

SYSTEM WSPOMAGANIA DOBORU PARAMETRÓW TECHNOLOGICZNYCH Z ZASTOSOWANIEM MODELOWANIA SIECIAMI NEURONOWYMI

Jerzy LIPSKI, Kazimierz ZALESKI, Agnieszka SKOCZYLAS

Streszczenie: Artykuł zawiera opis budowy i przykłady wykorzystania systemu informatycznego wspomagającego proces doboru parametrów sterujących procesami technologicznymi. Na podstawie założonych przez konstruktora oczekiwanych efektów po obróbce, oraz wieloparametrycznego modelu procesu zapisanego w strukturze sieci neuronowej, system wyznacza parametry obróbki. Parametry te są wystarczające do osiągnięcia narzuconych w konstrukcji cech wyrobu i jednocześnie zapewniają maksymalnie możliwą efektywność dla zidentyfikowanych warunków realizacji procesu. Zaprezentowano przykład zastosowania opracowanego narzędzia wspomagającego projektowanie procesów technologicznych.

Słowa kluczowe: parametry procesu wytwarzania, sieci neuronowe, modelowanie procesów wytwarzania, MatLab, systemy mobilne.

1. Wprowadzenie

Istotną fazą projektowania procesu technologicznego jest dobór parametrów, które mają zapewnić osiągnięcie cech wyrobu określonych w dokumentacji technologicznej. Spotykane w praktyce przemysłowej procesy technologiczne charakteryzują się znaczną liczbą czynników wpływających na przebieg procesu a w rezultacie na parametry wyjściowe. Również związki funkcyjne między parametrami wejściowymi procesów a istotnymi cechami wyrobów są często nieliniowe. Nawet, jeśli w wyników badań doświadczalnych, lub modelowania opartego na znanych prawach fizycznych, znane są funkcje opisujące te zależności to aplikacyjność takich modeli jest ograniczona do ściśle określonych warunków realizacji modelowanego procesu [4]. Budowa modeli wymaga czasochłonnych i kosztochłonnych badań, tym wyższych im więcej jest czynników wejściowych wpływających na proces.

Znajomość wieloparametrycznego modelu procesu technologicznego nie rozwiązuje jednak do końca problemu doboru parametrów sterujących procesem. Przy założeniu, że projektowany proces będzie realizowany w warunkach adekwatnych do warunków w jakich był opracowany model, trzeba z przestrzeni wielowymiarowej parametrów sterowalnych wybrać taki podzbiór, który zapewni osiągnięcie cech wyrobu zapisanych w dokumentacji konstrukcyjnej. Dodatkowo, nie może to być pierwszy podzbiór spełniający ten warunek lecz taki dla którego proces będzie maksymalnie efektywny.

Bez uwzględnienia tego warunku, w wyniku analizy modeli, będzie można znaleźć znaczną liczbę zbiorów parametrów wejściowych zapewniających osiągnięcie cech wyrobu na poziomie równym lub lepszym od podanych w dokumentacji konstrukcyjnej. Modele mające ekstrema globalne mogą, w ten sam sposób, generować jedno rozwiązanie. Jednakże zarówno w pierwszym jak i drugim przypadku nie musi być ono optymalne ze

względu na kryterium wydajności lub kosztów. Oznacza to, że technolog powinien znaleźć, mając wiarygodny model wejściowo-wyjściowy procesu, taki zbiór parametrów wejściowych, który zapewni osiągnięcie w wystarczającym stopniu cech konstrukcyjnych wyrobu i jednocześnie spełni kryterium maksymalnej wydajności lub minimalnych kosztów.

