



Użyteczność modeli parametrycznych i sztucznych sieci neuronowych w prognozowaniu kosztów produkcji

*ZBIGNIEW LESZCZYŃSKI *, TOMASZ JASIŃSKI ***

Streszczenie

Celem artykułu jest analiza użyteczności modeli parametrycznych i sztucznych sieci neuronowych w prognozowaniu kosztów produkcji. Prognozowane koszty produkcji stanowią fundamentalną determinantę dla podejmowanych przez inżynierów decyzji technicznych i biznesowych związanych z zarządzaniem produkcją i kosztami produkcyjnymi. W pierwszej części artykułu przedstawiono ramy konceptualne budowy modelu prognozowania parametrycznego kosztów produkcji, wielowymiarowego o zależnościach liniowych i nieliniowych. Następnie omówiono istotę i zastosowanie sztucznych sieci neuronowych jako modelu – nieparametrycznego prognozowania kosztów produkcji. W obu częściach artykułu przeprowadzono badanie empiryczne z wykorzystaniem analizy regresji oraz sztucznych neuronów połączonych w sieci. Badanie empiryczne prezentuje procedury budowy modeli – parametrycznego i nieparametrycznego prognozowania kosztów produkcji oraz ich wady i zalety. W toku procedury badawczej przedstawiono zastosowanie analizowanych modeli prognozowania kosztów produkcji w określonym środowisku przemysłowym.

Słowa kluczowe: model prognozowania kosztów, prognozowanie parametryczne, sztuczne sieci neuronowe, koszty prognozowane.

Abstract

The usefulness of parametric models and artificial neural networks in the estimation of production costs

The aim of the paper is to analyze parametric models and artificial neural networks in terms of their suitability as estimation tools of the production costs. Estimated production costs are a fundamental determinant of the decision-making process by costs engineers relating to design and management costs of new products, infrastructure projects and production lines. The first part of the paper presents a conceptual framework for the construction of a model of production costs parametric estimation, multi-dimensional with linear and nonlinear dependency. It then discusses the nature and use of artificial neural networks as nonparametric estimates of production costs. In both parts of the article, an empirical study is conducted with the use of adequate statistical methods and artificial neurons. This study presents procedures for construction of models of parametric and nonparametric estimation of production costs and discusses their advantages and disadvantages. It also presents the application and usefulness of both models for estimating production costs in production environment.

Keywords: model of cost estimation, parametric estimation, artificial neural neurons, estimated costs.

* Dr hab. Zbigniew Leszczyński, profesor nadzwyczajny, Politechnika Łódzka, Instytut Nauk Społecznych i Zarządzania Technologiami, zbigniew.leszczynski@p.lodz.pl

** Dr inż. Tomasz Jasiński, Politechnika Łódzka, Instytut Nauk Społecznych i Zarządzania Technologiami, tomasz.jasinski@p.lodz.pl



Wprowadzenie

Jednym z głównych obszarów inżynierii kosztów¹ jest prognozowanie kosztów produkcji. Prognozowane koszty produkcji stanowią fundamentalną determinantę dla podejmowanych przez inżynierów kosztów decyzji technicznych i biznesowych związanych z projektowaniem i zarządzaniem kosztami nowego produktu². Brinke (2004, s. 534–545), NASA (2002a), Taylor (1997), Mauchand i in. (2008, s. 159–172) w swoich badaniach wykazali, że 70–80% przyszłych kosztów wytworzenia produktu zostaje „zaprogramowanych” podczas jego projektowania. Podejmowanie nieprawidłowych decyzji projektowych w tej fazie cyklu życia produktu może być bardzo kosztowne w fazie produkcji. Modyfikacje i zmiany konstrukcyjne produktu w fazie produkcji są często niewykonalne bądź bardzo drogie. Przeprojektowanie produktu w fazie jego tworzenia następuje pod wpływem „niepokojących” informacji zwrotnych, które otrzymuje projektant, a będących odchyleniami projektowanych kosztów produktu w stosunku do kosztów prognozowanych – postulowanych (sterowanie wyprzedzające³). W celu redukcji kosztów produkcji na etapie projektowania produktu stosuje się tzw. projektowanie współbieżne⁴ (*concurrent engineering*), którego fundamentalnym elementem jest prognoza kosztów produkcji (Rush, Roy, 2001, s. 271–284). Prognozowane koszty produktu winny być zatem „zbliżone do prawdziwych”, satysfakcjonujące przedsiębiorstwo i potencjalnego klienta.

Horngren (2012, s. 362–416) bardzo wyraźnie artykułuje znaczenia prognozowania kosztów dla prowadzenia analizy ich „zachowania” (*how costs behave*) pod wpływem zmian parametrów technologicznych produkcji i poziomu produkcji. Uważa on, że menedżerowie muszą znać przyszłe zachowanie kosztów, aby podejmować decyzje operacyjne i strategiczne, nie tylko dotyczące projektowanych produktów, ale również przyszłych działań produkcyjnych.

¹ Amerykańskie Stowarzyszenie Inżynierów Kosztów (AACE) definiuje inżynierię kosztów jako obszar praktyki inżynierskiej, gdzie paradygmaty i metody naukowe z dziedziny inżynierii procesowej, technologii produkcji, technologii przemysłowej, technologii projektowania, matematyki, badań operacyjnych, sieci neuronowych, rachunku kosztów, analizy wartości są wykorzystane dla potrzeb prognozowania i kontroli kosztów oraz optymalizowania rentowności produktów, projektów i procesów produkcji (Leszczyński, Jasiński, 2015; Rajkumar, 2003, s. 1–30; Clark, Lorenzoni, 1997; Westney, 1997).

² Produktem może być wyrób wytwarzany w produkcji masowej, zaawansowane technologicznie urządzenie, projekt infrastrukturalny, proces i linie technologiczne (obiekt prognozowania).

³ Sterowanie wyprzedzające w literaturze angielskiej jest nazywane *feed forward* (Nishimura, 2003, s. 139–146).

⁴ Projektowanie współbieżne (*concurrent engineering*, CE) – dziedzina równoległego, zintegrowanego i przewidującego skutki – kosztowe, projektowania produkcji (różne obiekty kosztowe). Metodyka równoległego i zintegrowanego projektowania obiektów produkcji pozwala na poprawę ich konkurencyjności poprzez zmniejszenie kosztów, zapewnienie jakości i skrócenie czasu cyklu produkcji. Projektowanie CE jest rozwinięciem koncepcji projektowania sytuacyjnego (systemowego) z wyraźnym ukierunkowaniem na paradygmat CE (Rajkumar, 2003).

Badania przeprowadzone w Stanach Zjednoczonych w końcu lat 90. XX w. przez Masona z California Polytechnic University (Masona i in., 1997) wykazały, że w przedsiębiorstwach produkcyjnych planiści kosztów regularnie korzystają z analizy regresji w celu estymacji funkcji matematycznych (modelu matematycznego) wykorzystywanych do parametrycznego prognozowania kosztów produkcji. Z badań tych wynika, że doskonalenie parametrycznego prognozowania kosztów produkcji nie jest współmierne ze zmianami zachodzącymi w technologiach przemysłowych, a ich dokładność, złożoność i adekwatność są niewystarczające. Podobne stanowisko zaprezentowali Gemen i in. (1997, s. 1–58) oraz Marquez i in. (1998, s. 129–135), zarzucając parametrycznemu prognozowaniu kosztów produkcji zmienność i tendencyjność. Uznali oni, że istotność modelu prognostycznego (funkcji matematycznych) zależy od poprawności matematycznego opisu zależności między zmiennymi modelu oraz od zbioru danych używanych do jego budowy. Słusznie twierdzili, że nieprawidłowa parametryzacja modelu (zależności między zmiennymi) prowadzi do jego tendencyjności. Badania cytowanych akademików udowodniły, że parametryczne prognozowanie kosztów produkcji pozostawało na niezmiennym poziomie w stosunku do zmieniającego się środowiska przemysłowego⁵ (zaawansowane technologie produkcyjne, konstrukcja produktu, cyfryzacja produkcji, złożone technologicznie produkty).

