

# OCENA STANU ZUŻYCIA NOŻA TOKARSKIEGO Z ZASTOSOWANIEM SZTUCZNEJ SIECI NEURONOWEJ

Grzegorz KŁOSOWSKI, Tomasz RYMARCZYK

**Streszczenie:** W artykule zaprezentowano koncepcję podniesienia poziomu niezawodności systemu produkcyjnego poprzez efektywne monitorowanie stanu zużycia narzędzia. W szczególności, opisywana metoda dotyczy noży tokarskich do obrabiarek numerycznych. Przedstawiono model oceny stanu noża tokarskiego poprzez jego czterostanową klasyfikację. Model oceny stopnia zużycia wykorzystuje sztuczną sieć neuronową, której wejściem jest maksymalna sumaryczna siła posuwowa, a wyjściem wartość zużycia ostrza noża tokarskiego.

**Słowa kluczowe:** niezawodność, modelowanie, predykcja, sztuczne sieci neuronowe

## 1. Wprowadzenie

Postęp techniczny ułatwia dostęp do rozwiązań, które z uwagi na wysokie koszty implementacji nie były wcześniej rozważane pod względem ich praktycznych zastosowań. Szczególnym obszarem zainteresowań w aspekcie wdrożeń nowych metod automatyzacji procesów są złożone systemy produkcyjne.

W niniejszym artykule poruszono zagadnienie dotyczące eksploatacji i niezawodności systemów produkcyjnych, a w szczególności bardzo powszechny problem zużycia narzędzi w obrabiarkach skrawających. Niezawodność definiowana jest jako zdolność obiektu do spełnienia stawianych mu wymagań. W sensie probabilistycznym, niezawodność obiektu  $R(t)$  w danej chwili  $t$  jest prawdopodobieństwem  $P(T \geq t)$ , że jego trwałość  $T$  jest większa od  $t$ , tj.  $R(t) = P(T \geq t)$  [1].

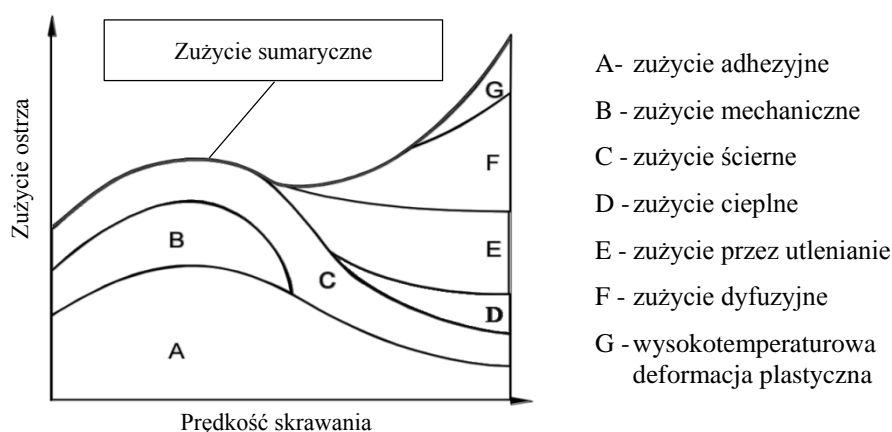
Zużyciem ostrza narzędzia nazywa się postępującą w czasie utratę właściwości skrawnych [2]. Na rys. 1 przedstawiono czynniki mające wpływ na zużycie ostrza. Jak widać czynników tych jest wiele, a ich wpływ na proces zużycia różni się w zależności od prędkości skrawania. Nie ulega wątpliwości, że podstawowym powodem obsługi obrabiarek skrawających jest stosunkowo częsta konieczność wymiany narzędzi powodowana naturalnym stępieniem ich ostrzy. Jednocześnie, predykcja zużycia ostrza, w szczególności pracującego z przemiennie zmiennymi parametrami skrawania, jest zagadnieniem trudnym [3].

Przy produkcji zautomatyzowanej, realizowanej przy pomocy wysokowydajnych obrabiarek numerycznych, ważna jest umiejętność prawidłowej oceny bieżącego stanu zużycia narzędzia. Celem jest identyfikacja optymalnego terminu wymiany, w taki sposób, by wycofać narzędzie przed jego nadmiernym zużyciem (stępieniem). Stępienie może doprowadzić do poważnego uszkodzenia zarówno narzędzia (np. noża tokarskiego) jak również innego podzespołu obrabiarki lub obrabianej części (np. poprzez przekroczenie dopuszczalnej tolerancji wymiarów i/lub chropowatości powierzchni). Jednocześnie, zbyt wczesna, nieuzasadniona wymiana noża jest działaniem nieekonomicznym.

