



Metodyka tworzenia modeli neuronowych procesu szlifowania z wykorzystaniem wiedzy analitycznej i doświadczalnej

Methodology of neural modelling of grinding process using analytical and experimental data

DARIUSZ LIPIŃSKI
 WOJCIECH KACALAK
 FILIP SZAFRANIEC
 ROBERT TOMKOWSKI*

W pracy przedstawiono metodykę tworzenia modeli neuronowych zależności charakteryzujących procesy szlifowania, z zastosowaniem procedur uczenia wykorzystujących wyniki symulacji. Parametry symulacji procesu szlifowania dobrano na podstawie wyników eksperymentu. Eksperyment obejmował analizę wpływu parametrów obróbki (dosuwu szlifowania a_e , prędkości posuwu stycznego stołu v_{ft} oraz posuwu osiowego stołu f_a) na parametr Sa chropowatości powierzchni obrabianej. Określono stopień dopasowania wyników symulacji numerycznej do wyników eksperymentu oraz dokładność dopasowania modelu neuronowego.

SŁOWA KLUCZOWE: proces szlifowania, symulacja, sieci neuronowe, chropowatość powierzchni

In the paper a methodology of neural modelling of grinding process using process simulation data was presented. Grinding process simulation parameters were chosen based on the results of the experiment. The experiment consisted of an analysis of the influence of processing parameters (allowance a_e , table feed speed v_{ft} and table axial feed f_a) on the roughness parameter Sa of the grinded surface. Accuracy of fitting the results of numerical simulation results and the accuracy of the neural network model was determined.

KEYWORDS: grinding process, simulation, neural networks, surface roughness

WPROWADZENIE

* dr inż. Dariusz Lipiński (dariusz.lipinski@tu.koszalin.pl),
 prof. dr hab. inż. Wojciech Kacalak (wojciech.kacalak@tu.koszalin.pl),
 mgr inż. Filip Szafraniec (filip.szafraniec@tu.koszalin.pl),
 dr inż. Robert Tomkowski (robert.tomkowski@tu.koszalin.pl)

Automatyzacja procesów szlifowania wymaga stosowania systemów monitorowania, optymalizacji i wspomaganie decyzji operatora. Tworzenie uniwersalnych systemów wspomagających proces automatyzacji wytwarzania wymaga opracowania metod efektywnego tworzenia modeli procesu szlifowania o szerokim zakresie stosowania.

W przypadku procesów obróbki wiedza niezbędna do określenia zależności w nim występujących może pochodzić z dwóch źródeł: wiedzy o zjawiskach zachodzących w procesie oraz z danych eksperymentalnych. W zależności od zastosowanego źródła pozyskiwania wiedzy, tworzone modele można zakwalifikować do dwóch grup: modeli analitycznych lub doświadczalnych.

Konstruowanie modelu może odbywać się na drodze modelowania matematycznego, w oparciu o prawa fizyki opisujące zjawiska zachodzące w badanym procesie. Modele tego typu, zazwyczaj obejmują wszystkie punkty pracy procesu oraz wyjaśniają fizyczną istotę procesu, lecz są stosunkowo trudne do otrzymania. Trudność w uzyskaniu tego typu modeli w przypadku opisu procesów szlifowania wynika z ich złożoności, konieczności identyfikacji wielu zjawisk zachodzących w procesie oraz mechanizmów kumulacji skutków ich oddziaływań.

Odmiernym rodzajem podejścia do tworzenia modeli, są modele tworzone z zastosowaniem wyników badań doświadczalnych. Tworzenie tego rodzaju modeli wymaga określenia postaci funkcji ujmujących wpływ zmiennych niezależnych na zmienne zależne. Poprawność tworzonego modelu zależna jest w dużej mierze od prawidłowego doboru postaci funkcji i często wymaga przeprowadzenia badań wstępnych. Po zdefiniowaniu postaci modelowanej zależności, w wyniku procedur optymalizacyjnych, określane są parametry modelu zapewniające dopasowanie jego odpo-

wiedzi do wyników testów doświadczalnych. Ograniczenia modeli eksperymentalnych wynikają z możliwości ich stosowania wyłącznie do zakresu potwierzonego eksperymentem. Ponadto liczba koniecznych testów wzrasta wykładniczo wraz ze wzrostem liczby czynników ujętych w modelu (co w praktyce ogranicza możliwość stosowania ich w praktyce przemysłowej).