W początkach obecnego stulecia odnotowano duże zainteresowanie przedsiębiorstw produkcyjnych nowoczesnymi narzędziami prognozowania kosztów produkcji. Efektem badań Wanga, Stocktona i Baguleya (2000), prowadzonych w Stanach Zjednoczonych, była prezentacja nowego modelu prognozowania kosztów produkcji, a mianowicie sieci neuronowych. W swoich badaniach Wang, Stockton i Baguley (2000) wykazali, że sieci neuronowe potencjalnie mogą przezwyciężyć wady i ograniczenia parametrycznego prognozowania kosztów produkcji (Setyawati i in., 2002). Sieci neuronowe mogą być złożonymi modelami, nieparametrycznego prognozowania kosztów produkcji, co jest jedną z głównych ich zalet w stosunku do tradycyjnego podejścia – prognozowania parametrycznego. Sieci neuronowe mogą prognozować koszty produkcji bez konieczności matematycznego opisu funkcjonalnej zależności między zmiennymi niezależnymi (nośniki kosztów) a zmienną zależną (kosztami) oraz konieczności definiowania założeń dotyczących postaci kosztów (Heping, 2010, s. 201–224).

Celem artykułu jest zbadanie w aspekcie teoretycznym i aplikacyjnym użyteczności modeli matematycznych (model prognozowania parametrycznego) oraz sztucznych sieci neuronowych (model prognozowania nieparametrycznego) w prognozowania

⁵ Środowiskiem przemysłowym autorzy artykułu nazywają określone warunki technologiczne, organizacyjne produkcji, inżynierie produkcji oraz określony typ i konstrukcję obiektu produkcji.

kosztów produkcji⁶. Metodyka badawcza przyjęta w niniejszej pracy to badanie literaturowe w zakresie sztucznej inteligencji, inżynierii kosztów, metod ilościowych, zarządzania kosztami oraz badanie empiryczne prowadzone metodą indukcyjną w formie rozbudowanego studium przypadku. Autorzy opracowali studium przypadku na podstawie badań własnych realizowanych w pracy akademickiej, w firmach konsultingowych oraz danych pozyskanych z literatury anglojęzycznej. W toku postępowania badawczego zaprezentowano analizę regresji i sztuczne sieci neuronowe. W badaniu empirycznym przedstawione zostały procedury budowy modeli prognozowania kosztów produkcji (parametrycznego i nieparametrycznego) oraz ich wady i zalety. Głównym problemem badawczym w artykule nie jest tylko istota, wiarygodność i procedury budowy modeli prognozowania kosztów produkcji, ale głównie ich użyteczność w procesie zarządzania kosztami w określonym środowisku przemysłowym. Innowacyjnością w tym artykule jest próba zaprezentowania modeli matematycznych będących efektem analizy regresji oraz sztucznych sieci neuronowych jako nowoczesnych modeli prognozowania kosztów produkcji (Marquez i in., 1998, s. 129–135).

Struktura artykułu jest następująca. W pierwszej części zaprezentowano parametryczne prognozowanie kosztów produkcji – liniowe, nieliniowe, wielowymiarowe. Omówiono ich podstawy teoretyczne, procedury oraz możliwości stosowania w praktyce przemysłowej. W następnej części skupiono się na zagadnieniach związanych z konceptualnymi ramami sieci neuronowych oraz wykorzystania ich w prognozowaniu kosztów produkcji. W obu częściach artykułu przeprowadzono badania empiryczne. Artykuł zakończono wnioskami.

⁶ Związek opisywanych modeli prognozowania kosztów produkcji z tradycyjnym budżetowaniem oraz ich rolę w zarządzaniu jest bardzo słaby lub wręcz nie istnieje. Tradycyjne budżetowanie kosztów produkcji to podejście „analogiczne”, tzn. szacowanie kosztów na poziomie kosztu obiektu analogicznego z uwzględnieniem różnic, w takich czynnikach, jak: skala, lokalizacja, złożoność, ceny, kursy walut, inflacja. Przy sporządzaniu budżetów kosztów produkcji planiści opierają się zazwyczaj na wiedzy księgowo-finansowej i nie uwzględniają aspektów inżynierijno-technologicznych produkcji. Tradycyjne budżetowanie kosztów stanowi realne narzędzie kontroli kosztów w przedsiębiorstwach, w których stopień zaawansowania technologicznego produkcji nie jest zbyt wysoki. W przedsiębiorstwach nowych technologii wykorzystujących maszyny numeryczne (mechatronika) oraz inteligentne systemy zarządzania produkcją (tzw. inteligentne fabryki) to technologie produkcyjne i inteligentne systemy zarządzania produkcją precyzyjnie sterują produkcją, eliminując przyczyny wszelkich odchyłeń produkcyjnych i kosztowych (Ruiza i in., 2011, s. 1469–1482). Horngren (2012, s. 362–416) wyraźnie rozdziela budżetowanie kosztów od prognozowania (*estymation*) kosztów (z wykorzystaniem modeli matematycznych). Autor ten określa prognozowanie kosztów jako badanie ich przyszłych zachowań. W przedsiębiorstwach prognozowane koszty produkcji spełniają swoją rolę zarządczą w fazie projektowania kosztów nowych produktów/projektów (Bajaj i in., 2012; Huanga i in., 2012, s. 417–431).

1. Prognozowanie parametryczne kosztów produkcji – ramy konceptualne

Prognozowanie parametryczne kosztów produkcji jest oparte na zależnościach empirycznych i matematycznych. Prognozowane koszty produkcji są funkcją parametrów technologicznych obiektu prognozowania (obiekt kosztów). Parametry to fizyczne lub funkcjonalne cechy obiektu prognozowania (produktywność, wydajność, energochłonności, materiałochłonność, powierzchnia, objętość, pojemność, czasy przebiegu, cykle produkcyjne) (Nicholas, Steyn, 2012, s. 429). Prognozowanie parametryczne kosztów produkcji uwzględnia powtarzalne relacje logiczne⁷ między zmiennymi niezależnymi oraz zmienną zależną – kosztami. Zmienne niezależne – to nośniki kosztów (parametry technologiczne), charakterystyczne dla obiektu produkcji. Proste modele prognozowania parametrycznego kosztów produkcji bazują zazwyczaj na zależnościach liniowych, jednowymiarowych lub dwuwymiarowych (jednego lub dwóch nośnikach kosztów). Złożone modele prognozowania parametrycznego wymagają stosowania wielu zmiennych (wielu nośników kosztów) oraz funkcji nieliniowych, wielowymiarowych.

Prognozowanie parametryczne kosztów produkcji jest oparte na danych historycznych odnoszonych do nowych obiektów kosztów. Dane historyczne stanowią podstawowy „budulec” modeli prognozowania kosztów produkcji. W procesie budowy modeli prognozowania parametrycznego kosztów produkcji wykorzystuje się metody statystyczne, takie jak analiza regresji. Jeżeli technologia powstania nowego obiektu kosztów (projektu, produktu, linii produkcyjnych) nie zmienia się, wykorzystujemy w modelu prognozowania znane zależności cech konstrukcyjnych, technologicznych, produkcyjnych obiektu kosztów i znane nośniki kosztów. Ulegają ilościowej korekcie parametry modelu.

Dysert (2008) zalicza do cech prognozowania parametrycznego kosztów produkcji:

- krótki czas prognozowania w stosunku do innych technik prognozowania;
- szeroką wiedzę z inżynierii produkcji analizowanego obiektu kosztowego;
- powiązanie ilościowego zasilania modeli prognozowania z algorytmami modelu, generującymi ilościowe wyniki prognozy;
- identyfikowalność wszystkich elementów kosztów;
- generowanie raportów prognozowania w spójnych formatach;
- zgodność z analizą wrażliwości prognoz scenariuszowych obiektu kosztowego (zmiany jego cech użytkowych);
- uwzględnianie cech konstrukcyjnych i technologicznych obiektu prognozowania;
- generowanie miar jakości dopasowania modelu; stopnia, w jakim model wyjaśnia kształtowanie się zmiennej objaśnianej (R^2 – współczynnik determinacji).

⁷ W terminologii angielskiej zależności te są nazywane *cost estimating relationship (CER)*, co oznacza szereg równań matematycznych (model matematyczny) odwzorowujących zależności między kosztami produkcji – zmiennymi zależnymi a nośnikami kosztów – zmiennymi niezależnymi (równania te odzwierciedlają zależności technologiczno-produkcyjne) (Rajkumar i in., 2001, s. 147–162).

