędzy 0,95 rzeczywistego czasu realizacji obiektu (dla próby testowej), a iloczynem rzeczywistego czasu trwania budowy i parametru  $L_G \geq 1$ . Prognoza krótsza, niż rzeczywisty termin zakończenia budowy, z zakresu


$$0,95t^{rz} \leq t^{pr} \leq t^{rz} \quad (5)$$

oznacza błąd mniej niż 2 tygodni dla najkrótszych z kontraktów oraz błąd nieco ponad 2 miesiące dla najdłuższej z analizowanych budów (trwającej 4 lata) i nie spowoduje znaczącej różnicy w finansach zamawiającego. Prognozy wskazujące dłuższy niż planowany okres budowy dają nieco mylną informację zamawiającemu, ale najprawdopodobniej nie są przyczyną strat zamawiającego (wykonanie krótsze niż przewidywane jest raczej przyczyną oszczędności).



Rys. 8. Dwa dychotomiczne podzbiory prognoz. Źródło: Anysz i in., 2017a.


Na tej podstawie można porównać parami uzyskane SSN stwierdzając, że lepsze prognozy uzyskujemy tą siecią, która ma większą liczebność prognoz trafnych (w rozumieniu zdefiniowanym powyżej) dla różnych wartości parametru  $L_G$ . Po wykonaniu obliczeń rezultat takich porównań przedstawiono na rys. 9 i rys. 10.



Rys. 9. Względna liczebność podzbioru prognoz trafnych dla próby testowej w zależności od parametru  $L_G$ . Porównanie prognoz sieci o najniższym MAPE oraz najniższym max APE. Źródło: Anysz, 2017.

Dla każdej szerokości przedziału prognoz trafnych, a więc dla każdej wartości parametru  $L_G$ , liczebność zbioru prognoz trafnych sieci dającej najniższy średni błąd względny prognoz jest większa niż sieci zapewniającej minimalną wartość maksymalnego błędów względnego. Zwiększanie wartości  $L_G$  powyżej wartości 1,81 nie zwiększa już liczebności zbioru prognoz trafnych, gdyż wszystkie nietrafne prognozy są krótsze niż  $0,95t^{rz}$ .





Rys. 10. Względna liczebność zbioru prognoz trafnych dla próby testowej w zależności od parametru  $L_G$ . Porównanie prognoz sieci o najniższym MAPE oraz najniższym MSE. Źródło: Anysz, 2017.

Podobny wniosek można wysnuć porównując liczebności zbiorów prognoz trafnych dla sieci prognozującej z najniższym MAPE oraz z najniższym MSE. W tym przypadku tylko dla  $L_G = 1,35$  liczebność zbioru prognoz trafnych jest nieco wyższa dla sieci o najniższym MSE. Dla  $L_G = 1,34$  oraz  $L_G = 1,39$  liczebności są równe. Dla pozostałych szerokości przedziałów prognoz trafnych lepsze prognozy zapewnia sieć o najniższym MAPE. Na podstawie tych porównań można stwierdzić, że najlepszą prognozę, tj. zapewniającą najdokładniejsze prognozy oraz najmniejsze szanse na stratę decydenta posługującego się prognozami, zapewnia znaleziona sieć z najniższym średnim błędem względnym (MAPE) równym 12%.

Parametry najlepszej sztucznej sieci prognozującej opóźnienia terminu zakończenia budowy dróg ekspresowych i autostrad ze średnim błędem względnym nie większym niż 12% pokazano w tabeli 4.

Tabela 4.

Parametry SSN MLP najmniejszych błędach prognoz (wartości błędów policzone dla próby testowej). Źródło: Anysz, 2017.