Efektywnym podejściem do analizy charakteru oraz siły wzajemnych oddziaływań zjawisk następujących w wyniku oddziaływania materiału obrabianego przez ziarna ściernic jest symulacja procesu szlifowania [1-6]. Modele zawarte w procedurach symulacyjnych stanowią połączenie zarówno modeli analitycznych jak i doświadczalnych a same procedury symulacyjne umożliwiają uzyskanie informacji o wielu niemierzalnych parametrach procesu obróbki [4, 7]. Ponadto modele symulacyjne pozwalają na prowadzenie badań nad procesem szlifowania równocześnie dla szerokiego zakresu parametrów wejściowych. Mogą zatem stanowić źródło danych wykorzystywanych do tworzenia modeli zależności w procesach szlifowania stanowiących podstawę uniwersalnych procedur monitorowania, prognozowania oraz optymalizacji procesu szlifowania.

W poniższej pracy przedstawiono metodykę tworzenia modeli neuronowych z wykorzystaniem, jako źródła danych, procedur symulacji procesu szlifowania. Przedstawiono przykłady tworzenia modelu określającego wpływ parametrów obróbki (dosuwu szlifowania a_e , prędkości posuwu stycznego stołu v_f oraz posuwu osiowego stołu f_a) na parametr S_a chropowatości powierzchni obrabianej.

METODYKA TWORZENIA MODELI NEURONOWYCH Z WYKORZYSTANIEM SYMULACJI PROCESU SZLIFOWANIA

Wynik procesu obróbki jest skutkiem wzajemnych oddziaływań powierzchni przedmiotu obrabianego oraz powierzchni czynnej narzędzia ściernego (CPS). Materiał przedmiotu obrabianego jest usuwany przez ziarna ściernic charakteryzujące się różnymi wymiarami, kształtem i orientacją oraz losowym położeniem na powierzchni narzędzia ściernego. Charakter i rodzaj oddziaływań przedmiotu obrabianego oraz powierzchni czynnej narzędzia ściernego zależy jest od parametrów obróbki, parametrów stereometrycznych przedmiotu obrabianego oraz struktury i rodzaju narzędzia ściernego i może być opisany szeregiem wielkości opisujących zarówno oddziaływania lokalne (związane najczęściej z pojedynczym ziarnem ściernym) jak i globalne (związane najczęściej ze zmiennymi wyników procesu obróbki, między innymi parametrami stereometrycznymi powierzchni obrabianej).

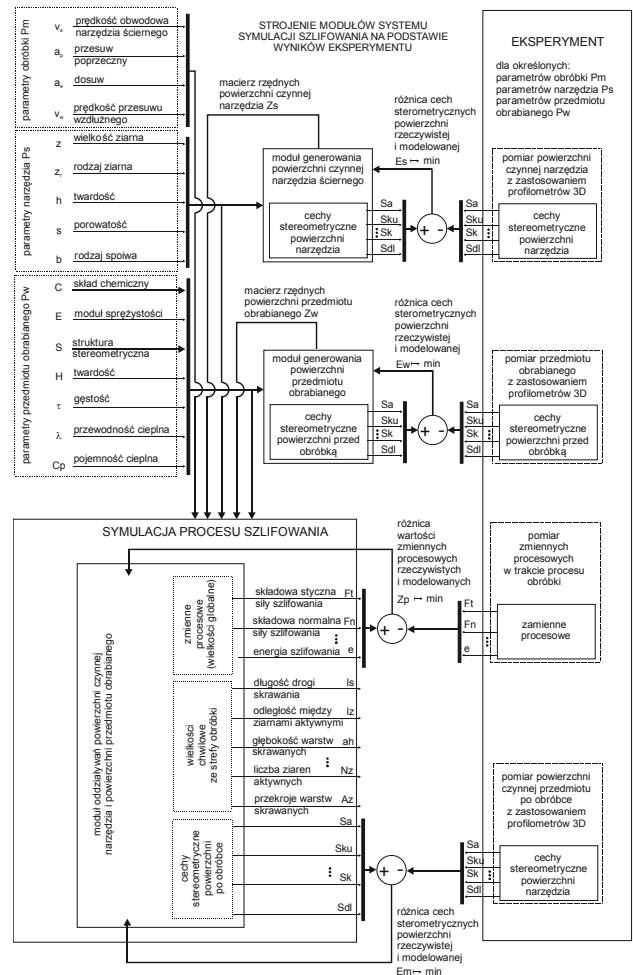
W procesie szlifowania często brak jest możliwości pomiaru wartości lokalnych (chwilowych), a istniejące wzory empiryczne odnoszą się do wartości globalnych (często przy istotnych uproszczeniach). Równocześnie w wielu ośrodkach naukowych prowadzone są badania nad opracowaniem systemów symulacji procesu szlifowania umożliwiających oceną stanu powierzchni czynnej narzędzia ściernego [7-12], analizę oddziaływań lokalnych w strefie obróbki [4, 7], jak i wielkości wyników charakteryzujących jakość procesu szlifowania [1-3, 13-15].