Model prognozowania parametrycznego kosztów produkcji przygotowywany jest w kilku etapach (Dysert, 1999; Sae-Hyun, 2010, s. 844–852; Sonmez, 2008, s. 1011–1006; Rajkumar i in., 2001, s. 147–162; Setyawati i in., 2002), scharakteryzowanych poniżej i zobrazowanych na rysunku 1.

Zdefiniowanie zakresu modelu prognozowania. Zakres parametrycznego modelu prognozowania kosztów produkcji obejmuje: nośniki kosztów, podstawowe rodzaje kosztów będące przedmiotem prognozy, stopień wiarygodności oraz definicję jego przeznaczenia końcowego. Końcowe przeznaczenie modelu to przygotowanie prognozy kosztu obiektu (projektu, produktu, linii produkcyjnej). Typ obiektu podlegającego prognozowaniu determinuje nośniki kosztów (zmienne niezależne) oraz rodzaje kosztów, które będą szacowane.

Zbieranie danych w celu budowy modelu prognozowania. Jakość modelu jest zdeterminowana jakością danych wykorzystanych do jego budowy. Zakres danych winien obejmować wszystkie proponowane kluczowe nośniki kosztów, a także wszelkie inne dane, które mogą mieć wpływ na koszty.

Normalizacja zebranych danych. Normalizacja danych zakłada korektę historycznych danych kosztowych. Celem korekty jest niwelowanie różnic pomiędzy danymi historycznymi a standardową bazą danych wykorzystywanych przy budowie modelu prognozowania.

Analizowanie znormalizowanych danych i budowa funkcji matematycznych. Zasadniczą metodą analizy danych jest analiza regresji kosztów w stosunku do ich nośników (cech konstrukcyjnych i technologicznych obiektu prognozowania). Efektem prowadzonej analizy regresji na podstawie zebranych danych historycznych są funkcje matematyczne, najwiarygodniej odzwierciedlające/ych zależności między nośnikami kosztów (zmiennymi niezależnymi) a poziomem kosztów produkcji (zmiennymi zależnymi). Funkcje matematyczne są składowymi modelu prognozowania. Zwykle przybierają formę zależności liniowych lub nieliniowych z jedną lub wieloma zmiennymi:

$$Y = a + b X_1 + c X_2 + \dots$$
 (wielowymiarowa zależność liniowa);

$$Y = a + b X_1^V + c X_2^Z + \dots$$
 (wielowymiarowa zależność nieliniowa);

X_1, X_2 – to zmienne niezależne (wejściowe);

a, b, c – parametry regresji; v i z – wykładniki regresji.


Tworzenie aplikacji modelu prognozowania kosztów produkcji (interfejsu). Program użytkowy modelu prognozowania kosztów wymaga utworzenia interfejsu użytkownika. Zadaniem interfejsu jest w łatwy i prosty sposób dostarczanie danych do modelu prognozowania. W większości przypadków użytkownicy korzystają z arkusza kalkulacyjnego Excel, a więc wówczas nie jest konieczna realizacja tego etapu.

Testowanie modelu prognozowania kosztów. Jednym z najważniejszych kroków w opracowaniu modelu prognozowania jest sprawdzenie jakości dopasowania modelu. Kluczową miarą dopasowania jakości modelu jest wskaźnik determinacji (R^2). Wartość R^2 determinuje stopień (siłę), w jakim zbudowany model prognozowania wyjaśnia kształtowanie się zmiennej objaśnianej – kosztów. Wskazane jest również wykonanie

analizy logicznej modelu w celu sprawdzenia, czy gwarantuje on istnienie oczywistych i oczekiwanych relacji między zmiennymi zależnymi i niezależnymi.

Dokumentowanie modelu prognozowania kosztów produkcji. Model prognozowania kosztów oraz adekwatne aplikacje mogą być udokumentowane w formie instrukcji. Instrukcja powinna zawierać jasno opisane wymagania dotyczące danych wejściowych modelu.

Rysunek 1. Etapy opracowania modelu prognozowania parametrycznego kosztów produkcji (SPBP*)



* W terminologii anglojęzycznej opracowanie modelu parametrycznego prognozowania nazywa się *Statistically Preprocessed data – Based Parametric (SPBP) cost model* (Sae-Hyun i in., 2019, s. 846).

2. Budowa modelu prognozowania parametrycznego kosztów produkcji z wykorzystaniem narzędzi statystycznych⁸

W celu zaprezentowania modelu prognozowania parametrycznego kosztów produkcji z wykorzystaniem danych rzeczywistych przeanalizujemy dwa badania empiryczne – liniowe, nieliniowe i wielowymiarowe zależności między kosztami produkcji (zmiennymi zależnymi) i nośnikami kosztów (zmiennymi niezależnymi).

Przykład nieliniowego modelu prognozowania parametrycznego kosztów dotyczy projektu budowlanego „wieży chłodniczej”, stosowanej w zakładach przemysłowych w celu zapewnienia obiegu wody chłodzącej do recyklingu⁹. Kluczowe parametry konstrukcyjne projektu (nośniki kosztów) mające wpływ na koszty budowy wieży chłodniczej obejmują: zakres chłodzenia (X_1), efekt chłodzenia (X_2), natężenie przepływu (X_3). W tabeli 1 przedstawiono rzeczywiste koszty i parametry konstrukcyjne (nośniki kosztów) sześciu ukończonych i oddanych do użytkowania wież chłodniczych. Koszty zostały znormalizowane.

Tabela 1. Parametry konstrukcyjne (nośniki kosztów)
i rzeczywiste koszty budowy wież chłodniczych

Zmienne niezależne (nośniki kosztów)			Zmienna zależna
zakres chłodzenia (X_1) stopnie F	efekt chłodzenia (X_2) stopnie F	natężenie przepływu (X_3) galon (1000)/min.	koszty rzeczywiste (y) (\$)
30	15	50	1 040 200
30	15	40	787 100
40	15	50	1 129 550
40	20	50	868 200
25	10	30	926 400
35	8	35	1 332 400

Źródło: opracowanie własne na podstawie Dysert (2008).

⁸ W prezentowanych badaniach empirycznych (projekt budowlany, linia produkcyjna) zastosowano analizę regresji, ponieważ obiekty kosztów nie wymagają skomplikowanych opisów matematycznych zależności pomiędzy zmiennymi modelu (nośnikami kosztów a kosztami). Liczba zmiennych niezależnych jest niewielka (max 5). Budowa funkcji kosztów bazuje na małych zbiorach danych historycznych. Zbudowane modele prognozowania kosztów są adekwatne do środowiska przemysłowego, w których funkcjonują obiekty prognozowania.

⁹ W przykładzie wykorzystano dane historyczne dotyczące budowy 6 wież chłodniczych (horyzont czasowy danych to czas budowy wież chłodniczych, budowy zostały ukończone): „Induced Draft Cooling Towers” (Dysert, 2008).

Dane z tabeli 1 stanowiły podstawę empiryczną do przeprowadzenia analiz regresji (krzywoliniowej) w celu ustalenia matematycznej funkcji prognozowania kosztów budowy wież chłodniczych (1):

$$Y = 86600 + 8450 (X_1)^{0,65} - 68600 (X_2) + 76700 (X_3)^{0,70} \quad (1)$$

Wzrost fizycznej wielkości nośników kosztów (X_1, X_3) powoduje wzrost kosztów inwestycji (wykładniczo), natomiast wzrost fizycznej wielkości nośnika kosztów (X_2) powoduje spadek kosztów inwestycji (liniowo). Współczynnik determinacji $R^2 = 0,96$. Poziom współczynnik determinacji świadczy o wysokiej jakości dopasowania modelu – stopnia, w jakim model wyjaśnia kształtowanie się zmiennej objaśnianej (Y) – kosztów budowy wież chłodniczych (prawidłowo odzwierciedla zależności pomiędzy zmiennymi modelu – nośnikami kosztów (X) i kosztami budowy wież chłodniczych (Y)).