Celem badań było opracowanie efektywnej i ekonomicznej metody bieżącej identyfikacji stanu narzędzia obrabiarki. Celem użytecznym było umożliwienie wycofania

lub naprawy zużytego narzędzia zanim jego niesprawność zacznie powodować straty i dodatkowe koszty wynikające z obniżenia jakości obrabianych elementów.

Można wyróżnić określone rodzaje innowacji prowadzące do podniesienia poziomu automatyzacji i niezawodności systemów produkcyjnych, jak choćby nowa myśl techniczna (innowacje konstrukcyjne i organizacyjne) oraz innowacyjne procesy. Wyżej wymienione obszary innowacji są bardzo obszerne jeśli chodzi o ilość potencjalnych sposobów kreacji. Z uwagi na dynamiczny rozwój technik informacyjnych i komunikacyjnych, a zwłaszcza informatyki, w praktyce przemysłowej znajduje zastosowanie wiele rozwiązań opartych na metodach komputerowych.



Rys. 1. Czynniki wpływające na zużycie ostrza narzędzia

Źródło: opracowanie własne na podstawie [4]

Znane metody monitorowania stanu ostrza narzędzia skrawającego można podzielić na dwie grupy: metody bezpośrednie i metody pośrednie. W warunkach laboratoryjnych (gdy narzędzie nie pracuje), bardziej szczegółowych i wiarygodnych danych dostarczają metody bezpośrednie, jednak z uwagi na trudność z dostępem do obszaru skrawania (zwłaszcza w trakcie obróbki) nie mają one zastosowania w praktyce. Do tego rodzaju metod zalicza się np. techniki indukcyjne, optyczne, elektrooporowe, pneumatyczne, radiometryczne.

Drugą grupę stanowią metody pośrednie. Metody te bazują na pomiarach wielu różnorodnych wielkości fizycznych (np. hałas, siły skrawania, moment obrotowy, moc, drgania, temperatura) [5]. Dzięki komputerowej analizie sygnałów wartości wejściowych prognozuje się wartość zużycia narzędzia. Metoda będąca przedmiotem niniejszego opracowania zalicza się do metod pośrednich.

### 3. Proces identyfikacji stanu narzędzia

Koncepcja sterownika do oceny stanu zużycia noża tokarskiego z zastosowaniem sztucznej sieci neuronowej oparta jest na założeniu, że zużycie  $VB$  konkretnego rodzaju noża tokarskiego jest mocno powiązane z siłą posuwową  $F_f$ , która oddziałuje na ostrza noża tokarskiego w trakcie procesu. Filozofia tego podejścia jest analogiczna do określania poziomu zużycia samochodu jego przebiegiem.

Aby określić „przebieg” ostrza noża tokarskiego wykorzystując jako miarę tego przebiegu siłę posuwową  $F_f$ , założono, że podczas każdej sekundy pracy narzędzia z

posuwem rejestrowana będzie maksymalna wartość  $F_f$ . W ten sposób, każdemu nożowi tokarskiemu może być przypisana aktualna, sumaryczna siła  $S_F$ . Sposób wyliczania  $S_F$  przedstawia zależność (1).

$$S_F = \sum_{i=1}^N F_{f_i}^{max} \quad (1)$$

gdzie:

$N$  – sumaryczny czas pracy (w sekundach) noża tokarskiego od chwili ostatniego naostrzenia

