



Optimalizacja struktury sieci neuronowej do oceny zużycia narzędzia w procesie wiercenia laminatów CFRP/sklejka

Optimization of the neural network structure for tool wear estimation in the drilling process of CFRP/plywood laminates

Krzysztof Szwajka^{a,*}, ORCID: 0000-0002-1038-1148
Joanna Zielińska-Szwajka^b, ORCID: 0000-0002-6212-2666

^aPolitechnika Rzeszowska, Wydział Mechaniczno-Technologiczny, Zakład Zintegrowanych Systemów Projektowania i Tribologii, ul. Kwiatkowskiego 4, 37-450 Stalowa Wola, Polska

^bPolitechnika Rzeszowska, Wydział Mechaniczno-Technologiczny, Zakład Wytwarzania Komponentów i Organizacji Produkcji, ul. Kwiatkowskiego 4, 37-450 Stalowa Wola, Polska

*Osoba do korespondencji: kszwajka@prz.edu.pl

Streszczenie

System diagnostyki stanu narzędzia jest wciąż brakującym elementem wyposażenia zaawansowanych maszyn do obróbki skrawaniem. Monitorowanie stanu narzędzi jest ważnym problemem w produkcji mebli i podobnych branżach. Efektywny układ tego typu zwiększyłby wydajność obróbki, przy jednoczesnym wzroście dokładności i niezawodności. Pozwoliłby również na pełną, elastyczną automatyzację wytwarzania. W pracy przedstawiono metodę szacowania zużycia ostrza na podstawie wielu miar sygnałów diagnostycznych. Typowym rozwiązaniem problemu aproksymacji zużycia ostrza na podstawie wielu miar jest zastosowanie sieci neuronowej. Najpopularniejszą siecią jest perceptron wielowarstwowy. Przedstawiono proces optymalizacji struktury i parametrów sieci.

Abstract

Tool condition diagnostics system is still a missing element of advanced machining equipment. Tool condition monitoring is an important problem in furniture production and similar industries. An effective system of this type would increase machining efficiency, while increasing accuracy and reliability. It would also allow for full, flexible automation of production. This paper presents a method for estimating blade wear based on multiple measures of diagnostic signals. A typical solution to the problem of approximating blade

wear based on multiple measures is the use of a neural network. The most popular network is a multilayer perceptron. The process of optimizing the structure and parameters of the network is presented.

Słowa kluczowe: wiercenie, opory skrawania, sieci neuronowe, zużycie narzędzia

Keywords: drilling, cutting resistance, neural networks, tool wear

Wprowadzenie

W dostępnych na rynku systemach nadzoru stanu narzędzia skrawającego dominuje najprostsza strategia jednoczynnikowa (Szwajka, K., et al., 2023). Publikacje prezentowane na całym świecie zgodnie stwierdzają, że takie podejście nie wystarcza do poprawnej oceny zużycia narzędzia i że jedynie zastosowanie wielu czujników może dać zadowalające rezultaty (Byrne, G., et al., 1995; Choi, G. S., et al., 1990). Sztuczna inteligencja, czy systemy ekspertowe, które wykorzystują zarówno informacje z wielu czujników jak i parametry skrawania wciąż pozostają w sferze badań laboratoryjnych (Choi, G. S., et al., 1990; Dornfeld, D. A., 1990). W wiodących ośrodkach badawczych podejmuje się jednak wiele wysiłku, w celu stworzenia efektywnego, inteligentnego układu nadzorującego. Obecnie do diagnozowania zużycia ostrza na podstawie sygnałów z wielu czujników korzysta się najczęściej z sieci neuronowych (Zhou, X., et al., 2023; Wang, J., et al., 2018), Neuro-Fuzzy (Tao, F., et al., 2018; Xu, L., et al., 2021) i logiki rozmytej (Saw, L. H., et al., 2018; Cheng, Y., et al., 2023). Szeroki przegląd takich rozwiązań można znaleźć w literaturze (Munaro, R., et al., 2023; Wang, Y., et al., 2023). Najpopularniejszą siecią jest perceptron wielowarstwowy (Wang, Y., et al., 2023; Szwajka, K., et al., 2024).