Wykorzystując funkcję matematyczną (1) dokonujemy prognozowania kosztów budowy wieży chłodniczej przy różnych wartościach parametrów konstrukcyjnych (nośnikach kosztów – zmienne niezależne) (tabela 2, rysunek 2).

Tabela 2. Parametry konstrukcyjne (nośniki kosztów)
i estymowane koszty budowy wież chłodniczych

Zakres chłodzenia (X_1) stopnie F	Metoda chłodzenia (X_2) stopnie F	Natężenie przepływu (X_3) galon(1000)/min.	Koszty estymowane (Y) (\$)
30	15	25	559 000
30	15	30	658 000
40	15	40	1 001 000
40	15	50	1 173 000
40	15	75	1 562 000

Źródło: opracowanie własne na podstawie Dysert (2008).

Rysunek 2. Nieliniowa funkcja kosztów budowy wieży chłodniczej z wieloma zmiennymi niezależnymi (nośniki kosztów – parametry modelu)



Źródło: opracowanie własne na podstawie Dysert (2008).

Drugi przykład nieliniowego modelu parametrycznego prognozowania kosztów produkcji¹⁰ dotyczy węzła technologicznego (linia obróbki mechanicznej komponentów, linia montażowa, linia kontroli jakości) zakładu produkcyjnego o produkcji masowej powtarzalnej¹¹. Wymienione linie produkcyjne są obsługiwane przez maszyny numeryczne (sterowane cyfrowo) i tradycyjną kontrolę jakości. Kluczowe parametry (nośniki kosztów) technologiczne linii obróbki mechanicznej, montażowej i kontroli jakości mające wpływ na koszty produkcyjne obejmują:

¹⁰ Koszty produkcji nie obejmują kosztów materiałów bezpośrednich, ponieważ zakład produkcyjny dokonuje obróbki i montażu zakupionych komponentów.

¹¹ W przykładzie wykorzystano dane pochodzące z projektów realizowanych w Instytucie Nauk Społecznych i Zarządzania Technologiami Politechniki Łódzkiej w ramach badań statutowych „Inżynieria kosztów”. Horyzont czasowy danych historycznych dotyczących zakładu produkcji obejmuje 12 miesięcy, $n = 12$ (jeden rok).

- produktywność maszyn (X_1) – ilość zużytych maszynogodzin dla wytworzonej produkcji (maszynogodziny),
- liczba serii produkcyjnych (X_2) – liczba uruchomionych serii produkcyjnych dla grup asortymentowych,
- produktywność montażu (X_3) – liczba wykonanych operacji montażowych dla wytworzonej produkcji (operacje montażowe),
- liczba serii montażowych (X_4) – liczba uruchomionych serii montażowych dla grup asortymentowych,
- liczba partii przeznaczonych do kontroli jakości (X_5) – liczba uruchomionych cykli kontroli jakości dla wytworzonej wielkości produkcji.

W tabeli 3 przedstawiono rzeczywiste koszty produkcji i parametry technologiczne produkcji (nośniki kosztów). Koszty rzeczywiste zostały znormalizowane.

Tabela 3. Rzeczywiste koszty produkcji i wartość parametrów technologicznych (nośników kosztów) zakładu produkcyjnego

Linia obróbki mechanicznej			Linia montażowa			Linia kontroli jakości	
koszty rzeczywiste (Y_p) (zł)	wielkość produkcji (X_1) (mh)	liczba serii produkcyj- nych (X_2)	koszty rzeczywiste (Y_M) (zł)	liczba operacji montażowych (X_3) (operacje montażowe)	liczba serii montażowych (X_4)	koszty rzeczywiste (Y_K) (zł)	liczba cykliów kontroli jakości (X_5)
130 600	301	11	65 300	2990	99	12 400	150
149 860	344	15	74 930	3221	135	13 100	160
127 910	298	10	63 955	3001	90	14 500	180
130 090	301	11	65 045	3111	99	16 900	200
126 280	299	10	63 140	3421	90	19 000	210
131 550	310	12	65 775	3100	108	19 800	220
124 020	294	10	62 010	3001	90	23 800	230
131 990	311	12	65 995	3115	108	25 000	250
138 740	321	13	69 370	3400	117	30 300	270
141 560	332	14	70 780	3401	126	32 000	287
132 120	315	12	66 060	3115	108	37 000	298
154 820	351	16	77 410	3560	144	39 000	310
$Y_p = 358,35 X_1 + 1320,47 X_2 + 6106,44$ $R^2 = 0,99;$ $F = 143$			$Y_M = 1,15 X_3 + 251,11 X_4 + 36310,64$ $R^2 = 0,98;$ $F = 110$			$Y_K = 4132,61 \times e^{0,0073 X_5}$ $R^2 = 0,92$	
$Y = [358,35 X_1 + 1320,47 X_2 + 1,15 X_3 + 251,11 X_4 + 42417,08] + [4132,61 \times e^{0,0073 X_5}]$							

Źródło: opracowanie własne.

Opierając się na danych z tabeli 3, przeprowadzono trzy analizy regresji (liniowe i krzywoliniowe) w celu ustalenia funkcji matematycznej kosztów produkcji zakładu produkcyjnego:

$$Y = [358,35 X_1 + 1320,47 X_2 + 1,15 X_3 + 251,11 X_4 + 42417,08] + [4132,61 \times e^{0,0073 X_5}] \quad (2)$$

Z powyższego równania wynika, że zmienne niezależne $(X_1), (X_2), (X_3), (X_4)$ wpływają liniowo na poziom kosztów produkcyjnych (rysunek 3), natomiast zmienna (X_5) ma wpływ nieliniowy – wykładniczy (rysunek 4). Zmienne niezależne są dodatnio skorelowane z poziomem kosztów produkcji. Wzrost liczby nośników kosztów: $(X_1), (X_2), (X_3), (X_4)$ powoduje wzrost kosztów produkcji zakładu produkcyjnego. Nośniki kosztów: $(X_1), (X_2), (X_3), (X_4)$ wpływają proporcjonalnie na poziom kosztów produkcji, natomiast nośnik kosztów (X_5) wpływa nieproporcjonalnie (wykładniczo) na poziom kosztów produkcji. Współczynniki determinacji R^2 mieszczą się w przedziale 0,92–0,99, co świadczy o wysokiej jakości dopasowania modelu (funkcja kosztów prawidłowo odzwierciedla zależności pomiędzy nośnikami kosztów a kosztami produkcji zakładu produkcyjnego).


Wykorzystując funkcję matematyczną (2) prognozujemy koszty dla zakładu produkcyjnego przy różnych wartościach parametrów technologicznych – nośnikach kosztów $(X_1), (X_2), (X_3), (X_4), (X_5)$ (tabela 4).

Tabela 4. Wartość parametrów technologicznych produkcji (nośników kosztów) i estymowane koszty produkcji

(Y) Koszty estymowane (zł)	(X ₁) (Mh)	(X ₂) (serie produkcyjne)	(X ₃) (operacje montażowe)	(X ₄) (serie montażowe)	(X ₅) (cykle kontroli jakości)
226 880	320	14	3200	104	225
233 131	324	17	2958	102	235
239 919	330	18	3345	110	240


Źródło: opracowanie własne.

Rysunek 3. Funkcja liniowa kosztów produkcji z dwiema zmiennymi niezależnymi dla linii obróbki mechanicznej¹²



Źródło: opracowanie własne.

Rysunek 4. Funkcja wykładnicza kosztów produkcji z jedną zmienną niezależną dla linii kontroli jakości



Źródło: opracowanie własne.

¹² Analogicznie prezentuje się funkcja kosztów produkcji linii montażowej.

Prognozowanie parametryczne to cenny model przygotowywania prognoz kosztów produkcji we wczesnych koncepcjach powstawania produktu, projektu budowlanego, linii produkcyjnych oraz badania „zachowania” (*how costs behave*) kosztów produkcji przy różnych parametrach technologicznych procesów produkcyjnych. Model ten jest często wykorzystywany w prowadzonych studiach wykonalności wymienionych obiektów kosztowych. Wysoką wiarygodność modeli prognozowania parametrycznego kosztów produkcji determinuje:

- jakość zebranych danych dotyczących obiektów kosztowych i wykorzystanych do budowy funkcji kosztów;
- wiedza planistów kosztów z dziedziny inżynierii, technologii i organizacji produkcji konieczna do zdefiniowania matematycznych zależności między zmiennymi;
- precyzyjna wartość zmiennych niezależnych (nośników kosztów – parametrów technologicznych).

