

Jerzy Józwik¹⁾

WYKORZYSTANIE SZTUCZNEJ SIECI NEURONOWEJ DO MODELOWANIA UGIĘCIA SPRĘŻYSTYCH PRZEDMIOTÓW OBRABIANYCH W PROCESIE SKRAWANIA TOCZENIEM

Streszczenie. W pracy przedstawiono przykład wykorzystania sztucznej sieci neuronowej MLP do predykcji ugięcia sprężystego wałka, przeznaczonego do obróbki tokarskiej. Zamieszczono przykładowe wyniki pomiarów eksperymentalnych strzałki ugięcia wałka zamocowanego w szczękach uchwytu tokarskiego bez podparcia. W analizach numerycznych uwzględniono wyniki kompletnych badań ugięcia, wałków o średnicach 16, 20, 25 i 30 mm. Analizowano najbardziej popularny przypadek zamocowania przedmiotu na obrabiarce.

Słowa kluczowe: proces skrawania, odkształcenia sprężyste, modelowanie, sztuczne sieci neuronowe.

WSTĘP

Modelowanie procesu skrawania a szczególnie odkształceń sprężystych i ciepłych przedmiotu obrabianego w aspekcie sterowania jakością obrabianego elementu jest jednym z priorytetowych zadań. Wiele modeli szeroko prezentowanych w literaturze ma najczęściej charakter uproszczony i kończy się na etapie rozpoznania podstawowych zależności pomiędzy badanymi wielkościami [1, 4, 12, 13]. Na podstawie prezentowanych wyników badań, błędy obróbki powodowane odkształceniami sprężystymi i ciepłymi są funkcją bardzo wielu zmiennych, których uwzględnienie podczas modelowania utrudnia, a czasami uniemożliwia wykorzystanie niektórych metod. Spotykane w literaturze modele - opracowane z zastosowaniem aparatu matematycznego posiadają szereg ograniczeń, chociażby z powodu dużej liczby założeń modelowanych związków [1, 4, 7, 9]. Powodem małej użyteczności modeli analityczno - doświadczalnych jest często fakt, iż badania mające na celu opracowanie strategii prognozowania prowadzone są w warunkach laboratoryjnych, które nie uwzględniają wielu czynników występujących w warunkach przemysłowych [10, 11].

Wykorzystanie sztucznych sieci neuronowych stanowi alternatywne rozwiązanie powyższych problemów [2, 5, 14]. Opracowane modele z wykorzystaniem sztucznych sieci neuronowych mogą mieć charakter wielowymiarowy, mogą uwzględniać bardzo wiele zmiennych wejściowych i wyjściowych oraz odwzorowywać bardzo

¹⁾ Katedra Podstaw Inżynierii Produkcji, Wydział Mechaniczny, Politechnika Lubelska.


złożone związki nieliniowe. Uwzględniając złożoność procesu skrawania i konieczność odwzorowywania skomplikowanych funkcji, sugerowana jest często potrzeba stosowania narzędzi inteligentnych, potrafiących poradzić sobie z problemem wielowymiarowości [2, 3, 5, 6, 14, 15, 17].

Modelowanie określonych w tytule niniejszej pracy związków przy zastosowaniu strategii „samo uczenia się”, pozwoli na diagnozowanie stanu geometrycznego przedmiotu na etapie przygotowania produkcji, dobór optymalnych warunków obróbki, a przez to minimalizację błędów wykonania gotowego wyrobu.


METODYKA BADAŃ I PRZEBIEG EKSPERYMENTU

Głównym celem badań eksperymentalnych było pozyskanie danych, niezbędnych do zbudowania modelu, opartego na sztucznych sieciach neuronowych. Model ten będzie odzwierciedlał złożone związki pomiędzy sprężystymi odkształceniami przedmiotu obrabianego y podczas obróbki tokarskiej a wartością składowej promieniowej siły skrawania $F=F_r$, położeniem punktu jej przyłożenia b i jego średnicą d . Badania rozpoznawcze i zasadnicze przeprowadzono na tokarce uniwersalnej S32.