Od kilku lat prowadzone są badania nad zastosowaniem sieci neuronowych (SN) do automatycznej oceny zużycia ostrzy narzędzi skrawających. Z sygnałów sił skrawania i emisji akustycznej rejestrowanych podczas prób skrawania wyznaczane są miary statystyczne. Do najczęściej wyznaczanych miar należy wartość średnia i odchylenie standardowe. Miary te wraz z parametrami skrawania służą jako dane do uczenia SN. Na podstawie tych danych, wyznaczanych na bieżąco podczas obróbki, nauczona wcześniej sieć neuronowa może przewidzieć wartość zużycia z niewielkim błędem.


Wykonano cztery próby trwałościowe. Zastosowano sieć neuronową: perceptronową typu FFBP. Celem tych badań było znalezienie minimalnej struktury sieci i sposobu jej treningu przy zachowaniu dobrej jakości odpowiedzi, czyli niskiego poziomu błędów. W artykule opisano metodykę przeprowadzonych badań trwałościowych. W dalszej kolejności zawarto wyniki optymalizacji struktury sieci neuronowej, a następnie przedstawiono wnioski wynikające z badań.

Cel i zakres pracy

Celem tych badań było znalezienie minimalnej struktury sieci i sposobu jej treningu przy zachowaniu dobrej jakości odpowiedzi, czyli niskiego poziomu błędów. W ramach badań wykonano cztery próby trwałościowe. Zastosowano sieć neuronową: perceptronową typu FFBP. Proponowana metoda została zweryfikowana poprzez eksperymentalne próby wierceń.


Materiały i metodyka badań

W badaniach zastosowano płytę sklejkową o grubości 9 mm oraz płytę CFRP o grubości 3 mm. Płyta CFRP została przyklejona jednostronnie do zewnętrznej powierzchni sklejki. Do testów użyto typowego narzędzia skrawającego, którym było wiertło jednoostrzowe o średnicy 5 mm wykonane z węgla HW firmy Leitz (Rys. 1).



Rys. 1. a) wskaźnik delaminacji; b) wskaźnik zużycia narzędzia; c) wiertło
Fig. 1. a) procedure for measuring delamination factor; b) procedure for measuring the tool wear; c) drill

W testach wiercenia rejestrowano wartości siły posuwowej (F_f) i momentu skrawania (M_c) podczas obróbki. Ponadto, dokonywano pomiaru wskaźnika rozwarstwienia laminatu F_d oraz pomiaru wskaźnika zużycia ostrza VB . Pomiar obu wskaźników przeprowadzano każdorazowo po serii wykonania trzydziestu otworów. Ponieważ w badaniach zastosowano zmienne parametry skrawania, jako wskaźnik zużycia brano pod uwagę starcie ostrza na powierzchni przyłożenia w strefie naroża. Do określania wartości tego wskaźnika użyty został mikroskop warsztatowy. Niepewność pomiaru można przyjąć jako 0.01. Otwory wiercono w płycie CFRP/plywood. W badaniach stosowano stałą prędkość obrotową 3000 obr/min i trzy wartości posuwu: 0.10; 0.15 i 0.20 mm/obr. Próby trwałościowe narzędzia oznaczono jako: T1, T2, T3 i T4. Wartość siły posuwowej i momentu skrawania mierzono za pomocą piezoelektrycznego czujnika przemysłowego Kistler 9345B2 (Rys. 2). Sygnały z czujnika rejestrowano na dysku komputera osobistego (PC) za pomocą 16-bitowej karty analogowo-cyfrowej National Instruments 6034E o częstotliwości próbkowania 50 Hz. Powierzchnię wokół każdego rejestrowano za pomocą kamery.