W praktyce gospodarczej dla wielu planistów kosztów spełnianie tych warunków jest trudne ze względu na brak wiedzy w obszarze inżynierii produkcji (szczególny problem stanowi warunek drugi). Kształcenie „inżynierów kosztów” w dużym stopniu rozwiązuje ten problem w zarządzaniu przedsiębiorstwem. Dwie dekady temu określenie „inżynier kosztów” nie było powszechnie znane w praktyce. Menedżerowie powiązani z tą dziedziną nie mieli silnego zaplecza akademickiego. Przedsiębiorstwa innowacyjne i zaawansowane technologicznie wymusiły na uczelniach technicznych kształcenie świadomych inżynierów kosztów w przemyśle.

3. Sztuczne sieci neuronowe – ramy konceptualne

Sztuczne sieci neuronowe (ANN – *Artificial Neural Networks*) stanowią względnie nowy sposób analizy danych oraz prognozowania. Początek ANN datowany jest na lata 40. ubiegłego stulecia¹³, jednak wzrost popularności ANN w praktyce gospodarczej jest ściśle związany z dynamicznym rozwojem systemów komputerowych, który miał miejsce w ostatnich dwóch dekadach.


ANN są siatką połączonych ze sobą sztucznych komórek nerwowych, czyli sztucznych neuronów. Każda pojedyncza komórka stanowi element naśladujący w pewnym stopniu rozwiązania biologiczne. Mimo iż nie stanowi ona wiernej kopii neuronów wchodzących w skład systemu nerwowego żywych organizmów, to jednak liczne analogie pozwalają sztuczemu modelowi w wielu przypadkach pracować w sposób zbliżony z pierwowzorem. Na rysunku 5 zaprezentowano ogólny schemat budowy sztucznej komórki nerwowej. Odpowiednikiem biologicznych dendrytów¹⁴, czyli

¹³ Za początek ANN uważany jest rok 1943, w którym McCulloch i Pitts w pracy pt. *A logical calculus of ideas immanent in nervous activity* zaprezentowali pierwszy matematyczny model neuronu (McCulloch, Pitts, 1943).

¹⁴ Są to struktury neuronu odpowiedzialne za wprowadzanie sygnałów do wnętrza komórki.

struktur, których zadaniem jest wprowadzanie sygnałów wejściowych do wnętrza komórki, są tzw. wejścia, oznaczone na rysunku 5 jako X_1 do X_n . Rolę jądra komórki pełni tzw. funkcja aktywacji¹⁵, zaś w roli aksonu¹⁶ wyjście y . Ponieważ *de facto* nie istnieje w sztucznych sieciach neuronowych struktura odpowiadająca synapsie¹⁷, jej rola została ograniczona do sumowania wartości sygnałów wejściowych pojawiających się na sztucznych dendrytach. Pewne funkcje synapsy może potencjalnie pełnić wspomniana wcześniej funkcja aktywacji, wchodząca w skład komórki nerwowej. Istotnym elementem ANN są tzw. wagi, oznaczone na rysunku 5 jako w_1 do w_n . Są to pewne liczby rzeczywiste. Ich liczba nie jest przypadkowa. Każda z wag sprzężona jest z jednym wejściem do komórki. Sygnały (liczby) pojawiające się na wejściach sztucznego neuronu mnożone są przez wartość wagi połączonej z daną strukturą wejściową. Tak powstałe iloczyny są następnie sumowane, tworząc tzw. całkowite pobudzenie neuronu (oznaczone na rysunku jako e). Na dalszym etapie funkcjonowania komórki ulega ono modyfikacji poprzez użycie wspomnianej powyżej funkcji aktywacji, by następnie opuścić komórkę nerwową i stanowić sygnał wejściowy kolejnych komórek, albo odpowiedź sieci (jeżeli komórka była elementem ostatniej warstwy ANN).

Rysunek 5. Schemat pojedynczego neuronu



Źródło: opracowanie własne.

ANN to model prognozowania nieparametrycznego kosztów produkcji. Możliwe jest to poprzez wykorzystanie jednej z głównych zalet ANN, a mianowicie faktu, że nie jest konieczna znajomość zależności łączących zmienne niezależne ($X_1 \dots X_n$) modelu ze zmienną zależną (Y) (nośniki kosztów z kosztami produkcji). O ile konieczne jest zapewnienie istnienia relacji między zmiennymi niezależnymi (wejściowymi) a zmienną zależną (wyjściową), o tyle zarówno charakter tej relacji, jak i współczynniki


¹⁵ Może ona przyjmować różną postać. W prognozowaniu zazwyczaj wykorzystywane są funkcje ciągłe, szczególnie logistyczna oraz tangensa hiperbolicznego.

¹⁶ Akson – jest to struktura neuronu, której zadaniem jest wyprowadzenie sygnału z wnętrza komórki.

¹⁷ Synapsa jest to miejsce, w którym zachodzi komunikacja między aksonem jednej komórki a dendrytem innej.

zależności nie są informacjami koniecznymi w prognozowaniu. Podczas nauki ANN¹⁸ same poszukują wspomnianych powiązań (rysunek 6). Poprzez modyfikację opisanych wcześniej wag (w_x) zmienia się charakter zależności między zmiennymi niezależnymi (wejściami) a zależnymi (wyjściami) modelu. Z twierdzenia Kołmogorowa (Pissarenko, 2002) wynika, że ANN o dwóch warstwach ukrytych mają potencjalną zdolność do przybliżania dowolnych funkcji ciągłych. Potencjalne możliwości ANN wykraczają zatem poza większość znanych obecnie modeli prognozowania kosztów.

Rysunek 6. Schemat nadzorowanego uczenia sieci



Źródło: Świąć, Bilski (2000, s. 78).

¹⁸ Odpowiedni algorytm, zwany uczącym, bazując na tzw. danych uczących, dla których znana jest rzeczywista wartość zmiennej zależnej przy danych wartościach zmiennych niezależnych, sprawdza wielkość błędu popełnionego przez ANN. Następnie dokonuje modyfikacji wag w neuronach, tak by kolejna odpowiedź ANN obciążona była niższą wartością błędu. Proces ten trwa aż do momentu, gdy dalsza nauka grozi tzw. przeuczeniem ANN, tj. sytuacją, w której traci ona zdolność do uogólniania przyswojonej w ten sposób wiedzy.

Należy dość ostrożnie podchodzić do wyboru zmiennych niezależnych ($X_1 \dots X_n$). Teoretycznie przyjąć można, że nie istnieje nawet konieczność doboru takich danych wejściowych, które w istotny sposób wpływają na modelowaną zmienną wyjściową. W ujęciu teoretycznym udział danych nieistotnych, z punktu widzenia zmiennej zależnej, zostanie w procesie nauki ANN zminimalizowany, a tym samym taka informacja będzie niemal pominięta w procesie analizy. W praktyce używane obecnie algorytmy uczące nie cechuje aż tak wysoki stopień zdolności do odrzucania zmiennych nieistotnych¹⁹. Na planie kosztów spoczywa obowiązek wstępnej selekcji zmiennych niezależnych, tak by wybrać te, które w możliwie wysokim stopniu powiązane są z prognozowanymi kosztami. Obala to często powtarzany mit, że ANN są metodą bliską „wróżeniu”. Jest to metoda matematyczna oparta o dane powiązane z analizowanym zjawiskiem, która *de facto* nie jest nawet tzw. metodą „czarnej skrzynki”, ponieważ wagi neuronów, połączenia wewnątrz sieci, a także użyte algorytmy mogą zostać poddane analizie realizowanej przez planistę kosztów.

W każdym modelu matematycznym, także i w tym modelu, dobór zmiennych niezależnych stanowi kluczowy element tworzenia poprawnie funkcjonującego systemu. W literaturze przedmiotu istnieje pewna luka, polegająca na pomijaniu przy konstrukcji modeli ANN z obszaru zarządzania kosztami, transformacji danych wejściowych. Ich przekształcenie polecane jest szczególnie w przypadku użycia zmiennych niezależnych i zależnych będących szeregami czasowymi. Zastosowanie narzędzi z obszaru analizy technicznej umożliwia w tym przypadku „odfiltrowanie” zaszumionych danych i wydobycie z nich tendencji o charakterze trendu²⁰.