W Katedrze Mechaniki Precyzyjnej Wydziału Mechanicznego Politechniki Koszalińskiej opracowano kompleksowy system do modelowania i symulacji procesu szlifowania obwodem ściernicy. Wyniki symulacji procesu szlifowania z wykorzystaniem wymienionego systemu udostępniono w formie animacji w specjalnym kanale informacyjnym (Katedry Mechaniki Precyzyjnej) w systemie multimedialnym

YouTube (<http://www.youtube.com/user/PrecisionMechanics>). Udostępnione animacje przedstawiają proces tworzenia struktury stereometrycznej powierzchni w trakcie trwania symulacji procesu szlifowania.

Opracowana metodyka tworzenia modeli neuronowych procesu szlifowania z wykorzystaniem, jako źródła danych, symulacji procesu szlifowania zakłada dobór bardzo licznego zbioru parametrów modeli symulacyjnych na podstawie danych eksperymentalnych. Dane te odnoszą się do stereometrii ziaren ściernych [20], topologii ich rozmieszczenia na powierzchni czynnej, procesów tworzenia wyływek i ich zależności od warunków pracy ostrza, procesów zużywania ziaren i narzędzia, zależności sił od przekroju warstwy skrawanej określonym ostrzem oraz cech geometrycznych i fizycznych procesu (rys. 1).

Strojenie parametrów modeli symulacyjnych dokonywane jest na podstawie wyników eksperymentu dla niezmiennych parametrów i warunków obróbki. Parametry modeli symulacyjnych dobierane są tak, aby zapewnić zgodność warunków i wyników obróbki.



Rys. 1. Schemat ogólny systemu strojenia parametrów procesu szlifowania na podstawie danych eksperymentalnych

Szczegółowy opis procesu strojenia parametrów modeli symulacyjnych wykracza poza zakres niniejszej publikacji. Czytelników zainteresowanych zagadnieniem odsyłamy do publikacji zespołu autorów [4-6, 15, 16].

Po zakończeniu procesu strojenia określany jest plan eksperymentu (między innymi: liczba zmiennych niezależnych i ich poziomów oraz liczba zmiennych zależnych). Następnie dla tak przyjętego planu eksperymentu przeprowadzana jest

symulacji numeryczna procesu szlifowania. W trakcie symulacji dokonywana jest rejestracja, w bazie danych o procesie, przebiegów zmienności wielkości lokalnych (chwilowych) w strefie obróbki oraz wielkości globalnych charakteryzujących wielkości wynikowe procesu obróbki.

■ Tworzenie i weryfikacja modelu neuronowego

Do opracowania zależności w procesie szlifowania wykorzystano sieci wielowarstwowe o sigmoidalnych funkcjach aktywacji neuronów w warstwach ukrytych oraz neuronach liniowych w warstwie wyjściowej. Prace naukowe dotyczące zastosowań sieci o takiej architekturze wskazują na ich wysokie zdolności do aproksymacji modelowanych zależności [17-19].

Odpowiedź k -tego neuronu w warstwie wyjściowej sieci dwuwarstwowej o ww. strukturze, określone jest zależnością:

$$\hat{y}_k(\zeta, x) = \sum_{j=1}^M w_{k,j}^{(2)} f_j^{(1)} \left(\sum_{i=1}^N w_{j,i}^{(1)} x_i + w_{j,0}^{(1)} \right) + w_{k,0}^{(2)} \quad (1)$$

gdzie: ζ - jest wektorem, zawierającym wszystkie zmienne parametry sieci (połączenia wagowe), x - jest wektorem sygnałów wejściowych, $w_{i,j}^{(n)}$ - waga łącząca i -ty neuron n -tej warstwy z j -tym neuronem warstwy $n-1$.

Procedura uczenia sieci neuronowej prowadzona jest z użyciem zbioru uczącego U uzyskanego w wyniku symulacji procesu szlifowania. Zbiory danych wykorzystywane w procesie uczenia zawierają wartości zmiennych niezależnych oraz odpowiadające im wartości zmiennych zależnych dla poszczególnych punktów eksperymentu. Po każdym kroku uczenia wyznaczane są wartości błędów modelu, zgodnie z zależnością:

$$E = \frac{1}{L} \sum_{i=1}^L (t_i - net(x_i))^2 \quad (2)$$

gdzie: L jest liczbą przykładów w zbiorze uczącym U .