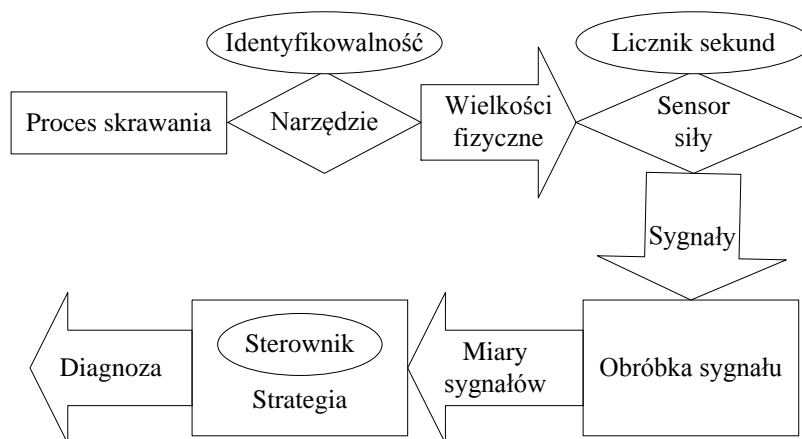
$i$  – sekundowy licznik czasu

$F_{f_i}^{max}$  – maksymalna siła posuwowa w trakcie  $i$ -tej sekundy pracy z posuwem noża tokarskiego

Sumowanie siły posuwowej rozpoczyna się od wartości zerowej, po każdorazowym naostrzeniu noża tokarskiego lub wymianie narzędzia na nowe. Trzeba zauważyć, że krzywa zależności między siłą posuwową a zużyciem będzie inna dla różnych rodzajów noży. Z tego powodu, każdy rodzaj noża tokarskiego powinien być uprzednio poddany wzorcowaniu. W tym celu należy wykonać szereg pomiarów zużycia noża tokarskiego w zależności od sumarycznej maksymalnej siły posuwowej  $S_F$ .

Aby móc określać i rejestrować wielkość  $S_F$  należy dysponować obrabiarką wyposażoną w odpowiedni czujnik umożliwiający pomiar siły posuwowej [6]. Czujnik siły i licznik czasu (zegar) powinny być zamontowane w obrabiarce, natomiast sterownik może być osobnym układem wyposażonym w odrębny system operacyjny, procesor i pamięć. Biorąc pod uwagę obecny poziom rozwoju technik informatycznych, jest prawdopodobne, by rozwiązanie ze sterownikiem umieszczonym w chmurze obliczeniowej (ang. cloud computing) było opcją najbardziej ekonomiczną.

Kolejnym elementem o kluczowym znaczeniu dla skuteczności omawianej koncepcji oceny stanu ostrza noża tokarskiego, jest identyfikowalność narzędzia. Każdy nóż powinien być oznaczony w sposób umożliwiający łatwe przypisanie do niego właściwego wzorca i zarejestrowanych wcześniej danych historycznych ( $S_F$  i  $N$ ). Rys 2 przedstawia przebieg i elementy składowe procesu diagnostyki stanu narzędzia.



Rys. 2. Struktura układu diagnostyki (stanu) narzędzia i procesu skrawania  
Źródło: opracowanie własne na podstawie [7]

Przed zamocowaniem noża tokarskiego w konkretnej obrabiarce należy najpierw odczytać jego identyfikator. Dzięki temu, system informatyczny przypisze do noża jego aktualne parametry (a tym samym, pośrednio, zaklasyfikuje go do konkretnego stanu). W szczególności, parametry zgromadzone w bazie danych dotyczące użytego narzędzia to: siła posuwowa zarejestrowana w poszczególnych sekundach, ilość sekund pracy z posuwem noża od ostatniego ostrzenia. W celu dokładniejszego prognozowania przydatne może być także dane o głębokości skrawania w sekundowej funkcji czasu.


Powyższe dane są następnie przetwarzane na sygnały mogące stanowić wejścia do sterownika neuronowego (obróbka sygnału). W szczególności informacje o sile posuwowej w funkcji czasu są zamieniane na wskaźnik maksymalnej sumarycznej siły posuwowej  $S_F$  lub iloczyn  $S_f \cdot a_p$ . W ostatniej fazie sterownik prognozuje stan ostrza narzędzia określając przewidywaną wartość zużycia  $VB$  a następnie klasyfikuje tę wartość do jednego z trzech stanów.