4. Budowa modelu prognozowania kosztów produkcji z wykorzystaniem sztucznych sieci neuronowych²¹

Perceptron wielowarstwowy wymaga określenia pewnych charakterystycznych cech modelu. Należą do nich: ilość zmiennych wyjściowych, ilość zmiennych wejściowych, liczba warstw ukrytych, ilość neuronów w poszczególnych warstwach ukrytych, stosowane


¹⁹ Każda zmienna, nawet ta której wkład w wynik końcowy jest niewielki oprócz informacji wartościowej niesie ze sobą także dane nieistotne, skutkujące błędem większym modelu. Ze względu na budowę sztucznego neuronu sygnały wejściowe (a zatem i błędy) ulegają sumowaniu w kolejnych neuronach przez które przechodzą. Skutkuje to rozprzestrzenianiem się błędów wewnątrz struktury ANN i finalnie niższą precyzją prognozy.

²⁰ Więcej na temat zastosowania analizy technicznej w przewidywaniu kosztów znajduje się w: Leszczyński, Jasiński (2015).

²¹ W prezentowanym badaniu empirycznym obiektem prognozowania są silniki indukcyjne o różnicach parametrach technologicznych (nośnikach kosztów). Problem z matematycznym opisem funkcjonalnej zależności pomiędzy zmiennymi (kosztami a ich nośnikami oraz autokorelacji zmiennych) determinuje w tym przypadku zastosowanie sieci neuronowych jako estymatora kosztów.

w sieci funkcje aktywacji²², ich parametry, rodzaj algorytmu uczącego oraz wartości takich elementów wspomnianego algorytmu, jak np. współczynnik nauki²³. Powyższe zestawienie nie zawiera konieczności ustalenia liczby neuronów na wyjściu oraz na wejściu sieci. Są one (liczba neuronów) jednoznacznie zdefiniowane przez ilość zmiennych zależnych i niezależnych. W modelu estymowana jest tylko jedna wielkość wyjściowa (Y), zatem ANN posiada pojedynczy neuron w warstwie wyjściowej (rysunek 7). Liczba komórek nerwowych na wejściu sieci odpowiada natomiast liczbie zmiennych niezależnych ($X_1 \dots X_n$) (rysunek 7). Pozostałe elementy modelu, mimo istnienia pewnych ogólnych sugestii co do ich wyboru, muszą być zazwyczaj poszukiwane w sposób eksperymentalny.

Rysunek 7. Model ANN prognozujący koszt wykonania wież chłodniczych



Źródło: opracowanie własne.

Na rysunku 7 zaprezentowano model prognozy kosztów, zbudowany na bazie danych dotyczących kosztu budowy wież chłodniczych (tabela 1). Zmienne niezależne X_1 , X_2 oraz X_3 stanowią odpowiednio: (i) zakres chłodzenia, (ii) efekt chłodzenia oraz (iii) natężenie przepływu. Zmienną zależną stanowił rzeczywisty koszt wytworzenia wieży.

Wybór zmiennych niezależnych powinien być ściśle związany z danym przedsiębiorstwem i charakterem produkcji. Jako przykład posłużyć może użycie przez Kim i in. (2014) ANN celem przewidywania kosztów w branży budowlanej. Dane wejściowe modelu stanowiły: (i) powierzchnia całkowita, (ii) liczba pięter, (iii) liczba lokali, (iv) czas budowy, (v) typ dachu, (vi) rodzaj fundamentu, (vii) sposób wykorzystania piwnicy, (viii) standard wykończenia²⁴.


²² Mogą one być różne dla każdego neuronu, niemniej jednak zazwyczaj określa się jedną funkcję dla całej sieci.

²³ Współczynnik nauki jest wartością określającą szybkość procesu uczenia. Ma ona również wpływ na jego skuteczność.

²⁴ Podobne badania przeprowadzili B.R. Setyawati i in. (2002). Zestaw danych wejściowych nieznacznie różnił się od użytych przez Kim i in. (2014).

W Departamencie Large Rotating Machinery, Toshiba Mitsubishi-Electric Industrial Systems Corporation wykorzystano cztery ANN do prognozowania kosztów produkcji udoskonalonych modeli silników indukcyjnych (Ikeda, Hiyama, 2005). Trzy sieci zostały użyte celem modelowania technologicznych parametrów produktu. Na podstawie uzyskanych wyników wykonano prognozy kosztów ich produkcji z wykorzystaniem czwartej ANN. Jej schemat został zaprezentowany na rysunku 8. Struktura sieci, w porównaniu do zaprezentowanej na rysunku 7, wzbogacona została o dwa neurony – jeden w warstwie wejściowej (zmienna X_5) oraz jednej w warstwie ukrytej. W obu przypadkach, co zostało zaznaczone na rysunku 8, do komórek wprowadzony jest tzw. „bias”, to jest sygnał o stałej wartości równej 1. Takie podejście do budowy ANN nie jest konieczne, niemniej często umożliwia ono uzyskanie lepszych wyników funkcjonowania sieci.

Rysunek 8. Model ANN prognozujący koszt wytworzenia silników indukcyjnych przy użyciu pojedynczej ANN



Źródło: opracowanie własne na podstawie Ikeda, Hiyama (2005, s. 1598).

Jako dane²⁵ uczące posłużyły wartości parametrów technologicznych (nośniki kosztów) silników wysokoobrotowych (tabela 5), silników średnioobrotowych (tabela 6) oraz koszty rzeczywiste ich wytworzenia.

Tabela 5. Dane uczące (rzeczywiste) silników wysokoobrotowych użyte w ANN

Lp.	Moc znamionowa (kW)	Liczba biegunów	Średnica obudowy	Długość rdzenia	Bias	Rzeczywiste koszty wytworzenia
1	710	2	0,450	0,500	1	0,4053
2	750	2	0,450	0,500	1	0,4053
3	800	2	0,450	0,500	1	0,4053
4	850	2	0,450	0,550	1	0,4140
5	900	2	0,450	0,600	1	0,4213
6	1000	2	0,450	0,650	1	0,4280
7	1120	2	0,450	0,700	1	0,4353
8	1250	2	0,450	0,750	1	0,4420
9	1400	2	0,500	0,600	1	0,5313
10	1800	2	0,500	0,800	1	0,5787
11	2000	2	0,500	0,850	1	0,5867
12	710	4	0,450	0,500	1	0,3740
13	750	4	0,450	0,500	1	0,3740
14	850	4	0,450	0,500	1	0,3740
15	900	4	0,450	0,600	1	0,3880
16	950	4	0,450	0,650	1	0,3940
17	1000	4	0,450	0,650	1	0,3940
18	1060	4	0,450	0,700	1	0,4007
19	1250	4	0,450	0,750	1	0,4007
20	1400	4	0,500	0,600	1	0,4613
21	1600	4	0,500	0,700	1	0,4853
22	2000	4	0,500	0,850	1	0,5100

Źródło: opracowanie na podstawie Ikeda, Hiyama (2005, s. 1599).

²⁵ Dane uczące to dane o kosztach rzeczywistych wytworzenia silników indukcyjnych pochodzące z ostatniego okresu ich produkcji (ostatnie 3 miesiące).