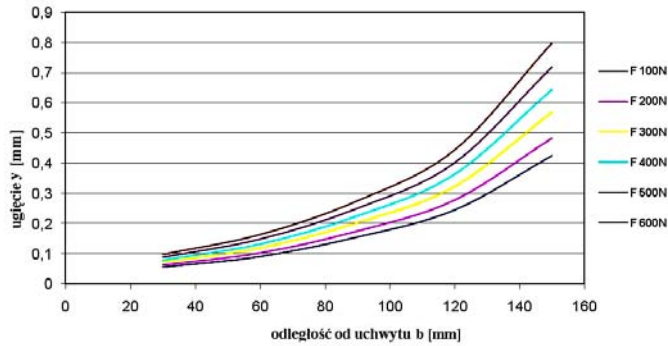
Symulowaną wartość składowej promieniowej siły skrawania $F=F_r$ zadawano przy wykorzystaniu siłomierza piezoelektrycznego Kistler (Typ 9257B) współpracującego ze wzmacniaczem ładunku (Typ 56017B) i sumatorem analogowym. Do pomiaru ugięcia sprężystego zastosowano laserowy czujnik przemieszczeń (optoNCDT1605/2) firmy Micro-Epsilon Masstechnik. Wartość siły F przyjęto na poziomie 100, 200, 300, 400, 500 i 600 N. Obciążeniu poddawano kolejno wałki o średnicach d równych 16, 20, 25 i 30 mm, siłą F położoną w odległościach $b = 30, 60, 90, 120, 150$ mm. W efekcie przeprowadzonego doświadczenia pozyskano dane, które wykorzystano do zbudowania zbiorów danych uczących walidacyjnych i testujących. Wybrane wyniki pomiarów eksperymentalnych przedstawiono na rysunkach 1–4.




Rys. 1. Krzywe eksperymentalne ugięcia wału $\phi 16$ dla różnych wartości promieniowej siły obciążającej w funkcji jej położenia od uchwytu



Rys. 2. Krzywe eksperymentalne ugięcia wału ϕ 20 dla różnych wartości promieniowej siły obciążającej w funkcji jej położenia od uchwyty




Rys. 3. Krzywe eksperymentalne ugięcia wału ϕ 25 dla różnych wartości promieniowej siły obciążającej w funkcji jej położenia od uchwyty



Rys. 4. Krzywe eksperymentalne ugięcia wału ϕ 30 dla różnych wartości promieniowej siły obciążającej w funkcji jej położenia od uchwyty

MODELOWANIE I WYNIKI

W oparciu o wyniki eksperymentalne przygotowano zbiory danych uczących i kontrolnych. Populację zestawów przypadków eksperymentalnych podzielono na trzy podzbiory: uczący, walidacyjny i testujący. W wyniku wielokrotnych poszukiwań wytypowano sieci neuronowe typu wielowarstwowy perceptron MLP (multilayer perceptron network) oraz sieci o radialnych funkcjach bazowych (RBF – radial basic function). Jako najlepszą sieć, którą wykorzystano do zbudowania modelu, w oparciu o kryterium minimum błędu RMS, wybrano sieć MLP o strukturze składającej się z jednej warstwy ukrytej o 7 neuronach (rys. 5).



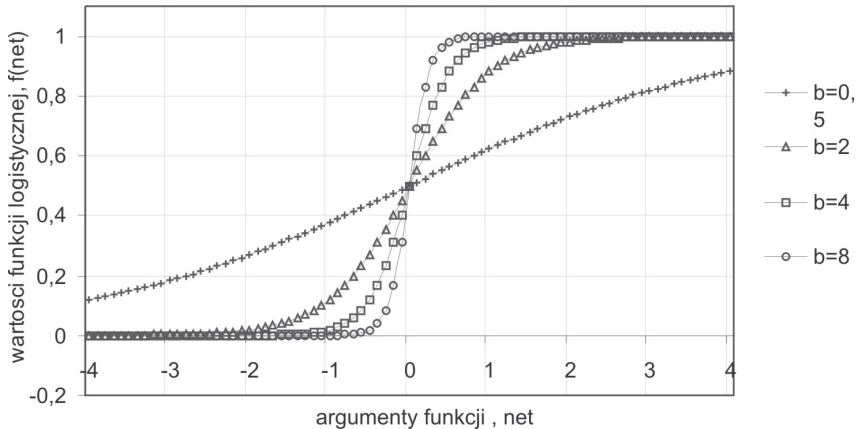
Rys. 5. Architektura sztucznej sieci neuronowej wykorzystanej do modelowania MLP 3:3-7-1:1: b, d, F – zmienne wejściowe, y – zmienna wyjściowa, h_1, h_2, h_3 – wielkości zakłócające, c_1, c_2 – wielkości stałe, b – odległości punktu przyłożenia siły F , d – średnica wałka, F – promieniowa siła obciążająca