## 2. Identyfikowalność narzędzi

Jak wcześniej wspomniano, ważnym elementem mającym wpływ na skuteczność zaproponowanej metody oceny stanu narzędzia ma identyfikowalność. Istnieje wiele możliwych metod identyfikacji części, jednak należy wziąć pod uwagę specyfikę elementów jakimi są noże tokarskie. Warunki procesu skrawania sprawiają, że przytwierdzenie do noża tokarskiego obcych elementów jakim są np. tagi RFID jest kłopotliwe. W tej sytuacji najlepszą metodą wydaje się być laserowe znakowanie narzędzi. Ma ono następujące zalety:

- Dzięki wiązce lasera można bardzo szybko nanosić kody 2D o wysokiej jakości.
- Dzięki wysokiej rozdzielczości można znakować bardzo małe kody.
- Duży kontrast otrzymywany na tworzywach sztucznych i metalach gwarantuje łatwy odczyt.
- Technologia laserowa zapewnia dużą wszechstronność. Jest bezkontaktowa, nie ogranicza odległości między oznaczoną częścią a urządzeniem, regulowane parametry względem powierzchni, wysoki stopień automatyzacji.
- Niskie koszty obsługi wynikające z powodu braku materiałów eksploatacyjnych.
- Mniejsza konieczność konserwacji w porównaniu z innymi technologiami kodowania takimi jak drukowanie lub znakowanie elektrochemiczne [8].

Na rys. 3 zaprezentowano przykłady znakowania laserowego narzędzi do obróbki skrawaniem.



Rys. 3. Przykład identyfikacji narzędzi metodą znakowania laserowego

Źródło: <http://www.lasery.pl/znakowanie-narzedzi.html> - dostęp 6.01.2017

### 3. Inteligentny sterownik

Z zależności (2) wynika, że siła posuwowa  $F_f$  jest prawie niezależna od posuwu, będąc funkcją jedynie głębokości skrawania i zużycia ostrza [7]:

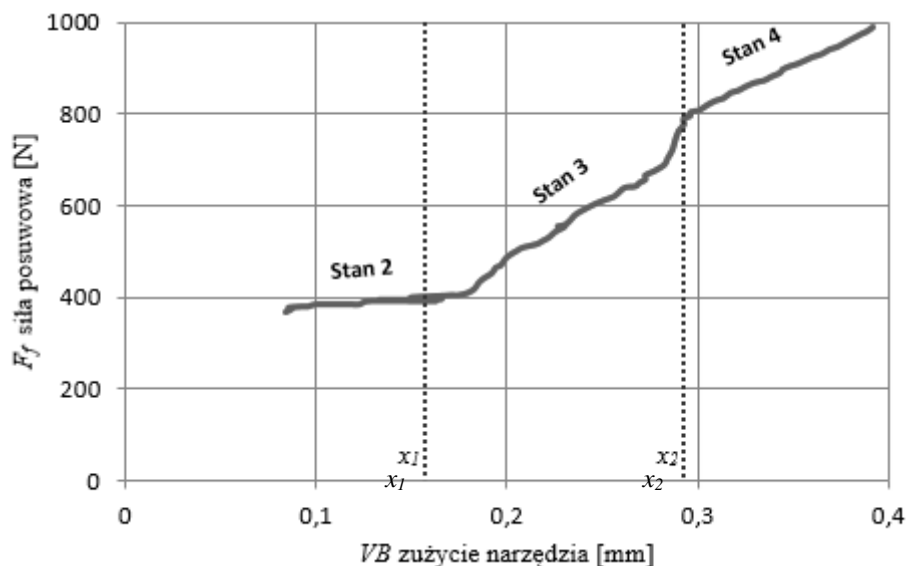
$$F_f = F_f(a_p, VB) \quad (2)$$

gdzie:

$a_p$  – głębokość skrawania

$VB$  – zużycie narzędzia

Zużycie narzędzia jest więc ściśle uzależnione od zmian siły posuwowej  $F_f$ , tym bardziej, że głębokość skrawania jest stała w trakcie jednego przejścia. Na rys. 4 zaprezentowano wykres zależności pomiędzy siłą posuwową a zużyciem ostrza noża tokarskiego. Wykres dotyczy jednego zabiegu, w którym czas skrawania wynosił pół minuty a głębokość skrawania  $a_p$  wynosiła 3mm.



Rys. 4. Krzywa zależności zużycia narzędzia od siły posuwowej

Źródło: opracowanie własne na podstawie [7]

Rozważany model sterownika do oceny stopnia zużycia narzędzia przewiduje następujący system klasyfikacji [9]:

- Stan 0 - Rozważane narzędzie jest w trakcie wymiany, ponieważ jest całkowicie zepsute i nie działa.
- Stan 1 - Narzędzie jest w trakcie naprawy, ponieważ uległo chwilowemu uszkodzeniu (np. stępieniu) i nie może być wykorzystywane.
- Stan 2 - Narzędzie działa i jest w stanie *burn-in phase*, gdy pewne początkowe uszkodzenia są możliwe wkrótce po zainstalowaniu tego elementu (jako całkowicie nowego).