Tabela 6. Dane uczące (rzeczywiste) silników średnioobrotowych użyte w ANN

Lp.	Moc znamionowa (kW)	Liczba biegunów	Średnica obudowy	Długość rdzenia	Bias	Rzeczywiste koszty wytworzenia
1	710	6	0,450	0,650	1	0,3733
2	750	6	0,450	0,700	1	0,3793
3	850	6	0,450	0,800	1	0,3887
4	900	6	0,500	0,550	1	0,4167
5	950	6	0,500	0,600	1	0,4247
6	1000	6	0,500	0,650	1	0,4327
7	1060	6	0,500	0,700	1	0,4407
8	1120	6	0,500	0,700	1	0,4407
9	1400	6	0,500	0,900	1	0,4740
10	1600	6	0,500	0,750	1	0,6233
11	1800	6	0,500	0,850	1	0,6447
12	2000	6	0,500	0,900	1	0,6533
13	710	8	0,500	0,650	1	0,4513
14	750	8	0,500	0,650	1	0,4513
15	800	8	0,500	0,700	1	0,4560
16	850	8	0,500	0,700	1	0,4560
17	900	8	0,500	0,750	1	0,4627
18	950	8	0,500	0,800	1	0,4680
19	1000	8	0,500	0,850	1	0,4733
20	1060	8	0,500	0,850	1	0,4733
21	1120	8	0,500	0,900	1	0,4780
22	1250	8	0,560	0,750	1	0,6193
23	1600	8	0,560	0,900	1	0,6533
24	1800	8	0,630	0,800	1	0,7700
25	2000	8	0,630	0,900	1	0,7960
26	800	6	0,450	0,750	1	0,3840

Źródło: opracowanie na podstawie Ikeda, Hiyama (2005, s. 1599).

ANN stworzone na bazie danych zawartych w tabelach 5 i 6 wykorzystano do prognozowania kosztów wytworzenia silników (tabela 7).

Tabela 7. Parametry technologiczne silnika (nośnik kosztów)
i prognozowane koszty wytworzenia silnika z wykorzystaniem ANN

Lp.	Moc znamionowa (kW)	Liczba biegunów	Średnica obudowy	Długość rdzenia	Bias	Prognozowany koszt wytworzenia
silniki wysokoobrotowe						
23	950	4	0,450	0,650	1	0,4280
24	1600	4	0,500	0,700	1	0,5620
25	800	4	0,450	0,500	1	0,3740
26	1120	4	0,450	0,750	1	0,4067
27	1800	4	0,500	0,800	1	0,5020
silniki średnioobrotowe						
27	1250	6	0,500	0,800	1	0,4580
28	1400	8	0,560	0,850	1	0,6360
29	710	6	0,450	0,650	1	0,3733

Źródło: opracowanie na podstawie Ikeda, Hiyama (2005, s. 1602).


Przy budowie modeli prognozowania kosztów produkcji z wykorzystaniem ANN mogą występować dwa podejścia. Pierwszym z nich jest budowa syntetycznego modelu prognostycznego, w którym prognozowanie kosztów dokonywana jest w oparciu o wszystkie (lub większość) zmiennych objaśniających, także tych które służą predykcji nieznanego nośnika kosztów (rysunek 8).

Drugim sposobem budowy poprawnie funkcjonującego modelu prognozowania kosztów jest jego podział na *de facto* dwa osobne modele. Jeden – zapowiadający nieznaną wartość rozważanego nośnika kosztów (X_3) oraz drugi – według tej prognozy, przewiduje koszty (Y). Schemat takiego połączenia dwóch różnych ANN został zaprezentowany na rysunku 9. Należy zauważyć, że model ten może być rozbudowany o kolejne ANN służące ekstrapolacji innych nośników kosztów. Zaletą zaprezentowanego podejścia, w stosunku do modelu całościowego, jest możliwość optymalizacji każdej z ANN pod kątem predykcji wartości konkretnej zmiennej wyjściowej. Wspomniana optymalizacja dotyczy przede wszystkim rodzaju zmiennych objaśniających, ale powinna również obejmować właściwy wybór rodzaju, struktury oraz metod nauki ANN.

W przedsiębiorstwach o zaawansowanej technologii produkcji, złożonych technologicznie produktach, różnorodnych parametrach technologicznych (nośnikach kosztów) budowa modelu prognozowania parametrycznego jest skomplikowana, ponieważ rośnie liczba zmiennych niezależnych (nośniki kosztów). Zależności między zmiennymi (nośnikami kosztów a kosztami) stają bardzo złożone i trudne do opisania matematycznie. Planiści kosztów nie są w stanie zidentyfikować zależności między zmienną zależną – kosztami produkcji – a zmiennymi niezależnymi – parametrami technologicznymi

(nośnikami kosztów). Budowanie wielowymiarowej funkcji kosztów jest niezwykle pracochłonne, a czasami wręcz niemożliwe. Zbiory danych koniecznych do budowy tak złożonych funkcji kosztów (wielość zmiennych niezależnych, zależności nieliniowe, brak autokorelacji zmiennych) są w wielu przypadkach nieadekwatne dla zastosowania analizy regresji. Zaletą prognozowania parametrycznego kosztów produkcji jest możliwość stosowania wiarygodnego audytu szczegółowych procedur, metod pracy, równań matematycznych (CER) oraz harmonogramów. W przypadku modelu prognozowania parametrycznego planisci kosztów budują równania matematyczne (CER), których prawidłowość może być sprawdzana nie tylko audytem formalnym, ale również logiką ich rozumowania. Komputerowe wspomaganie analizy regresji jest raczej proste i nie wiąże się z dużym nakładem pracy.

Rysunek 9. Model prognozujący koszt produkcji silników indukcyjnych przy użyciu dwóch ANN



Źródło: opracowanie własne na podstawie Ikeda, Hiyama (2005, s. 1597–1598).

Wnioski

Sieci neuronowe nie eliminują wszystkich trudności związanych ze stosowaniem prognozowania parametrycznego i kosztów produkcji. Stanowią one opłacalną alternatywę dla tradycyjnej analizy regresji, szczególnie w sytuacjach słabego rozpoznania charakteru zależności technologiczno-produkcyjnych (CER) między kosztami a ich nośnikami lub w sytuacji rozpoznania nieliniowych, wielowymiarowych (kilkadziesiąt nośników kosztów) zależności między zmiennymi, co jest charakterystyczne dla produktów

o bardzo zaawansowanej technologii (zaawansowane produkty elektroniczne, komponenty samolotów). Ta ważna zaleta sieci neuronowych redukuje konieczność wykonania analiz technologiczno-produkcyjnych oraz posiadania głębokiej wiedzy technologicznej u planistów kosztów produkcji. Z praktycznego punktu widzenia ANN są zdolne do analizy dużo większej liczby potencjalnych nośników kosztowych (nawet kilkudziesięciu) niż analiza regresji. Komputerowe wspomaganie ANN w przeciwieństwie do analizy regresji nie jest proste i wymaga określonej wiedzy informatycznej. Wadą ANN jest znaczące ryzyko w procesie budowy modelu neuronowego przy małej liczebności zbiorów danych. Jak wskazują zarówno wyniki badań literaturowych (Bode, 2000), jak i empirycznych przeprowadzonych przez autorów artykułu, liczba próbek danych stanowi jeden z podstawowych elementów wpływających na jakość prognozy²⁶.

Oba modele prognozowania kosztów produkcji w zastosowaniu praktycznym mogą być tak samo dokładne i wiarygodne, ale ze względów technologicznych i konstrukcyjnych obiektu kosztów można zastosować w danym środowisku przemysłowym zazwyczaj tylko jeden z nich²⁷. Poprawny dobór modeli prognozowania kosztów, a w konsekwencji wiarygodność i dokładność prognoz kosztowych, jest kluczowy dla fazy projektowania produktu, optymalizacji jego kosztów wytworzenia oraz analizy „zachowania” kosztów (sterowanie wyprzedzające – *feed forward*) w procesie decyzyjnym. Budowa modeli prognozowania kosztów produkcji, proces prognozowania oraz ich dobór dla określonego środowiska przemysłowego jest rozwinięciem przedmiotu rachunkowości zarządczej w odniesieniu do przedsiębiorstw o zaawansowanej technologii i cyfryzacji produkcji (Ruiza i in., 2011, s. 1469–1482). Poszerzenie przedmiotu rachunkowości zarządczej o problem zarządzania kosztami w warunkach zaawansowanych technologii i mechatroniki można zdefiniować jako „rachunkowość zarządcza w warunkach cyfryzacji produktu i produkcji” (*management accounting and digitization*) (Bhimani, 2006, s. 69–92). Przedstawiona w artykule analiza użyteczności dwóch modeli prognozowania kosztów produkcji stanowi punkt odniesienia do prowadzenia dalszych badań teoretycznych i praktycznych w tej dziedzinie.