Warstwę wejściową sieci stanowi: d – średnica wałka, F – siła promieniowa oraz położenie punktu przyłożenia promieniowej siły obciążającej przedmiot b . Jako zmienną wyjściową (w warstwie wyjściowej) wybrano ugięcie sprężyste przedmiotu y wywołane składową promieniową F . Do wielkości stałych c_i (gdzie $i=1; 2$) zaliczono brak zmienności przekroju poprzecznego próbki oraz niezmienny sposób zamocowania. Wielkości zakłócające h_i (gdzie $i=1; 2; 3$) stanowiły zaś: zmienna sztywności systemu OUPN, zmienna temperatura otoczenia, błędy toru pomiarowego sił i odkształceń. Sieć o tak zdefiniowanej strukturze uczono algorytmem wstecznej propagacji błędu BP (back propagation) stosując logistyczną funkcję aktywacji neuronów ukrytych (1).

$$f(net) = \frac{1}{1 + \exp^{-b \cdot net}} \quad (1)$$

gdzie: b – parametr, net – argument funkcji logistycznej.

Przebieg zmian wartości funkcji aktywacji $f(net)$ opisanej równaniem (1) w zależności od parametru b przedstawiono na rysunku 6. Wzrastająca wartość parametru b powoduje, że charakterystyki stają się bardziej strome, a przy dużych wartościach b , np. 8, niewielkie odchylenie wartości net od poziomu zerowego powoduje, że funkcja $f(net)$ znajdzie się w stanie nasycenia (rys. 6).



Rys. 6. Przebieg zmian wartości logistycznej funkcji aktywacji w zależności od parametru b

W wyniku złożonej procedury uczenia, walidacji i testowania otrzymano model, na podstawie którego można w łatwy i szybki sposób ocenić sprężyste ugięcie przedmiotu obrabianego klasy wałek. W tabeli 1 przedstawiono wyniki obliczeń parametrów regresji zmiennej wyjściowej modelu (ugięcia sprężystego przedmiotu y) bazującego na sieci MLP 3:3-7-1:1 uczonej algorytmem BP.

Charakterystyki regresyjne wyznaczono niezależnie dla zbiorów: uczącego, walidacyjnego i testującego. Na podstawie danych wartości zmiennej y (w powyżej wymienionych zbiorach) określono wartość średnią a następnie odchylenie standardowe i

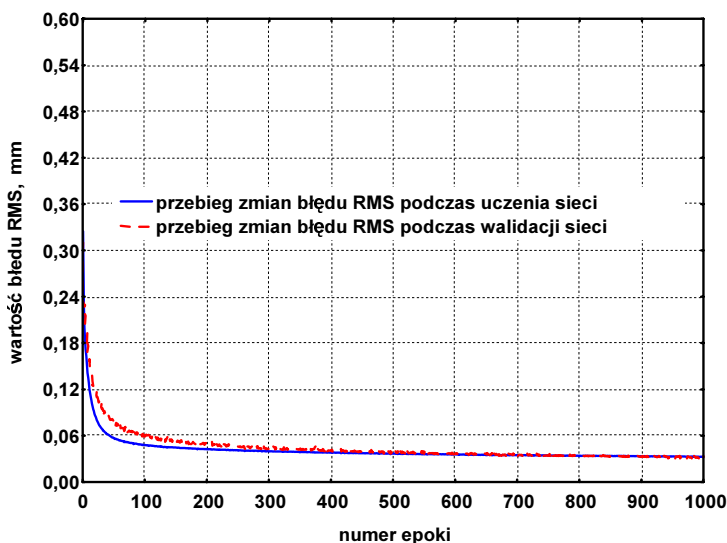
Tabela 1. Statystyki regresyjne ugięcia sprężystego przedmiotu y dla sieci MLP 3:3-7-1:1 uczonej algorytmem BP