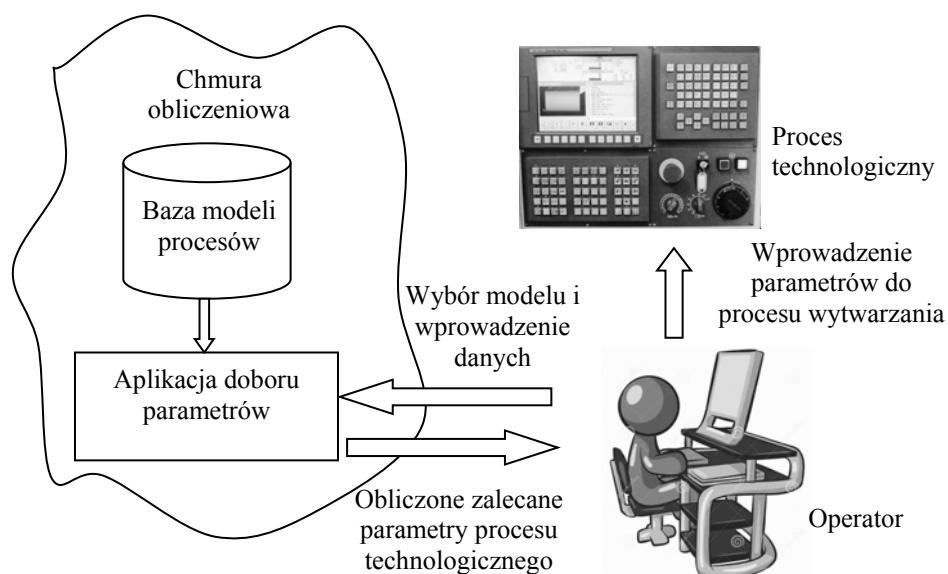
2. System doboru parametrów procesów technologicznych

Uwzględniając problemy związane z racjonalnym doбором parametrów technologicznych opracowano system informatyczny spełniający warunki podane powyżej. W tym celu należało:

- opracować strukturę funkcjonalną systemu;
- dokonać wyboru narzędzi informatycznych do zastosowania w systemie;
- opracować algorytmy aplikacji;
- opracować sposoby komunikowania z użytkownikiem;
- przeprowadzić testy dla wytypowanych procesów technologicznych.

2.1. Struktura funkcjonalna systemu informatycznego doboru parametrów procesu technologicznego

Struktura systemu została przedstawiona na rys. 1.



Rys. 1. Struktura systemu doboru parametrów procesów wytwarzania

Zarówno baza dysponowanych modeli procesów jak i aplikacja wyliczająca zalecane parametry, spełniające kryteria narzucone przez operatora, zostały zlokalizowane w Chmurze obliczeniowej. Wybrano w tym celu Matlab Cloud Computing, gdyż skorzystano z wygodnych i zoptymalizowanych narzędzi programistycznych tego systemu.

Rozwiązanie takie pozwoliło na korzystanie dodatkowo z zawartości bazy oraz programu w dowolnym miejscu za pośrednictwem aplikacji na smartfonie. Rola operatora sprowadza się do wybrania modelu procesu technologicznego. Model ten musi odpowiadać warunkom realizacji procesu dla jakich był opracowany. System wykorzystuje model reprezentowany przez zmienną strukturalną utworzoną w wyniku uczenia sieci neuronowej. Biorąc pod uwagę, że zmiany niektórych parametrów wejściowych mogą mieć wpływ na wydajność procesu, do algorytmu zostały wprowadzone warunki ekonomiczne redukujące podzbiór parametrów dopuszczalnych (ze względu na cechy konstrukcyjne wyrobu) do jednego zestawu. Zestaw ten spełnia zarówno kryterium konstrukcyjne jak i ekonomiczne.

2.2. Wybór narzędzi informatycznych do zastosowania w systemie

System doboru parametrów zrealizowano kompleksowo w środowisku obliczeniowym MatLab R2016b [6, 7, 8]. Zasadniczym modułem systemu jest wirtualny model procesu zawarty w nauczonej sieci neuronowej. W celu budowy takiego modelu koniecznym jest przeprowadzenie eksperymentów polegających na wykonaniu prób technologicznych dla wybranych kombinacji parametrów wejściowych i zarejestrowaniu parametrów wyjściowych. Pracochłonność tego etapu zależy od liczby parametrów wpływających w istotny sposób na rezultaty procesu a także od wielkości przestrzeni zmienności tych parametrów. Jest także istotna liczba R elementów ciągów uczących rozmieszczonych w $Q1$ wymiarowej przestrzeni wejść. Zbiór danych uczących jest dzielony na trzy podzbiory: uczący, testujący i walidacyjny. Proces uczenia sieci neuronowej w środowisku MatLab'a rozpoczyna się od wywołania funkcji budującej strukturę sieci w oparciu o rozmiary danych wejściowych i wyjściowych projektowanego modelu:

$$\text{net} = \text{newff}(\text{P}, \text{T}, \text{S}) \quad (1)$$

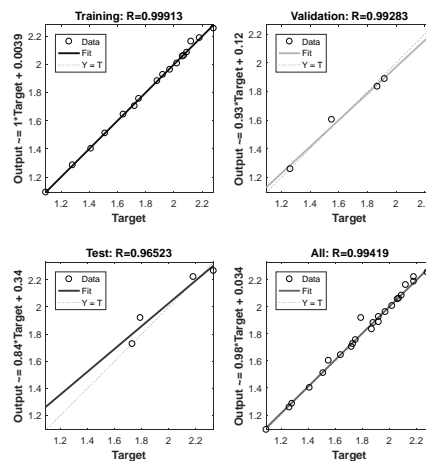
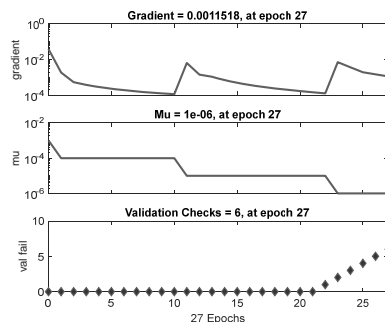
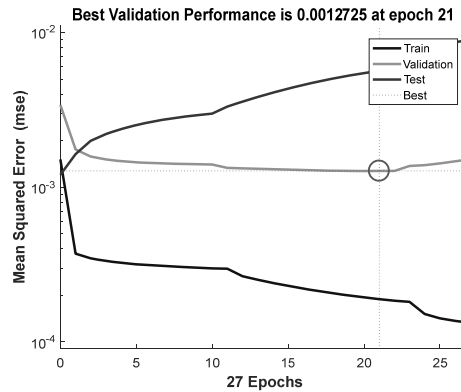
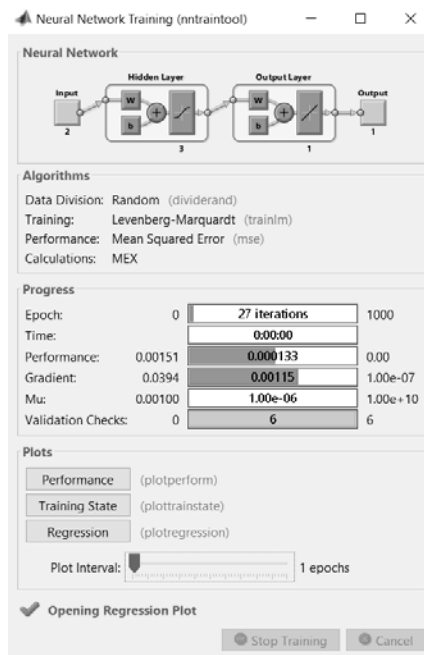
gdzie: P- macierz $Q1$ wektorów ciągów uczących o R elementach każdy;
T- macierz $Q2$ wektorów wartości wyjść;
S- proponowana liczba neuronów w warstwie ukrytej.

Struktura tak definiowanej sieci może być modyfikowana za pomocą opcjonalnych parametrów zgodnie z opisem w instrukcji biblioteki funkcji Toolbox Neural Networks.

Następny etap to uczenie zdefiniowanej struktury sieci przez wywołanie funkcji train:

$$\text{net} = \text{train}(\text{net}, \text{P}, \text{T}) \quad (2)$$

Na tym etapie, następuje ustalenie wartości wag w poszczególnych neuronach i ocena jakości dopasowania modelu do danych uczących oraz danych, które nie były przedmiotem uczenia ale pochodzą z tego samego eksperymentu. W ocenie dopasowania modelu pomaga kilka wygenerowanych parametrów i wykresów, których przykład [7] pokazano na rys.2. Proces uczenia jest interaktywny i może być wielokrotnie powtarzany dla różnej liczby neuronów w warstwie ukrytej. Najlepszy model to taki, który odwzorowuje z najmniejszym błędem wartości wyjściowe dla parametrów wejściowych, które nie były przedmiotem uczenia ale należą do przestrzeni uczącej.