²⁶ Już dwadzieścia lat temu, w pracy Lawrence i in. (1996), badając między innymi zależność między liczebnością zbiorów a jakością działania ANN wykazali konieczność użycia odpowiedniej ilości danych do uczenia sieci. Ich liczba jest ściśle powiązana ze stopniem złożoności ANN, a także z charakterem rozwiązywanego problemu. W literaturze przedmiotu odnaleźć można przykłady badań wskazujących na istnienie możliwości użycia ANN nawet w przypadku objętościowo ograniczonych zbiorów danych (Weckman i in., 2010, s. 257–274), jednakże takie podejście musi być powiązane ze sztucznym tworzeniem dodatkowych danych na podstawie już istniejących. Wydaje się, że podejście to powinno być stosowane tylko w wyjątkowych przypadkach oraz winno być połączone z wnikliwą analizą otrzymanych wyników. W przypadku prognozowania kosztów produkcji właściwa ilość danych uczących powinna zazwyczaj wahać się w przedziale od kilkuset do nawet kilku tysięcy.

²⁷ W określonych sytuacjach mogą być oba modele komplementarne. Np. w jednym przedsiębiorstwie prognozowanie kosztu produktu zaawansowanego technologicznie można realizować z wykorzystaniem sieci neuronowych, natomiast prognozowanie kosztów linii technologicznych (centrów kosztów) z wykorzystaniem funkcji matematycznych (CER).

Literatura

- Anderson D.M. (2014), *Design for Manufacturability*, CRC Press Taylor & Francis Group, New York.
- Babaj A., Douglas D. Gransberg D., Mark D., Grenz M. (2002), *Parametric Estimating for Design Costs*. Association for the Advancement of Cost Engineering International Transactions of the Annual Meeting, s. 1–6.
- Brinke E (2004), *Cost estimation architecture for integrated cost control based on information management*, „Computer Integrated Manufacturing”, 17 (6), s. 534–545.
- Bhimani A. (2006), *Contemporary Issues in Management Accounting*, Oxford University Press, London.
- Bode J. (2000), *Neural networks for cost estimation: simulations and pilot application*, „International Journal of Production Research”, 38 (6), s. 1231–1254.
- Clark F.D., Lorenzoni A.B. (1997), *Applied Cost Engineering*, CRC Press Taylor & Francis Group, New York.
- Dysert L.R. (2008), *An Introduction to Parametric Estimating*, Association for the Advancement of Cost Engineering International Transactions of the Annual Meeting, s. 1–7.
- Dysert L.R. (1999), *Developing a Parametric Model for Estimating Process Control Costs*, Association for the Advancement of Cost Engineering Transactions of the Annual Meeting, s. 11–14.
- Geman S., Bienenstock E., Doursai R. (1997), *Neural networks a/did the bias/variance dilemma*, „Neural Computation”, 4, s. 1–58.
- Heping L. (2010), *Cost Estimation and Sensitivity Analysis on Cost Factors: A Case Study on Taylor Kriging, Regression and Artificial Neural Networks*, 55 (3), s. 201–224.
- Horngren T.C., Datar M., Rajan M.V. (2012), *Cost Accounting. A managerial Emphasis*, Pearson Prentice Hall, Upper Saddle River, NJ.
- Huanga X., Newnesa L., Parryb G. (2012), *The adaptation of product cost estimation techniques to estimate the cost of service*, „International Journal of Computer Integrated Manufacturing”, 25, s. 417–431.
- Ikeda M., Hiyama T. (2005), *ANN based designing and cost determination system for induction motor*, „IEE Proceedings – Electric Power Applications”, 152 (6), s. 1595–1602.
- Kim G.-H., An S.-H., Kang K.-I. (2004), *Comparison of construction cost estimating models based on regression analysis, neural networks, and case-based reasoning*, „Building and Environment”, 39, s. 1235–1242.
- Lawrence S., Giles C.L., Tsoi A.C. (1996), *What Size Neural Network Gives Optimal Generalization? Convergence Properties of Backpropagation*, Technical Report UMIACS-TR-96-22 and CS-TR-3617 Institute for Advanced Computer Studies, University of Maryland.
- Leszczyński Z., Jasiński T. (2015), *Inżynieria kosztów*, ODDK, Gdańsk
- Marquez L., Hill T., Worthley R., Remus W. (1998), *Neural network models as an alternative to regression*, „Proceedings of the 24th Hawaii International Conference on System Sciences”, s. 129–135.
- Mcculloch W.S., Pitts W. (1943), *Logical Calculus of the Ideas Immanent in Nervous Activity*, „Bulletin of Mathematical Biophysics”, 5, s. 115–133.
- Mason K., Gunadharkma A., Lowe D. (1997), *Results of regression analysis survey*, Newsletter of the Society of Cost and Estimating Analysts, Alexandria, VA.
- Mauchand M., Siadat A., Bernard A., Perry N. (2008), *Proposal for tool-based method of product cost estimation during conceptual design*, „Journal of Engineering Design”, 19 (2), s. 159–172.
- Nishimura A. (2003), *Management Accounting. Feed Forward and Asian Perspectives*, Anthony Rowe Ltd., Chippenham and Eastburne, s. 139–146.
- NASA (2015), *NASA Cost Estimating Handbook*, https://www.nasa.gov/pdf/263676main_2008-NASA-Cost-Handbook-FINAL_v6.pdf (dostęp 01.03.2016).
- Nicholas J., Steyn H. (2012), *Zarządzanie Projektami- zastosowania w biznesie, inżynierii i nowoczesnych technologiach*, Oficyna a Wolters Kluwer Business, Warszawa.
- Pissarenko D. (2002), *Neural Networks for Financial Time Series Prediction: Overview Over Recent Research*, mnemopol.net, Universität Wien.

- Rajkumar R. (2003), *Cost Engineering: why, what and how?* Decision Engineering Report Series, (DEG) Cranfield University, UK, s. 1–30, <https://dspace.lib.cranfield.ac.uk/handle/1826/64> (dostęp 01.03.2016).
- Rajkumar R., Kelvesjo S., Forsberg S., Rush Ch. (2001), *Quantitative and qualitative cost estimating for engineering design*, „Journal Engineering Design”, 12 (2), s. 147–162.
- Rush C., Roy R. (2001), *Expert judgement in cost estimating: Modelling the reasoning process*, „Concurrent Engineering: Research and Applications Journal (CERA)”, 9 (4).
- Ruiza N., Gireta A., Bottia V., Feriab V. (2011), *Agent-supported simulation environment for intelligent manufacturing and warehouse management systems*, „International Journal of Production Research”, 49 (5).
- Sae-Hyun J., Moonseo P., Hyun-Soo L. (2010), *Data Preprocessing – Based Parametric Cost Model for Building Projects: Case Studies of Korean Construction Projects*, „Journal of Construction Engineering and Management”, August, s. 844–852.
- Sonmez R. (2008), *Parametric Range Estimating of Building Costs Using Regression Models and Bootstrap*, „Journal of Construction Engineering and Management”, December, s. 1011–1006.
- Setyawati B.R., Sahirman S., Creese R.C. (2002), *Neural Networks for Cost Estimation*, Association for the Advancement of Cost Engineering International. Transactions of the Annual Meeting, s. 13.1–13.8
- Świąć A., Bilski J. (2000), *Metoda wstecznej propagacji błędów i jej modyfikacje*, [w:] M. Nałęcz (red.), *Biocybernetyka i inżynieria biomedyczna 2000*, t. 6, Sieci neuronowe, Akademicka Oficyna Wydawnicza EXIT, Warszawa, s. 73–110.
- Taylor M., (1997) *Cost engineering – A feature based approach*, 85th Meeting of the AGARD Structures and Material Panel, Aalborg, Denmark, October 13–14.
- Wang Q., Stockton D.J., Baguley P. (2000), *Process cost modelling using neural networks*, „International Journal of Production Research”, 38 (16), s. 3811–3821.
- Weckman G.R., Paschold H.W., Dowler J.D., Whiting H.S., Young W.A. (2010), *Using Neural Networks with Limited Data to Estimate Manufacturing Cost*, „Journal of Industrial and Systems Engineering”, 3 (4), s. 257–274.
- Westney R.E. (1997), *Engineer's Cost Handbook: Tools for Managing Project Costs*, CRC Press Taylor & Francis Group, New York.