Liczba neuronów w warstwie ukrytej	Funkcja aktywacji dla warstwy ukrytej	Funkcja aktywacji dla warstwy wyjściowej	Algorytm uczenia	Rodzaj standaryzacji danych	Liczba predyktorów	Rodzaj wyjścia sieci (zmienna zależna)	MSE	MAPE	max APE
14	liniowa	tangens hiperboliczny	gradientów sprzężonych	Liniowa-maksimum	$\delta$	czas trwania budowy	13883	<b>0,1180</b>	0,3240

Jako zmienne niezależne przyjęto następujące predyktory:

- wartość kontraktu [zł],
- długość odcinka drogi [km],
- zakres kontraktu („buduj” vs „projektuj i buduj”),
- typ kontraktu (budowa vs remont, modernizacja, przebudowa),
- sumaryczne średnie zatrudnienie w przedsiębiorstwach konsorcjum wykonawcy,
- planowany czas trwania budowy [dni].

W celu uzyskania wartości prognozowanych opóźnień wyrażonej w dniach należy skorzystać z formuły (2).

#### 6.4. PRZYKŁAD ZASTOSOWANIA

Dla części predyktorów wyszczególnionych w ppkt. 3.6 policzono przeciętne lub najczęstsze występujące wartości (na podstawie zgromadzonych danych o kontraktach zakończonych w latach 2009–2013 (tabela 5).

Tabela 5.

Przeciętne lub najczęstsze warunki postępowań przetargowych w latach 2009–2013.  
Źródło: Anysz, 2017.

Długość odcinka drogi w km	13,2
Kontrakt typu buduj	Tak
Kontrakt typu P+B	Nie
Budowa od podstaw	Tak
Przebudowa, modernizacja, remont	Nie
Planowany czas trwania robót w dniach	683

Podobnie, bazując na zgromadzonych danych, stworzono przykładowe oferty na zadanie opisane w tabeli 5. Ceny hipotetycznych oferentów oraz liczbę zatrudnionych w konsorcjach oferentów (kolejne z predyktorów wyszczególnionych w ppkt. 3.6) pokazano w tabeli 6.

Tabela 6.

Parametry hipotetycznych ofert. Źródło: Anysz, 2017.

Lp. oferty	1	2	3	4	5
Wartość kontraktu w mln PLN – cena ofertowa	300	295	330	340	345
Średnie zatrudnienie w konsorcjum	1000	2000	5000	3000	4000

Wykorzystując zbudowany model (sztuczną sieć neuronową MLP o parametrach opisanych w tabeli 4, zapewniającą najniższy błąd prognoz MAPE) obliczono prognozy opóźnienia dla każdej z ofert, a wyniki pokazano w tabeli 7.

Parametry hipotetycznych ofert. Źródło: Anysz, 2017.

L.P. oferty	1	2	3	4	5
Prognozowany czas trwania budowy w dniach	852	850	865	862	865
Prognozowane opóźnienie zakończenia budowy	169	167	182	179	182

Zamawiający może więc wykorzystać prognozę opóźnienia jako jedno z kryteriów oceny ofert. Na podstawie uzyskanych prognoz można stwierdzić, iż w przypadku przyjęcia oferty nr 2 prognozowane opóźnienie terminu zakończenia budowy jest najmniejsze i wynosi 167 dni. Średni błąd względny prognoz wynosi 12%. Zastosowany przedziałowy system oceny punktowych prognoz pozwala na określenie przez decydenta (zamawiającego) przedziału prognoz trafnych poprzez określenie parametru  $L_G$ . Ustalenie wielkości tegoż parametru np. na 1,2 pozwala – na podstawie rys. 10 – na stwierdzenie, że szansa na to by prognoza czasu trwania tej konkretnej budowy znalazła się w przedziale od 0,95 do 1,2 rzeczywistego czasu trwania budowy (czyli pomiędzy 649 a 820 dniem) wynosi 60% (liczebność przedziału prognoz trafnych dla  $L_G = 1,2$ ).