Rys. 2. Konfiguracja eksperymentalna i schemat systemu akwizycji danych

Fig. 2. Experimental setup and diagram of the data acquisition system

Wyniki badań

Mając do dyspozycji dane z czterech prób trwałościowych narzędzia przystąpiono do eksperymentów z sieciami neuronowymi. Najwięcej uwagi poświęcono sieci typu FFBP i jej możliwościom pod kątem jakości predykcji zużycia wiertła. Minimalizacja struktury obejmowała głównie rozmiar wektora wejściowego, liczbę miar i parametrów wykorzystywanych przez sieć. Postąpiono tak ze względu na to, że ilość informacji wchodzących do sieci wymaganych do poprawnej oceny zużycia wpływa na koszt układu diagnostycznego. Do symulacji sieci neuronowej FFBP użyto oprogramowania stworzonego i modyfikowanego we własnym zakresie. Umożliwia ono między innymi:


- obserwację RMS błędu i błędu maksymalnego dla pliku uczącego (eu i mu) i testującego (et i mt) jednocześnie;
- zmianę współczynników uczenia sieci: η_1 - wsp. szybkości uczenia i η_2 - momentum;
- automatyczne lub ręczne zakłócanie struktury sieci poprzez dodawanie bądź losowych wartości z określanego przez użytkownika przedziału, bądź wybranych stałych liczb, do każdej z wag połączeń między warstwami neuronowymi; zakłócanie automatyczne wyzwalane jest po upływie dowolnie ustalonej liczby iteracji od chwili, gdy błąd RMS uczenia przestaje maleć;
- automatyczny pruning (redukcję) neuronów ukrytych, gdy błąd RMS odpowiedzi całej sieci spadnie poniżej założonej wartości, a zmienność wyjścia rozpatrywanego neuronu będzie niższa od narzuconej przez użytkownika granicy;
- ręczny pruning wejść na podstawie informacji o przewidywanych błędach po usunięciu dowolnego wejścia i dla kompletnej sieci.

W literaturze coraz częściej można spotkać pogląd, że sieć trzywarstwowa (z jedną warstwą ukrytą) może spełnić te same zadania, co sieć czterowarstwowa. Postanowiono zweryfikować ten pogląd w zastosowaniu do uzyskanych danych pomiarowych. Na wstępie przyjęto następujące struktury sieci:

- sieć czterowarstwowa: 4 - 10 - 5 - 1;
- sieć trzywarstwowa: 4 - 10 - 1;

W obu przypadkach wejściami do sieci były: wartość posuwu, wskaźnik rozwarstwienia laminatu, siła posuwowa i moment skrawania. Do analizy przyjęto $\eta_1 = 0.9$ oraz $\eta_2 = 0.9$.

Na Rys. 3 przedstawiono przebieg naturalnego, tzn. bez żadnych zakłóceń, uczenia sieci 4-warstwowej. Są tu błędy uczenia (eu) i błędy testowania sieci na próbie T1 (et), maksymalne błędy uczenia (mu) oraz średnie zmiany wag sieci. Ta ostatnia wielkość informuje o szybkości zmian, jakim podlega sieć. Sieć uczyła się (obniżała błędy uczenia) bardzo szybko na początku, po czym szybkość ta wyraźnie spadała. To naturalne zjawisko. Po 100000 iteracji błędy eu i et się ustabilizowały, stąd zapamiętano stan sieci jako 4W105a. Później nastąpiła intensyfikacja zmian sieci, osiągająca swoje maksimum po nieco ponad 200000 iteracji. Zaraz potem (po 220500 iteracjach) sieć osiągnęła minimum błędów testowania. Ten stan sieci został automatycznie wykryty przez program i zarejestrowany jako 4W105etm. Dalsze uczenie sieci prowadziło do naturalnego spadku błędów uczenia lecz także do wzrostu błędów testowania. Po prawej stronie Rys. 3 zestawiono wyniki uzyskanych sieci dla wszystkich czterech prób. Wyniki dla prób T1 i T2 są widoczne na rysunku, tablica 1 je jedynie precyzuje i dodaje maksymalne błędy testowania. Wiersz odpowiadający próbie T2 odnosi się oczywiście do błędów uczenia, a nie testowania.