Parametr	W zbiorze uczącym	W zbiorze walidacyjnym	W zbiorze testującym
Średnia	0,3737	0,3768	0,3549
Odchylenie standardowe	0,0335	0,0381	0,0288
Średni błąd	0,0017	0,0021	0,0019
Odchylenie błędu	0,0029	0,0036	0,0042
Średni błąd bezwzględny	0,0027	0,0032	0,0038
Iloraz odchyleń standardowych	0,0865	0,0944	0,1458
Korelacja	0,9962	0,9960	0,9901


średni błąd – jako moduł różnicy pomiędzy wartością zadaną i uzyskaną na wyjściu. Ponadto określono średni błąd bezwzględny jako różnicę pomiędzy wartością zadaną a wartością uzyskaną na wyjściu oraz odchylenie standardowe błędu. W oparciu o uzyskane wyniki obliczeń wyznaczono iloraz odchyłeń standardowych dla błędów i dla danych. Iloraz ten stanowi główny wskaźnik jakości zbudowanego modelu, wskazuje na stopień dokładności predykcji. Małe wartości ilorazu odchyłeń standardowych dla błędów i dla danych (dużo poniżej 1, np. 0,3; 0,2; 0,1 i mniej) świadczą o dobrej realizacji regresji przez sieć, czyli dobrym oszacowaniu wyjścia modelu za pomocą sieci.

Przyjęta w procesie modelowania struktura sieci (architektura, funkcja aktywacji neuronów ukrytych oraz algorytm uczenia) charakteryzuje się najniższą wartością błędu RMS (root square error). Na rysunku 7 zaprezentowano przebieg zmian wartości błędu RMS podczas uczenia i walidacji sieci MLP 3:3-7-1:1, w kolejnych epokach uczenia algorytmem wstecznej propagacji błędu. Wartość błędu RMS wraz z postępem uczenia maleje, a wyraźnie obserwowana zbieżność wartości błędów dla zbioru walidacji i uczenia świadczy o prawidłowym przebiegu procesu uczenia. Ostateczna weryfikacja modelu w oparciu o zbiór danych testujących wykazała niższe wartości błędu RMS niż dla zbiorów testującego i walidacji, co świadczy o wysokim stopniu zdolności sieci do poprawnej predykcji modelowanych związków.

Neurony wyjściowe modelu „prezentują” wyniki symulacji numerycznej (predykcji) wartości ugięcia sprężystego y , obarczone błędem odwzorowania. Na rysunku 8 przedstawiono powierzchnie odpowiedzi nauczonej sieci neuronowej MLP 3:3-7-1:1. Zaprezentowane charakterystyki przedstawiono w funkcji średnicy wałka d i odle-



Rys. 7. Przebieg zmian wartości błędu RMS podczas uczenia i walidacji sieci MLP 3:3-7-1:1 w kolejnych epokach uczenia algorytmem wstecznej propagacji błędu



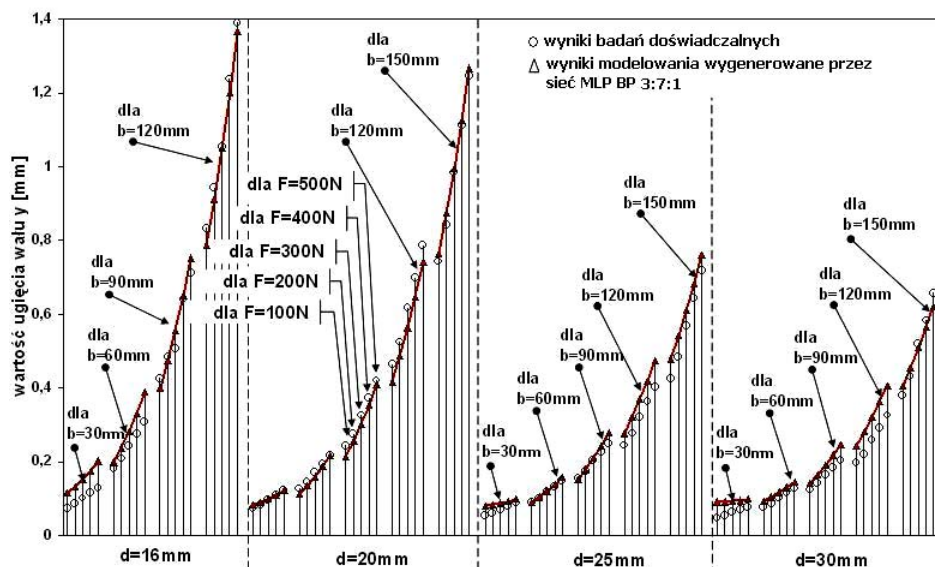
Rys. 8. Predykcja wartości ugięcia sprężystego y na podstawie modelu w postaci sieci neuronowej MLP 3:3-7-1:1, w funkcji: a) średnicy wałka d oraz odległości punktu przyłożenia siły F od uchwytu b , b) siły promieniowej F oraz odległości od uchwytu b , c) średnicy wałka d oraz siły promieniowej F .