Rys. 2. Przykładowe informacje o jakości dopasowania modelu generowane podczas uczenia sieci neuronowej [7]

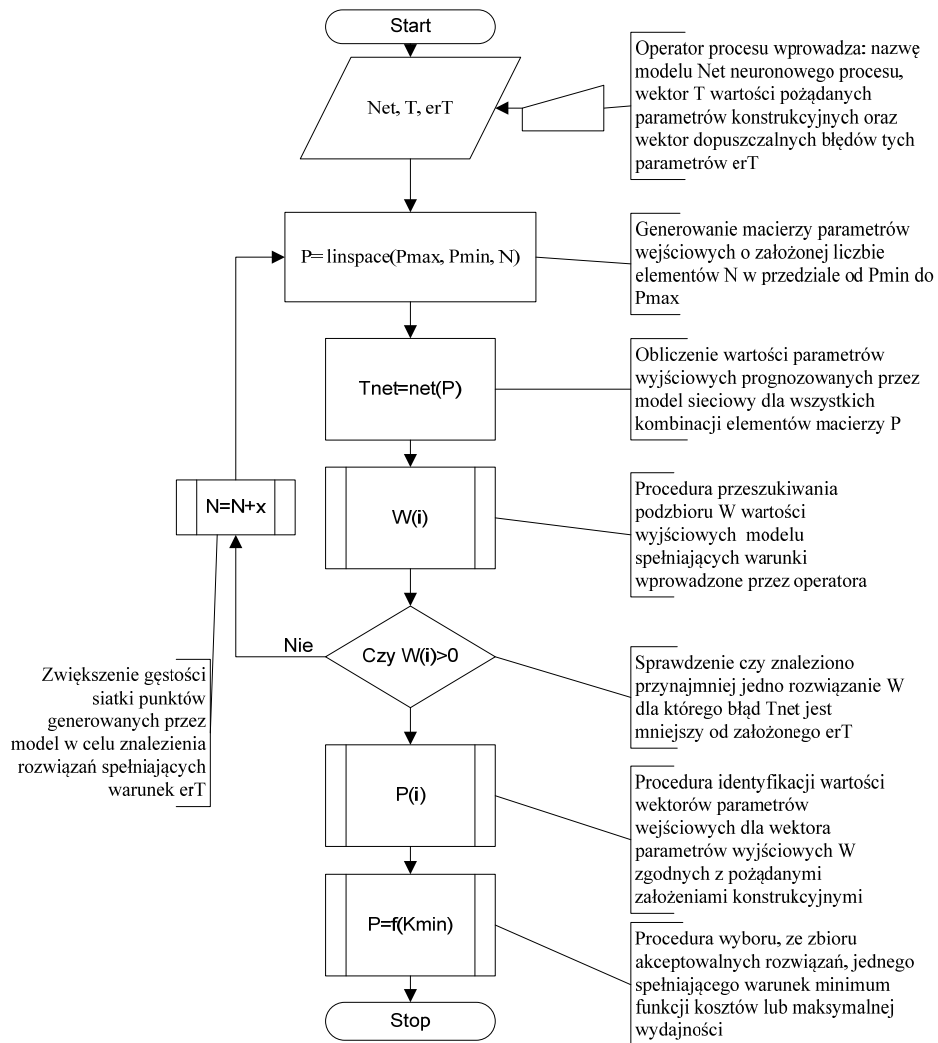
Informacje o właściwościach konkretnego modelu są zapisane w zmiennej strukturalnej *net* i mogą być wykorzystane do obliczenia wartości niejawnej funkcji reprezentującej właściwości modelowanego procesu:

$$T_{\text{net}} = \text{net}(\text{inputs}) \quad (3)$$

gdzie:

inputs - macierz $n \times N$ – wymiarowa danych wejściowych ; *n*- liczba wierszy reprezentujących zmienne wejściowe; *N*- liczba wartości danych wejściowych;
 T_{net} - wektor wartości funkcji dla zadanych argumentów wyznaczony w sieci;

Z punktu widzenia operatora procesu, bardziej praktyczną postacią modelu byłaby możliwość wyznaczenia zbioru argumentów wejściowych pozwalających na osiągnięcie założonego wektora wartości funkcji reprezentującej model [1]. Wektor ten reprezentuje wartości cech wyrobu zawartych w dokumentacji konstrukcyjnej.