Rys. 3. Przebieg naturalnego uczenia sieci 4-warstwowej i wyniki uzyskanych sieci
Fig. 3. The training process of a four-layer Network

Tabela 1. Wyniki sieci 4-warstwowej


Table 1. Quantitative results of the training process of the four-layer Network

Test	4W105a		4W105etm		4W105	
	rms	max	rms	max	rms	max
T1	0.047	0.125	0.045	0.120	0.050	0.123
T2	0.029	0.075	0.025	0.067	0.020	0.065
T3	0.064	0.129	0.067	0.137	0.070	0.150
T4	0.043	0.134	0.044	0.141	0.044	0.129
Wart. śred.	0.046	0.116	0.045	0.116	0.046	0.117

Analiza błędów uzyskanych w próbach T3 oraz T4 przynosi istotne wyniki. Najlepsza okazała się tu sieć pierwsza, uzyskana po zaledwie 100000 iteracjach. Dalsze uczenie sieci prowadziło zawsze do poprawienia wyników dla próby T2, minimum błędów dla próby T1 po

220500 iteracjach i systematycznego pogarszania wyniku dla prób T3 i T4. W sumie wyniki wszystkich trzech sieci dla wszystkich czterech prób (wartości średnie w ostatnim wierszu Tabeli 1) są niemal identyczne. Oznacza to bardzo ważny dla praktyki wniosek, że nie należy zbyt wagi przywiązywać do błędów testowania w czasie uczenia sieci. Wyniki uzyskane dla innych danych, mogą nie być zbieżne z uzyskanymi dla zbioru wykorzystanego do takiego testowania. Testowanie stanowić może jedynie przybliżoną wskazówkę o ewentualnym przetrenowaniu sieci, czyli zbytym dopasowaniu do zbioru uczącego, co skutkuje brakiem zdolności do uogólnienia i pogorszeniem wyniku dla innych danych niż uczące.

W dalszej części zajęto się analogicznym uczeniem sieci trzywarstwowej. Przebieg tego uczenia i uzyskane wyniki zestawiono na Rys. 4. Podobnie jak poprzednio zarejestrowano stan sieci po 100000 iteracji (sieć 3W10a). Tym razem nie wystąpiło minimum błędów testowania, a sieć do końca poprawiała błędy uczenia i testowania. Warto także zauważyć, iż mimo znacznie prostszej struktury, sieć trzywarstwowa uzyskała stabilizację szybkości zmian wag po większej liczbie iteracji niż sieć czterowarstwowa. Po 100000 iteracji średnie wyniki uzyskane przez sieć 3- i 4-warstwową były prawie identyczne. Później jednak sieć trzywarstwowa poprawiała swój wynik i to nie tylko dla zbioru uczącego (co oczywiste), lecz także dla wszystkich innych zbiorów. Przemawia to na korzyść sieci 3-warstwowej, a przynajmniej nie podważa wspomnianego wcześniej poglądu o równoważności tych struktur.




Rys. 4. Przebieg naturalnego uczenia sieci 3-warstwowej i wyniki oceny uzyskanych sieci
Fig. 4. The training process of a four-layer Network

Oczywiście obok liczby warstw, duże znaczenie może mieć liczba komórek w poszczególnych warstwach. Stąd też przed ostateczną decyzją co do przyjęcia sieci 4- lub 3-warstwowej, podjęto próbę zmniejszenia liczby komórek.