Na bazie doświadczeń swoich doświadczeń, zamawiający – oprócz wyboru oferty wykonawcy – mógłby stwierdzić, że prognozowane, blisko półroczne opóźnienie jest zbyt duże. Wtedy niezbędna byłaby decyzja o zmianie parametrów postępowania (np. skrócenie odcinka drogi lub wydłużenie planowanego czasu jego budowy). Zdaniem autora wydłużenie planowanego czasu realizacji kontraktu (o długość prognozowanego opóźnienia) spowoduje mniej negatywnych skutków, niż wybór krótszego planowanego czasu realizacji budowy, a następnie wybudowanie obiektu z opóźnieniem (w tym samym łącznym, rzeczywistym czasie).

## 6.5. PODSUMOWANIE

Planowanie budowlanych przedsięwzięć inwestycyjnych zapewniające jak największe prawdopodobieństwo ukończenia budowy w planowanym terminie jest współcześnie co raz bardziej istotne. Dlatego nie dziwi wielość prac i poruszanych zagadnień mających na celu uodpornienie procesu planowania i realizacji budowy na zakłócenia przynoszące negatywne skutki. Teoria zbiorów rozmytych stosowana jest m.in. do harmonogramowania (Kulejewski, 2010), konstruowania sieci zależności (Radziszewska-Zielina i Śladowski, 2017), określania ryzyka projektu (Ibadov, 2016); metoda PERT do oszacowania czasu trwania czynności (Plebankiewicz i in., 2015), metoda łańcucha krytycznego do odpornych na zakłócenia harmonogramów (Połoński, 2008), metoda wartości wypracowanej do kontroli postępu prac (Czarnigowska, 2009; Kapliński i in. 2014); algorytmy dokładne (Krzemiński, 2014) i heurystyczne (Jaśkowski, 2008) w harmonogramowaniu, metody potokowe w harmonogramowaniu (Hejducki i Rogalska, 2017). Oprócz prac

wymienionych w ppkt. 2.4 wykorzystanie przez polskich badaczy sztucznych sieci neuronowych częściej skupiało się na aspektach kosztowych i klasyfikacyjnych w budownictwie. Do zagadnienie prognozowania terminu zakończenia budowy zastosowano (Czarnigowska i Sobotka, 2013) trzy inne (niż SSN) narzędzia. Najniższy otrzymany tam MAPE wynosił 23% (dla modelu drzew binarnych CART). Na tym tle, znalezienie sztucznej sieci neuronowej prognozującej termin zakończenia budowy z błędem MAPE równym 12% można ocenić wysoko. Oczywiście porównując te wyniki należy mieć na uwadze, że nieco inny był przedmiot badań. Czarnigowska i Sobotka badały budowę dróg (z wyłączeniem autostrad) tylko w 3 województwach, w latach 2003–2009, więc także czas i lokalizacja budów była inna niż w niniejszej pracy. W obydwu pracach podobna była wielkość badanej próby. Można więc stwierdzić, że własności SSN do rozpoznawania (nieznanych badaczowi) reguł rządzących złożonym procesem zostały wykorzystane. Wpłynęło to na relatywnie niski (biorąc pod uwagę złożoność procesów budowy i moment wykonywania prognoz) średni błąd względny prognoz (MAPE). Zdaniem autora, uzyskanie błędu dużo niższego niż 12% np. 2% byłoby zdecydowanie niewiarygodnym wynikiem, ze względu na fakt, że po wykonaniu opisywanych prognoz następuje etap budowy, kiedy – jak wykazano – ujawnia się znakomita większość przyczyn powstawania opóźnień. Należy jednak wspomnieć, że łączne zastosowanie SSN i teorii zbiorów rozmytych (Anysz i Ibadov, 2017) pozwoliło – prowadząc obliczenia na tych samych danych – na obniżenie błędów prognoz MSE o 18,6%, co wskazuje, że możliwe jest zbudowanie jeszcze dokładniej prognozującego modelu.