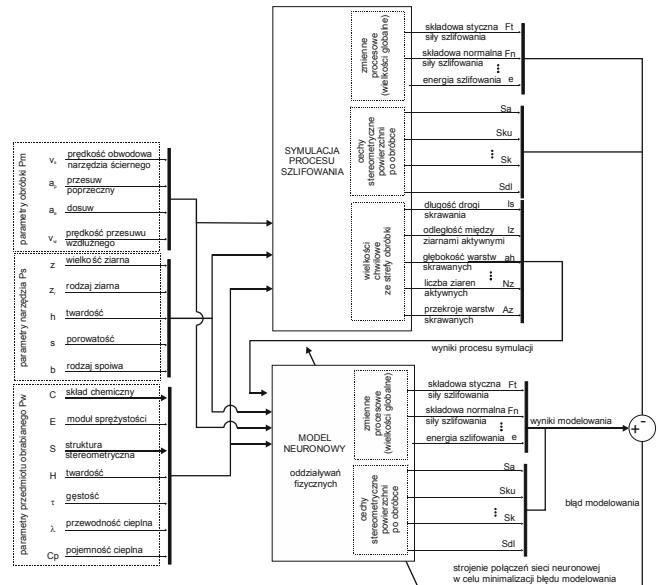
W celu zapewnienia wyższej zdolności uogólniania danych zawartych w zbiorze wyjściowym zastosowano regularyzację połączeń wagowych sieci. Funkcja celu w zadaniu optymalizacji połączeń wagowych sieci została zdefiniowana jak poniżej:

$$R = \alpha \cdot E + (1 - \alpha) \cdot msw \quad (3)$$

gdzie: $msw = \sum_{i=1}^D w_i^2 / D$, $\alpha \in (0,1)$ - parametr regularyzacji, $D = M(N + 1) + K(M + 1)$ - liczba połączeń wagowych sieci neuronowej.

Zastosowanie powyższej funkcji celu umożliwia uzyskanie mniejszych wartości połączeń wagowych sieci, co w rezultacie zapewnia mniejszą podatność sieci na nadmierne dopasowanie do zbioru danych uczących.

Schemat procesu uczenia sieci neuronowej przedstawiono na rysunku 2.



Rys. 2. Schemat ogólny procesu uczenia sieci neuronowej na podstawie wyników symulacji

Ocena poprawności modelu neuronowego dokonywana jest z zastosowaniem danych eksperymentalnych dla wybranych punktów eksperymentu numerycznego. Uzyskane dane eksperymentalne służą zarówno do testowania poprawności odpowiedzi jak i do optymalizacji struktury sieci neuronowej.

Optymalizacja struktury sieci neuronowej zakładała poszukiwanie takiej liczby neuronów w warstwie ukrytej sieci neuronowej dla której współczynnik korelacji liniowej Pearsona między odpowiedzią sieci dla danych testowych a wartością oczekiwaną będzie większy do wartości 0,95 a różnica między wartością współczynnika dla danych uczących i testowych będzie minimalna.

NEURONOWY MODEL CHROPOWATOŚCI POWIERZCHNI OBROBIONEJ – PRZYKŁAD ZASTOSOWANIA

Z zastosowaniem powyższej metodyki opracowano modele zależności opisujące wpływ dosuwu szlifowania a_e , prędkości posuwu stycznego stołu v_{tt} oraz posuwu osiowego stołu f_a na parametr Sa chropowatości powierzchni obrabianej dla przedstawionych poniżej warunków obróbki

■ Warunki i zakres eksperymentu

Badania procesu szlifowania współbieżnego obwodem ściernicy przeprowadzono na szlifierce do płaszczyzn SPG 25×60 CNC firmy FAS–Głowno. Szlifowano próbki o wymiarach 80×20×15 mm wykonane ze stopu trudnoskrzalnego INCONEL® 718. Materiał szlifowano z zastosowaniem ściernicy elektrokorundowej o oznaczeniu 99A120K7VE01 firmy Andre Abrasive Articles. Stosowano chłodzenie metodą zalewową z wykorzystaniem cieczy chłodząco-smarującej na bazie syntetycznego koncentratu emulgującego EMU-12L firmy Dik-Oil, o stężeniu ok. 3%.

Badania przeprowadzono dla stałej wartości prędkości obwodowej ściernicy $v_s = 35$ m/s. Eksperyment przeprowadzono dla zestawu parametrów obróbki, przedstawionych w tabeli 1.