Tabela 2. Wyniki sieci 3-warstwowej**Table 2.** Quantitative results of the training process of the three-layer network

Test	3W10a		3W10	
	rms	max	rms	max
T1	0.052	0.123	0.047	0.121
T2	0.031	0.081	0.026	0.067
T3	0.063	0.131	0.062	0.132
T4	0.043	0.130	0.041	0.120
Wart. śred.	0.047	0.116	0.044	0.112



Rys. 5. Przebieg autokonfiguracji sieci 4-warstwowej
Fig. 5. Auto-configuration process of a four-layer network


Doboru właściwej liczby neuronów postanowiono dokonać w oparciu o opracowany we własnym zakresie algorytm automatycznego doboru struktury sieci wykorzystującego pruning komórek. Polega on na tym, że po osiągnięciu przez błąd uczenia zadanej wartości (eu_{pr}), świadczącej o dobrym wytrenowaniu sieci, następuje analiza zmienności na wyjściach wszystkich komórek. Wybierana jest ta, której zmienność jest najmniejsza i o ile jest ona niższa od założonego tzw. parametru pruningu (pr), komórka ta jest usuwana. Średnią wartość jej wyjścia rozkłada się równomiernie na wartości progowe (bias) pozostałych komórek w warstwie. Stan sieci przed usunięciem komórki jest zapamiętywany. Minimalna liczba iteracji pomiędzy kolejnymi próbami usunięcia zbędnej komórki (it_{pr}) jest deklarowana przez użytkownika. Na podstawie przedstawionych wyżej przebiegów naturalnego uczenia sieci, przyjęto minimalny błąd uczenia, zezwalający na pruning komórek, na poziomie $eu_{pr} = 0.3$. Ponadto przyjęto arbitralnie $pr = 0.2$ oraz $it_{pr} = 2500$. Na Rys. 5 przedstawiono przebieg uczenia sieci 4-10-5-1 z automatycznym pruningiem komórek (autokonfiguracja sieci). Na Rys. 6 natomiast przebieg autokonfigurowania sieci 3-warstwowej. Już na pierwszy rzut oka zaobserwować można podobieństwo zmienności

zarówno błędów sieci jak i zmienności wag w trakcie autokonfiguracji w stosunku do naturalnego uczenia (porównując Rys. 3 i 5 oraz 4 i 6).

Tabela 3. Wyniki ilościowe procesu autokonfiguracji sieci czterowarstwowej

Table 3. Quantitative results of the auto-configuration process of the four-layer network

Test	4W82Aetm		4W82A	
	rms	max	rms	max
T1	0.046	0.115	0.050	0.124
T2	0.023	0.066	0.020	0.066
T3	0.067	0.142	0.069	0.150
T4	0.044	0.139	0.044	0.126
Wart. śred.	0.045	0.116	0.046	0.117



Rys. 6. Przebieg autokonfiguracji sieci 3-warstwowej
Fig. 6. Auto-configuration process of a three-layer Network

Jak widać usuwanie kolejnych komórek powodowało jedynie „chwilowe” zakłócenie przebiegu uczenia, a po niewielkiej liczbie iteracji, sieć wracała do stanu sprzed pruningu. Usuwanie kolejnych komórek odbywało się szybko jedno po drugim, gdy tylko sieci osiągnęły założony poziom błędów uczenia. Świadczy to o właściwym doborze parametrów autokonfiguracji. Sieć czterowarstwowa dała się zredukować do 4-8-2-1, czyli wyeliminowano 5 komórek. W czasie dalszego uczenia, zmienność wyjść pozostałych komórek nie spadała poniżej założonego progu $pr = 0.2$.


Inaczej rzecz się miała w przypadku sieci trzywarstwowej. Tu po stosunkowo szybkim usunięciu 4 komórek, długo nie następowały żadne zmiany. Dopiero po 405250 iteracjach usunięta została piąta komórka, co pociągnęło za sobą wyraźne pogorszenie jakości sieci (podwyższenie błędów), które spadały w trakcie dalszego uczenia wolno, nie osiągając poprzedniego poziomu nawet po blisko 100000 iteracji. Wyniki podawane w Tabelach 3 i 4