- Stan 3 - Narzędzie działa i jest w stanie *normal operations state* (stan standardowy), gdyż okres początkowych uszkodzeń się już skończył.
- Stan 4 - Narzędzie działa, ale osiągnęło stan *wear-out period* (stan post-standardowy), co oznacza, że uszkodzenia są możliwe z większym prawdopodobieństwem w wyniku postępującej degradacji elementu.

Ponieważ stany 0 i 1 odpowiadają sytuacjom, w których nóż tokarski jest niezdalny do użycia, monitorowanie w trakcie procesu obróbki skrawaniem sprowadza się do zaklasyfikowania bieżącego zużycia do jednego z trzech stanów: 2, 3 lub 4. Jeżeli narzędzie znajdzie się w stanie 4, po zakończonym zabiegu należy dokonać oceny stanu zużycia ostrza wykonując stosowne pomiary jego mikrogeometrii [10]. Dzięki temu można upewnić się czy predykcja stopnia zużycia ostrza na podstawie sumarycznej maksymalnej siły posuwowej okazała się trafna. Wyniki pomiarów powinny wejść w skład zbioru uczącego perceptronu wielowarstwowego – jednej z odmian sztucznych sieci neuronowych.

W opisywanej koncepcji każdy rodzaj narzędzia powinien mieć własny, indywidualnie nauczony wzorzec i sterownik predykcyjny. Na podstawie danych doświadczalnych wyznacza się krzywą zależności  $S_F$  i  $VB$ . Zgromadzone wyniki pomiarów mogą posłużyć jako zbiór uczący.

Wejściami do systemu predykcyjnego są:

- sumaryczna maksymalna siła posuwowa  $S_F$  wyliczona z zależności (1),
- opcjonalnie - głębokość skrawania  $a_p$ , która jest wartością stałą podczas każdego przejścia.


Wyjściem systemu predykcyjnego jest klasyfikacja do jednego z trzech rodzajów stanów: 2, 3 lub 4. W rzeczywistości, sztuczna sieć neuronowa może dokonywać precyzyjnej predykcji wartości zużycia ostrza  $VB$ , natomiast klasyfikacja może być realizowana przez instrukcje warunkowe typu:

JEŻELI  $VB < x_1$  WTEDY Stan 2

JEŻELI  $x_1 < VB < x_2$  WTEDY Stan 3

JEŻELI  $VB > x_2$  WTEDY Stan 4

Na rys. 5 przedstawiono schemat sztucznej sieci neuronowej. Jest to perceptron wielowarstwowy z dziesięcioma neuronami w warstwie ukrytej i z jednym neuronem w warstwie wyjściowej. Sieć ma jedno wejście - sumaryczną maksymalną siłę posuwową  $S_F$ . Głębokość skrawania jest tu wielkością stałą, więc nie została uwzględniona jako osobne wejście.



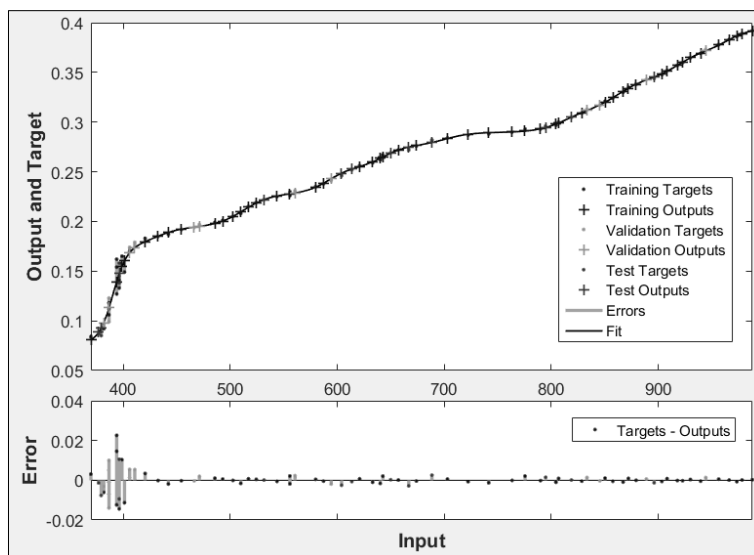
Rys. 5. Schemat sztucznej sieci neuronowej