Rys.3. Ogólny algorytm poszukiwania parametrów procesu wytwarzania dla pożądanego wektora parametrów wyrobu i z uwzględnieniem maksymalnej wydajności procesu lub minimalnych kosztów

Problem ten można rozwiązać, przy założeniu pewnej niepewności spowodowanej ograniczoną dokładnością modelu neuronowego jednak jest to w większości przypadków akceptowalne. W tym celu wygenerowano n wymiarową przestrzeń parametrów wejściowych modelu i obliczono przewidywane przez sieć wartości wyjściowe dla

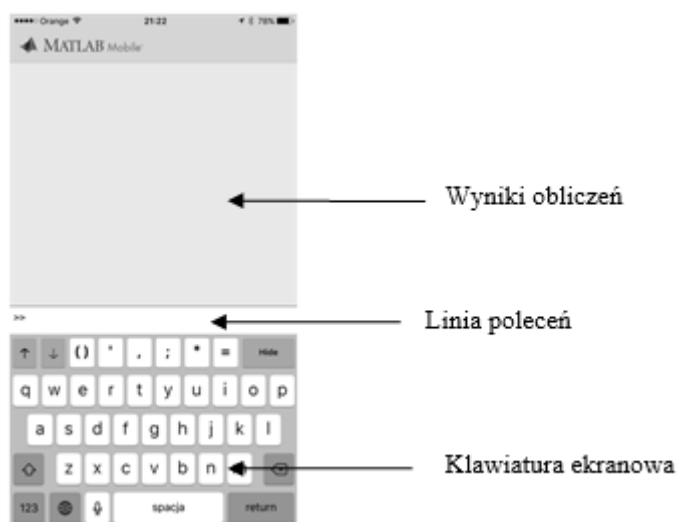
możliwych kombinacji. Powstała n wymiarowa macierz wartości funkcji w której każdy element jest adresowany przez wektor reprezentujący parametry wejściowe konieczne do otrzymania wartości tego elementu. Przeszukując tak utworzoną macierz algorytm wyznacza zbiór wektorów wyjść najlepiej dopasowanych do założeń konstrukcyjnych. Jeżeli podzbiór ten nie jest jednoelementowy zostają wprowadzone dodatkowe kryteria przeszukiwania uwzględniające warunki nakładane na parametry wejściowe z punktu widzenia wydajności procesu. W wyniku otrzymuje się zbiór parametrów procesu wytwarzania spełniający zarówno kryteria konstrukcyjne wyrobu jak i wydajnościowe. Algorytm aplikacji przedstawiono na rys. 3.

Pewnym problemem jest fakt, że liczba elementów macierzy wartości funkcji bardzo szybko rośnie wraz z ilością parametrów wejściowych i liczbą punktów na jaki zostanie podzielona przestrzeń tych parametrów. Przykładowo dla 3 parametrów wejściowych, z których każdy jest reprezentowany przez 20 punktów liczba elementów macierzy wyników osiągnie 8000. Przeszukanie takiego zbioru może potrwać kilka minut na komputerze PC.

Jednakże, dzięki zoptymalizowanym algorytmom MatLab'a [2, 9], oraz umieszczeniu aplikacji w Chmurze obliczeniowej przeszukanie nawet większych macierzy zajmuje kilkadziesiąt sekund.

2.3. Sposób komunikowania się systemu z użytkownikiem

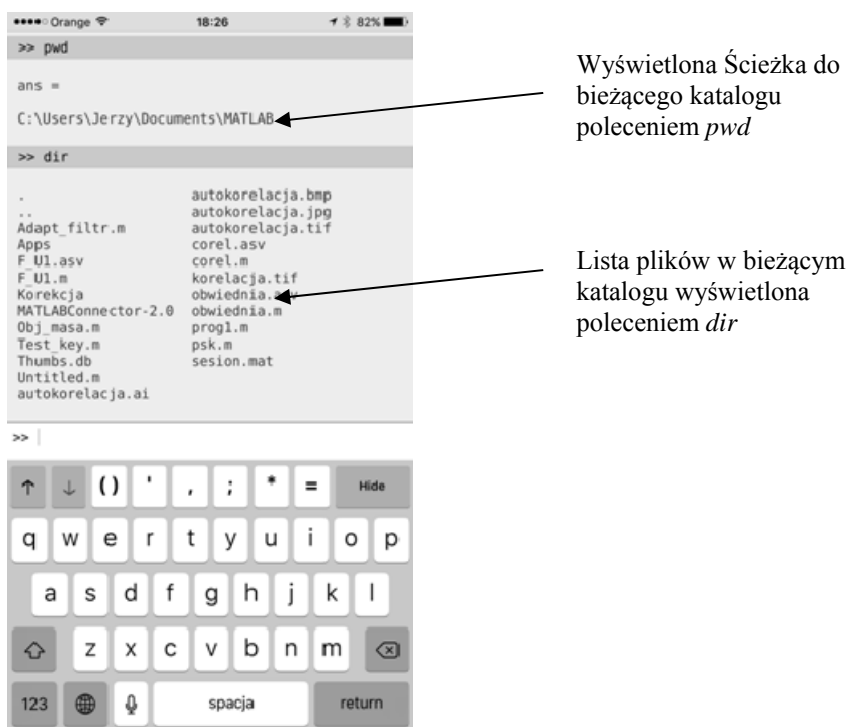
Wraz z pojawieniem się opcji uruchamiania opracowanego oprogramowania na wydajnych komputerach klastrowych umieszczonych w Chmurze Obliczeniowej, MATLAB zyskał nowe możliwości. Teraz można umieszczać w Chmurze Obliczeniowej MatWorks'a skrypty i dane do obliczeń oraz zdalnie, przy pomocy urządzeń mobilnych, uruchamiać programy i otrzymywać wyniki [8]. Technologię tę można stosować także do prywatnej Chmury Obliczeniowej wyposażonej w wydajny komputer. Pozwala na to aplikacja MATLAB Mobile dostępna zarówno na systemy operacyjne Android jak i iOS Apple.