Tab.1. Plan i wyniki eksperymentu

numer punktu pomiarowego	a_e [μm]	v_{ft} [m/min]	f_a [mm/skok]	Sa [μm]
1	5	2	4	0,159
2	5	3	2,7	0,151
3	5	4	2	0,139
4	10	2	2	0,206
5	10	3	1,3	0,177
6	10	4	1	0,204
7	20	2	1	0,220
8	20	3	0,7	0,180
9	20	4	0,5	0,197

Powierzchnie obrobione poddano analizie z zastosowaniem systemu pomiarowego Talysurf CCI 6000 firmy Taylor Hobson. Zasada działania urządzenia oparta jest na wykorzystaniu jednej z odmian interferometrii światła białego (ang. WLI – White Light Interferometry) tzw. szerokopasmowej interferometrii skaningowej (ang. SBI – Scanning Broadband Interferometry). Dla zmierzonych fragmentów powierzchni o wymiarze $0,899 \times 0,899$ mm wyznaczono parametr Sa (wyniki pomiaru zamieszczono w kolumnie 5 tabeli 1).

Wyniki symulacji procesu szlifowania

W celu weryfikacji procedur strojenia modeli symulacyjnych przeprowadzono eksperyment numeryczny zgodnie z planem określonym w tabeli 2. Dla uzyskanych w wyniku symulacji modeli powierzchni obrobionych wyznaczono wartość parametru chropowatości Sa.

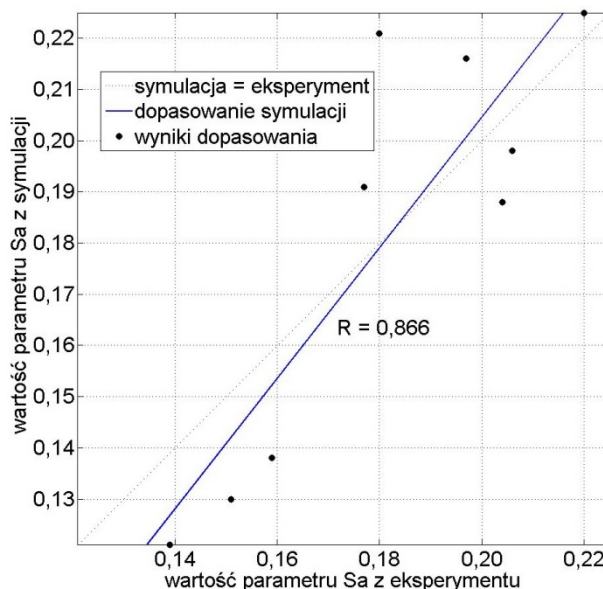
Tab.2. Plan i wyniki eksperymentu numerycznego (symulacji)

numer punktu pomiarowego	a_e [μm]	v_{ft} [m/min]	f_a [mm/skok]	Sa [μm]
1	5	2	4	0,138
2	5	2	2	0,104
3	5	2	1	0,085
4	5	3	4	0,148
5	5	3	2,7	0,130
6	5	3	1,3	0,102
7	5	3	0,7	0,080
8	5	4	4	0,154
9	5	4	2	0,121
10	5	4	1	0,100
11	5	4	0,5	0,083
12	10	2	4	0,271
13	10	2	2	0,198
14	10	2	1	0,158
15	10	3	4	0,292
16	10	3	2,7	0,245
17	10	3	1,3	0,191
18	10	3	0,7	0,154
19	10	4	4	0,305
20	10	4	2	0,241
21	10	4	1	0,188
22	10	4	0,5	0,150
23	20	2	4	0,386
24	20	2	2	0,284
25	20	2	1	0,225
26	20	3	4	0,411
27	20	3	2,7	0,348
28	20	3	1,3	0,272

29	20	3	0,7	0,221
30	20	4	4	0,425
31	20	4	2	0,339
32	20	4	1	0,271
33	20	4	0,5	0,216

Kolorem żółtym w tabeli 2 oznaczono punkty pomiarowe symulacji zgodne z punktami pomiarowymi eksperymentu.

Na rysunku 3 porównano ze sobą wartości parametru chropowatości Sa dla obu eksperymentów.



Rys. 3. Porównanie wartości parametru chropowatości Sa powierzchni uzyskanych w wyniku eksperymentu oraz symulacji

Poprawność dopasowania wyników modelu symulacyjnego do wyników eksperymentu wynosi 87%. Średni błąd dopasowania wartości parametru chropowatości Sa wynosi $0,018 \mu\text{m}$ (10,6% analizując wartości względne), zaś błąd maksymalny wynosi $0,04 \mu\text{m}$ (18,6% względem wartości względnych).