Biorąc pod uwagę fakt, że obrabiarki numeryczne realizują instrukcje zawarte w skryptach programowych, w każdej sekundzie procesu (z posuwem) znana jest także głębokość skrawania. W tej sytuacji, można jako wejście sieci neuronowej zastosować iloczyn  $S_F \cdot a_p$ . Wtedy, po przekształceniu zależności (2) spełniony byłby postulat

uzależniający zużycie ostrza VB od siły posuwowej i głębokości skrawania. Zależność tę przedstawia równanie (3).

$$VB = VB(F_f, a_p), \text{ zatem:} \\ VB = VB(S_F, a_p) \quad (3)$$

Na rys. 6 zaprezentowano krzywą przebiegu procesu uczenia, walidacji i testowania sztucznej sieci neuronowej. Obserwując wykres można stwierdzić, że dla wszystkich trzech rodzajów zbiorów (uczącego, walidacyjnego i testowego) wartości wyjściowe były bardzo zbliżone do wartości wzorcowych. Ponadto, analizując lewą-dolną część wykresu widać, że największe błędy miały miejsce na początku procesu uczenia, a następnie dość szybko nastąpiło ustabilizowanie. Wszystkie te fakty świadczą o wysokiej jakości sieci, a także o tym, że sieć nie została przeuczona. Dzięki temu sieć powinna mieć wysoką zdolność generalizacji, czyli do prawidłowego prognozowania wartości zużycia narzędzia na podstawie sumarycznej maksymalnej wartości siły posuwowej.



Rys. 6. Wykres przebiegu procesu uczenia, walidacji i testowania

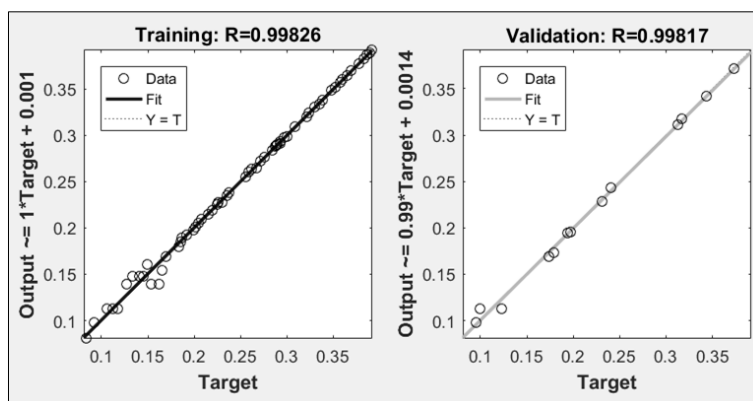
Na rys. 7. zaprezentowano wykresy regresji dla zbioru uczącego i walidacyjnego natomiast na rys. 8 przedstawiono analogiczne wykresy dla zbiorów testowego i dla całego zbioru danych.

Cały zbiór danych składa się z 86 przypadków. Został on podzielony na trzy podzbiory w następujący sposób:


- zbiór uczący - 60 przypadków,
- zbiór walidacyjny - 13 przypadków,
- zbiór testowy - 13 przypadków.

Zbiór uczący jest najbardziej liczny, ponieważ przypadki w nim zawarte są wykorzystywane do korygowania parametrów sieci (wag i momentum) w procesie uczenia. Zbiór walidacyjny jest używany do pomiaru zdolności sieci do generalizacji. Generalizacja, to właściwość sieci umożliwiająca jej prawidłowe przewidywanie przypadków, które nie

znalazły się w zbiorze uczącym. W przypadku, gdy wartości błędów dla przypadków walidacyjnych osiągną pewien ustalony wcześniej poziom, jest to sygnałem do zakończenia procesu uczenia. Warunkiem zatrzymania procesu uczenia sieci może być także maksymalny czas lub ilość epok, jednak bez kontroli jakości sieci dzięki walidacji mogłoby dojść to tak zwanego przeuczenia sieci.