Ważnym elementem pracy było zastosowanie niestandardowego narzędzia do oceny, którą ze znalezionych sieci uznać jako najlepiej prognozującą. Wykorzystanie zasady minimalizacji strat decydenta do stworzenia przedziałowej metody oceny prognoz punktowych pozwoliło na procentową ocenę szans trafności prognozy dla różnej szerokości przedziału prognoz trafnych.

Na podstawie zbudowanego przykładu pokazano w jaki sposób zamawiający budowę (lub projektowanie i budowę) odcinka autostrady lub drogi ekspresowej, mogą wykorzystywać prognozy terminu zakończenia budowy wykonane jeszcze przed wyborem wykonawcy zadania, a więc także przed rozpoczęciem prac budowlanych. Decyzje podjęte na tej podstawie mogą przyczynić się do zmniejszenia opóźnień terminów zakończenia budowy odcinków dróg, a tym samym do zwiększenia efektywności gospodarowania zamawiającego i wykonawcy robót.

## 6.6. BIBLIOGRAFIA

- ABISUNGA A.O., AMUSU O.R.O., SALVADOR K.A. (2014). Construction Delay in Nigeria – Perception of Indigenous and Multinational Construction Firms. *Journal of Emerging Trends in Economics and Management Sciences*, 5 (3) 371–378.

- ANYSZ H. (2012). Wpływ opóźnień w realizacji kontraktu budowlanego na wzrost kosztów jego obsługi logistycznej. *Logistyka*, 3, 15–21.
- ANYSZ H., ZBICIAK A. (2013). *Przyczyny powstawania opóźnień w realizacji kontraktów budowlanych – analiza wstępnych wyników badania ankietowego*. Autobusy (3/14), DW Spatium.
- ANYSZ H., IBADOV N., WIELĄDEK P. (2013). Analiza możliwości prognozowania wyników finansowych przedsiębiorstw w sektorze budownictwa za pomocą sztucznych sieci neuronowych MLP. *Technika Transportu Szybowego*, 10, 2035–2045,
- ANYSZ H., FOREMNY A., KULEJEWSKI J. (2014). Estimating potential losses of the client in public procurement in case of collusion utilizing a MLP neural networks. *Technical Transactions*, 1-B.
- ANYSZ H., ZBICIAK A., IBADOV N. (2016). The influence of input data standardization method on prediction accuracy of artificial neural networks. *Procedia Engineering*, 153.
- ANYSZ H., ZBICIAK A., IBADOV N. (2016a). Pomiar trafności prognoz opóźnień w realizacji przedsięwzięć budowlanych za pomocą sztucznych sieci neuronowych. *Materiały Budowlane*, 6, 3–5.
- ANYSZ H. (2017). *Wykorzystanie sztucznych sieci neuronowych do oceny możliwości wystąpienia opóźnień w realizacji kontraktów budowlanych* (rozprawa doktorska). Warszawa, Politechnika Warszawska.
- ANYSZ H., IBADOV N. (2017). Neuro-fuzzy predictions of construction site completion dates. *Technical Transactions*, 6, 51–58, Civil Engineering.
- BARTKIEWICZ J. (red. Zieliński J.S.) (2000). *Inteligentne systemy w zarządzaniu*, PWN, Warszawa.
- CIESZYŃSKI K. (2006). *Zarządzanie procesem budowlanym*, Fundacja Edukacji Menedżerskiej Budowlanych, Warszawa.
- CIEŚLAK M., (red. Welfe W.) (1977). *Ekonometryczne modele rynku, tom 1, Metody ekonometryczne*, PWE, Warszawa.
- CZARNIGOWSKA A., HEJDUCKI Z., NAHURNY T.O., ROGALSKA M. (2006). Metody wyznaczania czasu trwania procesów budowlanych z uwzględnieniem pogodowych czynników ryzyka. *Przegląd Budowlany*, 1, 37–42.
- CZARNIGOWSKA A., SOBOTKA A. (2010). Przewidywalność czasu trwania budowy: Publiczne przedsięwzięcia drogowe. *Czasopismo Techniczne. Budownictwo*, 1-B, Zeszyt 2, 23–34.
- CZARNIGOWSKA A., SOBOTKA A. (2013). Zależność czas–koszt w przewidywaniu czasu realizacji budowy. *Budownictwo i Architektura*, 12, 23–30.
- CZARNIGOWSKA A. (2009). Kontrola postępu realizacji przedsięwzięcia metodą Earned Value. *Przegląd Budowlany*, 2, 50–55.