głości punktu przyłożenia siły F od uchwytu b (rys. 8a), siły promieniowej F oraz odległości od uchwytu b (rys. 8b) jak również w funkcji średnicy wałka d i siły promieniowej F (rys. 8c).

Przedstawione na rys. 8 wyniki symulacji numerycznej potwierdzają nieliniowy charakter zmian odkształceń sprężystych przedmiotu zarówno w funkcji średnicy wałka d oraz odległości punktu przyłożenia siły F od uchwytu b jak również wartości składowej promieniowej F siły obciążającej. Można przypuszczać, że z uwagi na możliwość dowolnej liczby miar predykcji, wykorzystanie odpowiednio skonfigurowanej sieci neuronowej przyniesie lepsze wyniki niż model regresyjny wielu zmiennych.

Na rysunku 9 zaprezentowano wyniki ugięcia sprężystego wału y podpartego w uchwycie trójszczekowym, wygenerowane przez sieć MLP 3:3-7-1:1 na tle wyników badań eksperymentalnych.

Przedstawione wyniki wskazują na wysoki stopień korelacji z wynikami badań doświadczalnych. Zaprezentowane krzywe odpowiedzi sieci dotyczą wałków o średnicach 16, 20, 25 i 30 mm.



Rys. 9. Wyniki ugięcia sprężystego wału y podpartego w uchwycie trójszczekowym, wygenerowane przez sieć MLP 3:3-7-1:1 na tle wyników badań eksperymentalnych

Zestawienie wyników badań i odpowiedzi modelu numerycznego przedstawiono dla różnych wartości położenia punktu przyłożenia b składowej promieniowej siły skrawania, jak również zmiennej jej wartości F .

PODSUMOWANIE I WNIOSKI

Opracowany model predykcji ugięć sprężystych przedmiotu obrabianego pozwoli na wyprzedzające przewidywanie geometrii wyrobu już na etapie przygotowania produkcji. Zaprezentowane w pracy wyniki modelowania wykazują wysoką zgodność odpowiedzi modelu z otrzymanymi wynikami badań eksperymentalnych. Zastosowanie sztucznych sieci neuronowych wydaje się być dobrą alternatywą w stosunku do takich narzędzi numerycznych jak: MES, MEB, MRS.

W analizowanym modelu sztuczne sieci neuronowe z zadowalającą dokładnością spełniają postawione im zadanie predykcji uwzględniając realne wyniki badań eksperymentalnych uzyskanych podczas badań na obiekcie rzeczywistym. Sztuczne sieci neuronowe, jako narzędzie numeryczne, nie tylko ułatwiają proces modelowania, ale niejednokrotnie są jedynym sposobem zbudowania wiarygodnego, użytecznego i łatwego w stosowaniu modelu.

Poruszane w pracy problemy są niezwykle istotne w przypadku kształtowania części maszyn podatnych na działanie sił generowanych podczas skrawania (np. smukłe wałki, tuleje cylindrowe silników spalinowych, tuleje cienkościenne wykorzystywane w połączeniach pasowanych, itp.). Z uwagi na rangę analizowanych problemów a szczególnie ich znaczenie utylitarne uzasadnione jest dalsze rozszerzenie zbudowanego modelu o odkształcenia będące efektem generowania podczas skrawania ciepła. Zaprezentowane w pracy wyniki badań eksperymentalnych, jak również modelowania, dają optymistyczne przesłanki w odniesieniu do możliwości zbudowania użytecznego modelu mechanicznego procesu skrawania, a w przyszłości modelu termomechanicznego - pozwalającego na predykcję sprężystych i cieplnych odkształceń przedmiotu obrabianego. Wykorzystanie takiego modelu w strukturze sterowania z modelem, umożliwi wpływanie na trajektorię ostrza narzędzia i minimalizację błędów obróbkowych.