Rys. 7. Wykresy regresji dla zbioru uczącego i walidacyjnego



Rys. 8. Wykresy regresji dla zbioru testowego i dla całego zbioru danych


Przeuczenie ma miejsce wtedy, gdy sieć nauczy się dokładnie przewidywać przypadki zawarte w zbiorze uczącym, jednak nie potrafi poradzić sobie z danymi spoza tego zbioru.

Zbiór testowy nie wywiera bezpośredniego wpływu na proces uczenia. Dostarcza on niezależnych informacji umożliwiających obiektywną ocenę skuteczności wytrenowanej sieci zarówno w trakcie procesu uczenia jak również po jego zakończeniu. Bliskie jedynki wartości regresji  $R$  na rys. 7 i 8 świadczą o wysokiej efektywności sieci neuronowej.


Zbiór uczący wykorzystany w niniejszym opracowaniu został utworzony w rezultacie digitalizacji wykresu zależności siły posuwowej  $F_f$  i zużycia ostrza noża tokarskiego  $VB$  (próba I9) w publikacji [7]. Oryginalnie, eksperyment był przeprowadzony przy użyciu imaka wyposażonego w czujnik przemysłowy. Ciekawym spostrzeżeniem autora jest stwierdzenie, że siła posuwowa  $F_f$  jest niemal niezależna od posuwu, będąc funkcją



jedynie głębokości skrawania i zużycia ostrza. Wyciągnięte przez autora wspomnianych badań wnioski posłużyły jako baza do rozważań nad tematyką niniejszej publikacji.



Rys. 9. Histogram błędów procesu uczenia




Rys. 10. Wykresy wartości gradientu, momentum i liczby błędnych walidacji w 14 epokach procesu trenowania sieci neuronowej

Rys. 9 przedstawia histogram błędnych odpowiedzi wygenerowanych przez trenowaną sieć w trakcie uczenia, walidacji i testowania. Obszar wykresu podzielony został na 20 przedziałów. Można zauważyć, że najczęściej przypadków charakteryzował bardzo mały błąd (zerowy błąd zajmuje okolice środka osi poziomej).

Na rys. 10 zaprezentowano wykresy wartości gradientu, momentum i błędnych przypadków walidacyjnych w trakcie procesu uczenia sieci.

Uczenie sieci było realizowane wg algorytmu Levenberga-Marquardta (LM). Jest to, iteracyjny algorytm optymalizacji nieliniowej należący do grupy metod wstecznej propagacji błędu. Algorytm LM zawiera elementy metody Gaussa-Newtona oraz metody największego spadku. Algorytm Levenberga-Marquardta jest szybki, jednak wymaga większej pamięci operacyjnej. Uczenie sieci zostaje automatycznie zatrzymane gdy generalizacja sieci przestaje rosnać. Miarą takiego stanu jest rosnący błąd średniokwadratowy próbek zgromadzonych w zbiorze walidacyjnym.

Ważną rolę w algorytmie LM odgrywa gradient funkcji błędu. Gradient jest wykorzystywany jako wskazówka do modyfikacji wartości wag. Korekty są dokonywane w kierunku największego spadku funkcji błędu. Najniższe wartości i w miarę płaski przebieg krzywej dynamiki gradientu mogą wskazywać na epokę, w której udało się najlepiej dopasować sieć.



Rys. 11. Wykresy błędów średniokwadratowych dla uczenia, testowania i walidacji z uwzględnieniem epok iteracyjnych

Momentum, to tzw. bezwładność uczenia sieci. Wielkość momentum jest regulowana automatycznie. Niskie wartości momentum wskazują na niewielkie korekty wprowadzane w odniesieniu do wag. Najniższy punkt na wykresie wskazuje miejsce najlepszego dopasowania sieci.

Wykres błędnych wyników walidacji wskazuje ilościowo przypadki fałszywych odpowiedzi sieci w poszczególnych iteracjach. W prezentowanej sieci proces uczenia został zakończony po 14 iteracjach.

Na rys. 11 zaprezentowano wykres błędu średniokwadratowego (ang. Mean Square Error) dla przypadków walidacyjnych. Najlepszy rezultat (najmniejszą wartość błędu) uzyskano w epoce ósmej. Ponadto, zgodny przebieg wszystkich trzech przebiegów krzywych błędów MSE świadczy o dobrej jakości otrzymanej sieci.