Problemem w osiągnięciu wysokich zgodności parametrów chropowatości powierzchni uzyskanej w wyniku symulacji oraz powierzchni rzeczywistej, jest dokładne odwzorowanie struktury stereometrycznej powierzchni przed obróbką oraz powierzchni czynnej narzędzia ściernego [9-12]. Dokładność odwzorowania wymagana jest nie tylko w sensie statystycznym, ale przede wszystkim pod względem odwzorowania cech stereometrycznych decydujących o liczbie oraz rodzaju kontaktów ziaren ściernych z powierzchnią obrabianą. Problem ten nabiera decydującego znaczenia w przypadku obróbki z niewielkim dosuwem oraz małą prędkością przesuwu stycznego stołu skutkującymi małymi przekrojami warstw skrawanych.

Rozbieżności między wartościami parametrów chropowatości Sa powierzchni rzeczywistych i modelowych może być spowodowana brakiem implementacji w modelach komputerowych zjawiska wykruszania ziaren ściernych i ich oddziaływań w strefie obróbki.

■ Tworzenie i weryfikacja modelu neuronowego

Zbiorem wejściowym do modelu neuronowego ujmującego wpływ modelowanych parametrów szlifowania na parametr chropowatości Sa powierzchni obrobionej jest macierz:

$$P^{K \times L} = [x_1; x_2; \dots; x_L] \quad (4)$$

gdzie: $x_i = [a_e, v_{ft}, f_a]^T$ jest wektorem kolumnowym określającym i -te parametry obróbki (zgodnie z planem eksperymentu).

Zbiorem wyjściowym jest wektor:

$$Sa^{1 \times L} = [Sa_1, Sa_2, \dots, Sa_L] \quad (5)$$

gdzie: Sa_i jest wartością parametru Sa chropowatości i -tej powierzchni obrobionej.

W wyniku działania sieci wielowarstwowej otrzymujemy aproksymowaną zależność określoną poniższym zapisem macierzowym:

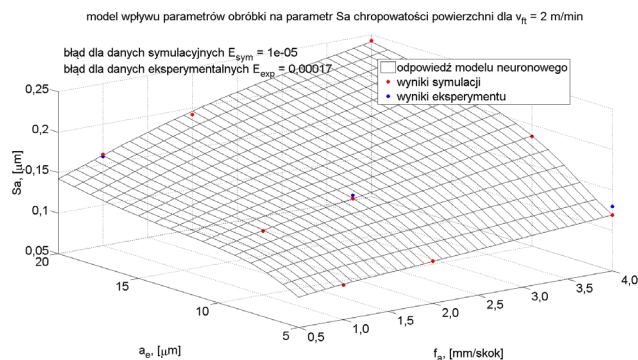
$$Sa = f(P \cdot W_1) \cdot W_2 \quad (6)$$

gdzie: funkcja $f(\cdot)$ jest funkcją sigmoidalną aktywacji neuronów w warstwie ukrytej, W_1 i W_2 odpowiednio macierzami wag w warstwie wejściowej i ukrytej sieci neuronowej.


Liczba neuronów w warstwie wejściowej i wyjściowej określona jest przez wymiar wektora wejściowego i wyjściowego. Problemem zostaje określenie liczby warstw ukrytych oraz liczby neuronów w tychże warstwach.

Podstawą do poszukiwań optymalnej architektury sieci jest m.in. teoria Kołmogorowa [20]. Teoria Kołmogorowa pozwala na określenie maksymalnej liczby warstw i neuronów w warstwach pozwalających na rozwiązanie problemu aproksymacji funkcji ciągłej, bez określenia postaci funkcji aktywacji oraz algorytmu optymalizacji wag połączeń sieci. Daje ona jednak jedynie przybliżenie idealnej liczby neuronów warstw i neuronów w warstwach ukrytych. W zastosowaniach praktycznych liczba neuronów w warstwach ukrytych waha się od \sqrt{N} do $3N$.

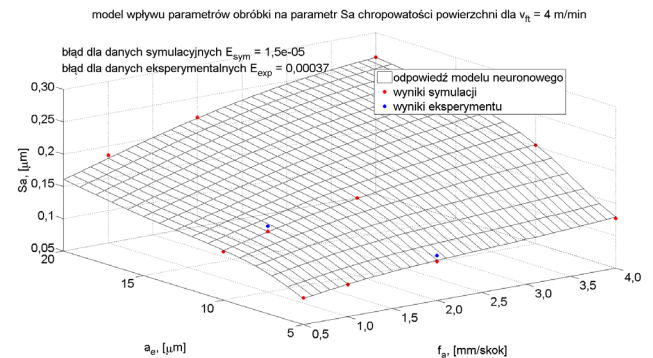
W przypadku modelowania parametru chropowatości Sa powierzchni obrobionej najkorzystniejsze rezultaty uzyskano w wyniku zastosowania sieci dwuwarstwowej o strukturze 3-4-1. Dalszy wzrost liczby neuronów w warstwie ukrytej nie prowadził do znaczącej poprawy dopasowania modelu zwiększając jedynie czas uczenia sieci. Przykładowe wyniki modelowania przedstawiono na rysunkach 4 do 6.