przy powyższych rysunkach są oczywiście obiektywną miarą jakości sieci, jednakże z punktu widzenia użytkownika ważniejszy jest rozkład błędów oszacowania zużycia popełnianych przez sieć w funkcji czasu. Stąd na Rys. 7 przedstawiono podsumowanie wyników najlepszych z dotychczas uzyskanych sieci (4W82etm oraz 3W6A) w postaci porównania rzeczywistych przebiegów zużycia (pogrubione, monotoniczne przebiegi) z oszacowanymi przez te sieci. Jak widać, dokładność oszacowania zużycia rośnie wraz z jego wartością. Dla $VB = 0.3$ mm (wielkość odpowiadająca koniecznemu w tych warunkach skrawaniu wskaźnikowi stępienia) przewidywanie to jest bardzo dokładne. Wyniki uzyskiwane przez obie sieci są bardzo zbieżne ze sobą, co świadczy o ich równoważności. Ostatecznie można zatem przyjąć do dalszych rozważań sieć 3-warstwową.

Tabela 4. Wyniki ilościowe procesu autokonfiguracji sieci trzywarstwowej

Table 4. Quantitative results of the auto-configuration process of the three-layer network

Test	4W82Aetm		4W82A	
	rms	max	rms	max
T1	0.046	0.121	0.050	0.124
T2	0.026	0.067	0.030	0.079
T3	0.062	0.131	0.061	0.123
T4	0.040	0.121	0.041	0.120
Wart. śred.	0.044	0.113	0.046	0.112



Rys. 7. Porównanie rzeczywistego przebiegu zużycia z oszacowanym przez sieci 4W82etm i 3W6A we wszystkich próbach

Fig. 7. Comparison of the real consumption profile with that estimated by the 4W82etm and 3W6A networks in all tests

Wnioski

Jak wynika z analizy przedstawionych wyników zastosowana w badaniach sieć perceptronowa typu FFBP bardzo dobrze nadaje się do automatycznej oceny stanu zużycia ostrza na podstawie użytych miar sił i parametrów skrawania. Pod względem implementacji jest to najłatwiejsze narzędzie realizujące odwzorowania w wielowymiarowych przestrzeniach miar, parametrów i zużycia.

Sieci neuronowe nie wymagają poświęcania szczególnej uwagi danym wejściowym. Wystarczy skorzystać z wyciągniętych wcześniej wniosków dotyczących wyboru miar i struktury sieci, a następnie nauczyć sieć oczekiwanego odwzorowania. Sieć perceptronowa dobrze reaguje na zmienne wejściowe. Przy sztucznej inteligencji można z niewielkim błędem szacować zużycie ostrza narzędzia. Błąd ten ulega wyraźnej redukcji przy obniżeniu liczby danych uczących odpowiadających węższemu zakresowi zużycia. Zawężenie takie jest konieczne, ponieważ odwzorowanie danych w zużycie poniżej wartości 0.15 mm jest niemożliwe, a próby uczenia sieci na całych przebiegach miar prowadzą do wzrostu błędów w istotnym przedziale 0.2-0.3 mm. Ponieważ producenci narzędzi skrawających określają wskaźnik stopienia dla nowoczesnych, wielokrotnie pokrywanych wiertel na ok. 0.3 mm (VB), ważniejsza jest znajomość dokładnego zużycia w zakresie od 0.2 do 0.3 mm niż w całym przedziale zmienności tych parametrów. Błąd oceny powyższych wskaźników wynika nie tyle z niedoskonałości samych narzędzi realizujących odwzorowanie, co z rozrzutu użytych miar spowodowanego głównie błędami pomiarowymi przy określaniu zużycia.

W przyszłości planuje się badania nad jakością oceny zużycia dla różnych wskaźników zużycia. Przewiduje się analizę zużycia ostrza na powierzchni przyłożenia na przebiegi siły skrawania. Celem tej analizy będzie znalezienie wskaźnika zużycia najlepiej skorelowanego z miarami siły siły posuwowej i momentu skrawania. Dodatkowo badania rozszerzone zostaną o inne typy sieci - np. samouczącą, a także o hybrydę logiki rozmytej i sieci neuronowych, czyli Neuro-Fuzzy.