#### 4. Wnioski

W prezentowanym opracowaniu przedstawiono klasyfikacyjną koncepcję oceny stanu zużycia noża tokarskiego opartą na sterowniku neuronowym. Cechą charakterystyczną opisywanej metody jest minimalna ilość wielkości mierzonych (siła posuwowa, sekundowy czas obróbki i głębokość skrawania). Dzięki modelowi uwzględniającemu jedno wejście i jedno wyjście, udało się zaprojektować i wytrenować efektywną sieć neuronową, precyzyjnie przewidującą wartości zużycia ostrza narzędzia, a tym samym skutecznie klasyfikującą nóż tokarski do odpowiedniego stanu.

Nowością jest założenie, że zużycie narzędzia może zależeć od sumarycznej maksymalnej siły posuwowej lub od iloczynu tej siły i głębokości skrawania. W celu weryfikacji założeń prezentowanej koncepcji zaprojektowano sztuczną sieć neuronową (perceptron wielowarstwowy), pozyskano dane do zbioru uczącego i wytrenowano sieć. Walidacja i testowanie sieci dały zadowalające rezultaty. Sieć posiada dużą zdolność generalizacji.

Prostota modelu sprawia, że koszty implementacji sterownika nie powinny być wysokie, co nadaje koncepcji walor użyteczny. Jeżeli prezentowana metoda – po jej praktycznej weryfikacji – okazałaby się skuteczna, istnieje duża szansa, że w podobny sposób można oceniać nie tylko stopień zużycia noży tokarskich, lecz także innych narzędzi skrawających, jak np. frezy, wiertła, rozwiertaki, gwintowniki.

Należy zaznaczyć, że zaprezentowana w niniejszym artykule metoda nie została dotąd zweryfikowana w praktyce i stanowi jedynie głos w szerokiej dyskusji nad poszukiwaniem efektywnych sposobów podniesienia poziomu niezawodności systemów produkcyjnych.

#### Literatura

1. Macha E.: Niezawodność maszyn. Oficyna Wydawnicza PO, 2001, s. 5.
2. Wittbrodt P.: Nadzorowanie i prognozowanie stanu narzędzi skrawających w procesie skrawania. [w:] Innowacje w zarządzaniu i inżynierii produkcji, pod redakcją Ryszarda Knosali, Oficyna Wydawnicza Polskiego Towarzystwa Zarządzania Produkcją, Opole 2014.
3. Wittbrodt P.: logika rozmyta w systemie wspomagania decyzji w procesie obróbki skrawaniem, [w:] Innowacje w zarządzaniu i inżynierii produkcji, pod redakcją Ryszarda Knosali, Oficyna Wydawnicza Polskiego Towarzystwa Zarządzania Produkcją, Tom 1, Opole 2015.
4. König W.: Horizons in manufacturing technology, University of Michigan, Michigan 1967.
5. Naruszewicz W.: Pomiary momentu obrotowego <https://goo.gl/kH094q>, dostęp 6.01.2017

6. Skoczyński W. et al.: Sensory we współczesnych obrabiarkach sterowanych numerycznie, *Mechanik*, 11/2016
7. Jemielniak K.: Automatyczna diagnostyka stanu narzędzia i procesu skrawania. Oficyna Wydawnicza Politechniki Warszawskiej, 2002. s. 138
8. Jaką technologię znakowania kodów Data Matrix wybrać? <https://goo.gl/7mouc9> dostęp 6.01.2017
9. Romaniuk M.: On simulation of maintenance costs for water distribution system with fuzzy parameters, *Eksploracja i niezawodność - Maintenance and reliability*, 2016, 18.4: 514-527
10. Gilewicz A.: Zużywanie się ostrzy narzędzi skrawających na przykładzie noży strugarek z uwzględnieniem kryteriów oceny ich zużycia, <https://goo.gl/OY67TN>, dostęp 6.01.2017

Dr inż. Grzegorz KŁOSOWSKI  
Katedra Organizacji Przedsiębiorstwa  
Politechnika Lubelska  
20-618 Lublin, ul. Nadbystrzycka 38 D  
tel./fax: (0-81) 5384567  
e-mail: g.klosowski@pollub.pl

Dr inż. Tomasz RYMARCZYK  
Centrum Badawczo-Rozwojowe  
Netrix S.A.  
20-148, Lublin, Związkowa 26  
tel./fax: (0-81) 748-08-34  
e-mail: tomasz@rymarczyk.com