Rys. 4. Wyniki modelowania parametru Sa chropowatości powierzchni obrobionej w zależności od przyjętych parametrów obróbki ($v_R=2m/min$)




Rys. 5. Wyniki modelowania parametru Sa chropowatości powierzchni obrobionej w zależności od przyjętych parametrów obróbki ($v_R=3m/min$)



Rys. 6. Wyniki modelowania parametru Sa chropowatości powierzchni obrobionej w zależności od przyjętych parametrów obróbki ($v_R=4m/min$)

Opracowane modele pozwalają na prognozowanie parametru chropowatości powierzchni Sa . Na ich podstawie możliwe jest wyznaczenie przestrzeni dopuszczalnych parametrów obróbki zapewniających uzyskanie założonych parametrów chropowatości.

W celu oceny dokładności dopasowania modelu zestawiono wartości modelowe z danymi symulacyjnymi oraz wartościami uzyskanymi w wyniku eksperymentu. Wyniki zestawiono na rysunku 7. W podobny sposób przeprowadza się modelowanie innych zależności opisujących inne parametry chropowatości powierzchni, składowe siły szlifowania lub trwałość narzędzi.



Rys. 7. Porównanie wartości parametru Sa chropowatości powierzchni dla modelu neuronowego z: a) wynikami symulacji, b) wynikami eksperymentu

Poprawność dopasowania wyników modelu neuronowego do wyników symulacji wynosi 99% a do wyników eksperymentu 87%. Uzyskane wyniki wskazują na dokładne odwzorowanie wyników symulacji przez model neuronowy, błąd dopasowania do danych eksperymentalnych jest spo-

wodowany wyłącznie błędem dopasowania modelu symulacyjnego.

PODZIĘKOWANIA

Badania zrealizowano w ramach projektu pt. „Innowacyjne, hybrydowe narzędzia ścierne do obróbki stopów metali lekkich” realizowanego w ramach programu „Innotech” w ścieżce programowej IN-TECH, finansowanego przez Narodowe Centrum Badań i Rozwoju, umowa nr INNO-TECH-K3/IN3/43/229135/NCBR/14.

PODSUMOWANIE

Zastosowanie systemów symulacji procesów szlifowania oraz opracowanie procedur strojenia parametrów symulacji na podstawie danych eksperymentalnych umożliwia analizę wpływu parametrów i warunków obróbki na wyniki procesu szlifowania. Poprawność dopasowania wyników modelu symulacyjnego do wyników eksperymentu, dla przyjętych warunków i parametrów obróbki, wynosi 87%.

Problemem w opracowaniu zależności neuronowych dla szerokiego zakresu parametrów i warunków obróbki jest konieczność posiadania pełnego zestawu danych umożliwiającego przeprowadzenie procesu uczenia sieci. Wykorzystując procedury symulacji procesu szlifowania możliwe jest uzyskanie danych na podstawie wybiórczego planu eksperymentu, którego wyniki zostaną wykorzystane w procesie strojenia parametrów symulacji.

Utworzone z zastosowaniem przedstawionej metodyki modele neuronowe prognozujące wartość parametru S_a powierzchni obrobionej na podstawie przyjętych parametrów obróbki (dosuw szlifowania a_e , prędkość posuwu stycznego stołu v_{ft} oraz posuw osiowy stołu f_a) wykazują dopasowanie do danych eksperymentalnych na poziomie 87% (odpowiadającemu dopasowaniu systemu symulacji).

Integracja źródeł informacji (pochodzących z systemów symulacji procesów szlifowania oraz danych eksperymentalnych) umożliwia uzyskanie efektu synergii zapewniającego uzyskanie wyższego stopnia wiedzy o stanie procesu oraz umożliwia podjęcie właściwych decyzji zapewniających uzyskanie wymaganej jakości i dokładności obróbki.

Zastosowanie metod symulacji numerycznych procesu precyzyjnego szlifowania oraz metod sztucznej inteligencji umożliwia prognozowanie stanu procesu, stanowić również może podstawę oceny skutków technologicznych wypracowanych decyzji optymalizacyjnych.