Literatura

Szwajka, K., Zielińska-Szwajka, J., Trzecieński, T., 2023: The use of a radial basis function neu-ral network and fuzzy modelling in the assessment of surface roughness in the MDF milling process. *Materials* 16(15), 5292. DOI: <https://doi.org/10.3390/ma16155292>

Byrne, G., Dornfeld, D., Inasaki, I., Ketteler, G., Teti R., 1995: Tool condition monitoring (TCM) - The status of research and industrial application. *Annals of CIRP* 44(2), 541-567. DOI: [https://doi.org/10.1016/S0007-8506\(07\)60503-4](https://doi.org/10.1016/S0007-8506(07)60503-4)

Choi, G. S., Wang, Z. X., Dornfeld, D., 1990: Monitoring and control of machining process using neural networks. Progress Report to Omron Electronics.

Dornfeld, D. A., 1990: Neural network sensor fusion for tool condition monitoring. *CIRP Annals* 39(1), 101-105. DOI: [https://doi.org/10.1016/S0007-8506\(07\)61012-9](https://doi.org/10.1016/S0007-8506(07)61012-9)

Zhou, X., Yu, T., Wang, G., Guo, R., Fu, Y., Sun, Y., Chen, M., 2023: Tool wear classification based on convolutional neural network and time series images during high precision turning of copper. *Wear* 522, 204692. DOI: <https://doi.org/10.1016/j.wear.2023.204692>

Wang, J., Ma, Y., Zhang, L., Gao, R. X., Wu, D., 2018: Deep learning for smart manufacturing: Methods and applications. *Journal of Manufacturing Systems* 48, 144-156. DOI: <https://doi.org/10.1016/j.jmsy.2018.01.003>

Tao, F., Qi, Q., Liu, A., Kusiak, A., 2018: Data-driven smart manufacturing. *Journal of Manufacturing Systems* 48, 157-169. DOI: <https://doi.org/10.1016/j.jmsy.2018.01.006>

Xu, L., Huang, C., Li, C., Wang, J., Liu, H., Wang, X., 2021: Estimation of tool wear and optimization of cutting parameters based on novel ANFIS-PSO method toward intelligent machining. *Journal of Intelligent Manufacturing* 32, 77-90. <https://doi.org/10.1007/s10845-020-01559-0>

Saw, L. H., Ho, L. W., Yew, M. C., Yusof, F., Pambudi, N. A., Ng, T. C., Yew, M. K., 2018: Sensitivity analysis of drill wear and optimization using Adaptive Neuro fuzzy - genetic algorithm technique toward sustainable machining. *Journal of Cleaner Production* 172, 3289-3298. DOI: <https://doi.org/10.1016/j.jclepro.2017.10.303>

Cheng, Y., Gai, X., Guan, R., Jin, Y., Lu, M., Ding, Y., 2023: Tool wear intelligent monitoring techniques in cutting: a review. *Journal of Mechanical Science and Technology* 37, 289-303. DOI: <https://doi.org/10.1007/s12206-022-1229-9>

Munaro, R., Attanasio, A., Del Prete, A., 2023: Tool wear monitoring with artificial intelligence methods: A review. *Journal of Manufacturing and Materials Processing* 7(4), 129. DOI: <https://doi.org/10.3390/jmmp7040129>

Wang, Y., Chang, M., Huang, X., Li, Y., Tang, J., 2023: Cutting tool wear prediction based on the multi-stage Wiener process. *International Journal of Advanced Manufacturing Technology* 129, 5319-5333. DOI: <https://doi.org/10.1007/s00170-023-12648-8>

Szwajka, K., Zielińska-Szwajka, J., Trzepieciński, T., 2024: Experimental Analysis of Smart Drilling for the Furniture Industry in the Era of Industry 4.0. *Materials* 17(9), 2033. DOI: <https://doi.org/10.3390/ma17092033>

Artykuł recenzowany / Reviewed paper

Zgłoszony / Submitted: 14.05.2025

Opublikowany online / Published online: 19.12.2025