- DYTCZAK M., GINDA G., SZKLENNIK N. (2014). Identification of weather insensitive to construction schedules. *Technical Transactions*, 2-B (6), 291–297.
- ELSAWY I., HOSNY H., RAZEK M.A. (2011). A Neural Network Model for Construction Project Site Overhead Cost Estimating in Egypt. *International Journal of Computer Science Issues*, Vol. 8, No. 1, 273–283.
- FILASIEWICZ A. (1977). *Prognoza, Program, Plan*. Wiedza Powszechna, Warszawa.
- HAGAN M.T., DEMUTH H.B., BEALE M.H., DE JESUS O. (2016). *Neural Network Design*. 2nd edition, ISBN 978-0-9717321-7.
- HEJDUCKI Z., ROGALSKA M. (2017). *Harmonogramowanie procesów budowlanych metodami sprzężeń czasowych*. Politechnika Lubelska – Monografie, Lublin.
- HOŁA B., SCHABOWICZ K. (2010). Estimation of earthworks execution time cost by means of artificial neural networks. *Automation in Construction*, 19, 570–597.
- IBADOV N. (2016). Determination of the Risk Factors Impact on the Construction Project Implementation Using Fuzzy Sets Theory. *Acta Physica Polonica A*, Vol. 130, 107–111.
- Instytut Badawczy Dróg i Mostów (2008). *Instrukcja oceny efektywności ekonomicznej przedsięwzięć drogowych i mostowych dla dróg wojewódzkich*
- JAŚKOWSKI P. (2015). Methodology for enhancing reliability of predictive project schedules in construction. *Maintenance and Reliability*, 17 (3), 470–479.
- JUSZCZYK M. (2010). Modelowanie kosztów realizacji budynków mieszkalnych z zastosowaniem zespołów sztucznych sieci neuronowych. *Czasopismo Techniczne*, 1-B, 167–175.
- KIM G-H., SHIN J-M., KIM S., SHIN Y. (2013). Comparison of School Building Construction Cost Estimation Methods Using Regression Analysis, Neural Network, and Support Vector Machine. *CJournal of Building Construction and Planning Research*, 1, s. 1-7
- KAFTANOWICZ M., KRZEMIŃSKI M. (2015). Multiple-criteria Analysis of Plasterboard Systems. *Procedia Engineering*, 111, 364–370.
- KAPLIŃSKI O., DZIADOSZ A., REJMENT M. (2014). Użyteczność i zakres stosowania metody Earned Value Management przy realizacji kontraktów budowlanych. *Budownictwo i Architektura*, 13 (4), 257–364.
- KRZEMIŃSKI M. (2014). Use of the KASS Program in Scheduling. *Technical Transactions*, 2-B, 217–224.
- KULEJEWSKI J. (2010). *Metody harmonogramowania budowy z uwzględnieniem rozmytego charakteru danych*. Prace Naukowe. Budownictwo, z. 153, Oficyna Wydawnicza PW, Warszawa.
- LEŚNIAK A., PLEBANKIEWICZ E. (2010). *Opóźnienia w robotach budowlanych*. Zeszyty Naukowe WSOWL, Nr 3 (157), 332–339.