LITERATURA

- Zhou X., Xi F.: Modeling and predicting surface roughness of the grinding process, *International Journal of Machine Tools and Manufacture*, 42 (2002), str. 969-977.
- Hecker R.L., Liang S.Y., Predictive modeling of surface roughness in grinding, *International Journal of Machine Tools and Manufacture*, 43(2003), str. 755-761.
- Cao Y., Guan J., Li B., Chen X., Yang J., Gan C., Modeling and simulation of grinding surface topography considering wheel vibration, *International Journal of Machine Tools and Manufacture*, 66(2013), str. 937-945.
- Kacalak W., Szafraniec F., Modelowanie obciążeń ziaren aktywnych i sił w procesie szlifowania, *Mechanik* 8/9 2013, str. 241-252.
- Metodyka określania granicznej minimalnej grubości warstwy szlifowanej z zastosowaniem ściernic do mikroszlifowania *Mechanik*, 8-9(2012), str. 235-243
- Kacalak W., Królikowski T., Szafraniec F., Kunc R., Remelska H., Metodyka doboru parametrów mikro- i nanoszlifowania dla określonych wymagań dotyczących chropowatości powierzchni, *Podstawy i technika obróbki ścierniej, Materiały XXXIII Naukowej Szkoły Obróbki Ścierniej w: Podstawy i technika obróbki ścierniej, Wydawnictwo Uczelniane Politechniki Łódzkiej*, 2010, str. 413-427.
- Wang D., Ge. P., Bi W., Jiang J., Grain trajectory and grinding workpiece contact analyses for modeling of grinding force and energy partition, *International Journal of Machine Tools and Manufacture*, 70(2011), str. 2111-2123.
- Lipiński D., Kacalak W., Tomkowski R., Methodology of evaluation of abrasive tool wear with the use of laser scanning microscopy, *Scanning* 36:1 (2014), str. 53-63.
- Chen X., Rowe B.W., Analysis and simulation of the grinding process, part I: generation of the grinding wheel surface, *International Journal of Machine Tools and Manufacture*, 36(1996), str. 871-882.
- Xie J., Xu J., Tang Y., Tamaki J., 3D graphical evaluation of micron-scale protrusion topography of diamond grinding wheel, *International Journal of Machine Tools and Manufacture*, 48(2008), str. 1254-1260.
- Nguyen T.A., Butler D.L., Simulation of precision grinding process, part 1: generation of the grinding wheel surface, *International Journal of Machine Tools and Manufacture*, 45(2005), str. 1321-1328.
- Wang Y., Moon K.S., A methodology for the multiresolution simulation of grinding wheel surface, *Wear*, 211(1997), str. 218-225.
- Tang J., Du J., Chen Y., Modeling and experimental study of grinding forces in surface grinding, *Journal of Materials Processing Technology*, 209(2009), str. 2847-2854.
- Hecker R.L., Liang S.Y., Wu X.J., Xia P., Guo D., Jin W., Grinding force and power modeling based on chip thickness analysis. *International Journal of Advanced Manufacturing Technology* 33:5/6 (2007), str. 449-459.
- Kacalak W., Szafraniec F., Królikowski T., Kunc R., Remelska H., Wybrane problemy maksymalizacji wydajności mikro- i nanoszlifowania dla ograniczeń nałożonych na określone parametry chropowatości powierzchni, *Podstawy i technika obróbki ścierniej, Materiały XXXIII Naukowej Szkoły Obróbki Ścierniej w: Podstawy i technika obróbki ścierniej, Wydawnictwo Uczelniane Politechniki Łódzkiej*, 2010, str. 455-469.
- Kacalak W., Szafraniec F., Tomkowski R., Metodyka modelowania powierzchni ziaren określonych materiałów ściernych, *Innovative Manufacturing Technology*, Instytut Zaawansowanych Technologii Wytwarzania, 2012, str. 555-562.
- Govindhasamy J.J., McLoone S.F., Irwin G.W., French J.J., Doyle R.P., Neural modelling, control and optimization of an industrial grinding process, *Control Engineering Practice*, 13(2005), str. 1243-1258.
- Kumar S., Choudhury S.K., Prediction of wear and surface roughness in electro-discharge diamond grinding, *Journal of Materials Processing Technology*, 191(2007), str. 206-209.
- Mukherjee I., Routroy S., Comparing the performance of neural networks developed by using Lavenberg-Marquardt and Quasi-newton with the gradient descent algorithm for modelling a multiple response grinding process, *Expert Systems with Application*, 39 (2012), str. 2397-2407.
- Osowski S., Sieci neuronowe do przetwarzania informacji, Oficyna Wydawnicza Politechniki Warszawskiej, 2000, Warszawa.