PIŚMIENNICTWO

1. Asao T., Mizugaki Y., Sakamoto M. Precision turning by means of a simplified predictive function of machining error. *Annals of the CIRP*. 41(1), 1992: 447–450.
2. Azouzi R., Guillot M. On-line optimization of the turning process using an inverse process neurocontroller. *Transaction of the ASME Journal of Manufacturing Science and Engineering*. 120, 1998: 101–108.
3. Józwiak J., Lipski J. Application of neural network to modeling of workpiece deformations during turning process. *Maintenance and Reliability*, nr 4, 2002.
4. Kops L., Gould M., Mizrach M. A search for equilibrium between workpiece deflection and depth of cut: key to predictive compensation for deflection in turning. *2 Manuf. Sci. Eng., ASME PED*, 68 (2) 1994: 819-825.
5. Li X., Venuvinod P.K., Djorjevich A., Liu Z. Predicting Machining Errors in Turning Using Hybrid Learning. *Int. J. Adv. Manuf. Technol.* 18, 2001: 863–872.
6. Li X., Venuvinod P.K., Chen M.K. Feed Cutting Force Estimation from the Current Measurement with Hybrid Learning. *Int. J. Adv. Manuf. Technol.* 16, 2000: 859–862.
7. Li X. Real -Time Prediction of Workpiece Errors for a CNC Turning Centre, Part 4. Cutting-Force-Induced Errors. *Int. J. Adv. Manuf. Technol.* 17 (2001), 665–669.
8. Osowski S. *Sieci neuronowe w ujęciu algorytmicznym*. WNT, Warszawa 1996.
9. Liu Z.Q. Finite difference calculations of the deformations of multi-diameter workpieces during turning. *Journal of Materials Processing Technology*, 98, 2000: 310–316.
10. Luttervelt C.A., Childs T.H.C., Klocke F., Venuvinod P.K. Present situation and future trends in modelling of machining operations. Progress Report of the CIRP working group „Modelling of Machining Operations”. *Annals of the CIRP*, 47 (2), 1998: 587–626.

11. Ehmann K.F., Kapoor S.G., DeVor R.E., Lazoglu I. Machining Process Modeling: A Review. *Transaction of the ASME Journal of Manufacturing Science and Engineering*, 119, 1997: 655–664.
12. Mayer J.R.R., Phan A.V., Cloutier G. Prediction of diameter errors in bar turning: a computationally effective model. *Applied Mathematical Modeling*, 24, 2000: 943–956.
13. Phan A.V., Cloutier G., Mayer J.R.R. A finite element model for predicting tapered workpiece deflections in turning. *Computer Modeling and Simulation in Engineering*, 4, 1999: 138–142.
14. Orr Mark J.L. Recent advances in radial basis function networks. Technical report, Institute for Adaptive and Neural computation, Edinburgh University, 1999.
15. Liao T. Warren, Chen L.J. Manufacturing process modeling and optimization based on multi-layer perceptron network. *Transaction of the ASME Journal of Manufacturing Science and Engineering*, 120, 1998: 109–119.
16. Lipski J., Szabelski K., Warmański J., Litak G., Zaleski K. Identification of cutting process using neural network. Technical University of Budapest, International Workshop: Non-linear Dynamics and Control in COST Action P4, 1999.
17. Moriwaki T., Zhao C. Neural network approach to identify thermal deformation of machining center. *Proceedings of 8th International IFIP WG5.3 Conference, PROLAMAT'92*, Tokyo, Japan, 1992: 685–697.

THE USE OF THE ARTIFICIAL NEURAL NETWORK TO FLEXIBLE DEFLECTION WORKPIECE MODELLING IN TURNING

Summary

In this paper the example of possible use of the artificial neural network ANN application for prediction of flexible deflection workpiece during turning process is presented. Some results of modeling and experimental verification are introduced. The results relate to a chosen way of workpiece clamp on the lathe namely in three-jaw chuck. In numerical analyses complete results of flexible deflection for different diameters of workpiece (16, 20, 25, 30 and 35 mm) are discussed. The author of the paper analyzed the typical example of clamp of workpiece on the lathe.

Keywords: cutting process, workpiece deflection, modeling, artificial neural network.