- LEŚNIAK A. (2012). Przyczyny opóźnień budowy w opiniach wykonawców. *Czasopismo Techniczne. Budownictwo 1-B/2012*, Zeszyt 2, 57–68.
- MARCINKOWSKI R. (2016). *Harmonogramowanie robót w budownictwie*. Systematyka procesu. Część 2. Builder (56).
- NOWAK E. (1998). *Prognozowanie gospodarcze. Metody, modele, zastosowania, przykłady*. Agencja Wydawnicza PLACET, Warszawa.
- OGUNLANA S.O., PROMKUNTONG K., JEARKJIRM V. (1996). Construction delays in a fast-growing economy: comparing Thailand with other economies. *International Journal of Project Management*, 14 (1), 35–45.
- OSOWSKI S. (1996). *Sieci neuronowe w ujęciu algorytmicznym*. WNT, Warszawa.
- OSOWSKI S. (2006). *Sieci neuronowe do przetwarzania informacji*. Oficyna Wydawnicza PW, Warszawa.
- PLEBANKIEWICZ E., JUSZCZYK M., MALARA J. (2015). Estimation of task completion times with the use of the PERT method on the example of real construction project. *Archives of Civil Engineering*, Vol. LXI (3), 51–62.
- POŁOŃSKI M., PRUSZYŃSKI K. (2008). Lokalizacja buforów czasu w metodzie łańcucha krytycznego w harmonogramach robót budowlanych (cz. I) – podstawy teoretyczne. *Przegląd Budowlany*, 2, 45–49.
- RADZISZEWSKA-ZIELINA E., ŚLADOWSKI G. (2017). Proposal of the Use of a Fuzzy Stochastic Network for the Preliminary Evaluation of the Feasibility of the Process of the Adaptation of a Historical Building to a Particular Form of Use. *Materials Science and Engineering*, 245, 072029, IOP Publishing.
- ROGALSKA M. (2016). *Wieloczynnikowe modele w prognozowaniu czasu procesów budowlanych*. Politechnika Lubelska – Monografie, Lublin.
- RUTKOWSKI L. (2012). *Metody i techniki sztucznej inteligencji*. PWN, Warszawa.
- RYBARCZYK A. (red.) (2008). *Sztuczne sieci Neuronowe. Laboratorium*. Wydawnictwo Politechniki Poznańskiej, Poznań.
- SAHA A. *Neural Network Models in Excel for Prediction and Classification*.  
<http://web.archive.org/web/20091026213444/>  
<http://www.geocities.com/adotsaha/NNinExcel.html>.
- SAMBASIVAN M., SOON Y.W. (2007). Causes and effects of delays in Malaysian construction industry. *International Journal of Project Management*, 25, 517–526.
- SKORUPKA D., KUCHTA D., GÓRSKI M. (2012). *Zarządzanie ryzykiem w projekcie*. WSOWL, Wrocław.
- SODIKOV J. (2005). Cost Estimation of Highway Projects in Developing Countries: Artificial Neural Network Approach. *Journal of the Eastern Asia Society for Transportation Studies*, Vol. 6, 1036–1047.

Statsoft. *Internetowy podręcznik Statistica*.

[http://www.statsoft.pl/textbook/stathome\\_stat.html](http://www.statsoft.pl/textbook/stathome_stat.html)

<http://www.statsoft.pl/textbook/stfacan.html>.

TADEUSIEWICZ R. (red. Nałęcz M.) (2000). *Biocybernetyka i inżynieria medyczna. T. 6. Sieci Neuronowe*. Akademicka Oficyna Wydawnicza EXIT, Warszawa.

ZAVADSKAS E.K, TURSKIS Z. (2008). A New Logarithmic Normalization Method in Games Theory. *INFORMATICA*, 19 (2), 303–314.

ZELIAŚ A., PAWEŁEK B., WANAT S. (2013). *Prognozowanie ekonomiczne. Teoria, przykłady, zadania*. PWN, Warszawa.