Rys.4. Interfejs użytkownika MATLAB Mobile na smartfonie iPhone

Interfejs użytkownika MATLAB Mobile (rys.5) jest bardzo uproszczony, umożliwia jednak odszukanie potrzebnego pliku programu na serwerze w Chmurze Obliczeniowej i uruchomienie go z zadanymi parametrami oraz wyświetlenie wyników obliczeń. Jeżeli urządzenie mobilne ma połączenie przez sieć komputerową z MATLAB'em uruchomionym w Chmurze Obliczeniowej użytkownik systemu mobilnego ma dostęp, przez linię poleceń interfejsu, do wszystkich plików z danymi i może uruchamiać każdy plik z programem, który znajduje się na ścieżce dostępu MATLAB'a w Chmurze Obliczeniowej. Może także zlecać operacje na plikach (rys.5) wykonując standardowe polecenia MATLAB'a takie jak:

- cd (zmień katalog) i pwd (wyświetl bieżący katalog);
- zapisywać dane do pliku i uzyskiwać do nich dostęp poleceniami save i load;
- przeglądać zawartość plików tekstowych zawierających programy MATLAB'a poleceniem type.



Rys. 5. Przykładowe operacje na plikach umieszczonych na dysku serwera w Chmurze Obliczeniowej wykonywane z poziomu interfejsu użytkownika MATLAB Mobile

Możliwość wykorzystania interfejsu użytkownika z poziomu aplikacji mobilnej [6] dla pracy z systemem doboru parametrów wytwarzania przetestowano, równolegle z wykorzystaniem stacjonarnej instalacji Matlab'a na komputerze klasy PC. W jednym i drugim przypadku umieszczono w zdefiniowanym katalogu zarówno modele neuronowe procesów, nauczone na danych z eksperymentów, oraz program realizujący zadania opisane w algorytmie pokazanym na rys.3. Program ma formę funkcji zgodnej z syntaktyką Matlab'a. Takie rozwiązanie pozwoliło na wywołanie aplikacji z linii poleceń na smartfonie

wraz z przekazaniem do programu, przez użytkownika, wszystkich potrzebnych danych jako argumentów tej funkcji. Wyniki, czyli parametry wejściowe do projektowanego procesu są elementami zdefiniowanej macierzy.


2.4. Przykład wykorzystania opracowanego systemu do doboru parametrów procesu nagniatania tocznego

Proces nagniatania ma na celu obniżenie chropowatości obrobionej wstępnie powierzchni przy jednoczesnym jej umocnieniu [6]. Dane do budowy modelu neuronowego pozyskano w wyniku eksperymentów prowadzonych bezpośrednio na stanowisku roboczym.

W badaniach wykorzystano próbki ze stali niestopowej C45 (oznaczenie według PN – EN 10083 – 1:2008). Stal tego gatunku znajduje szerokie zastosowanie w przemyśle maszynowym na średnio obciążone elementy maszyn i urządzeń, jak: osie, wały, wrzeciona, tarcze, piasty do kół, dźwignie oraz niehartowane koła zębate. Próbki w kształcie prostokątów o wymiarach 4 x 8 x 100 mm zostały wykonane przy użyciu wycinarki laserowej LASER Amada 3000 W, stosując parametry standardowe cięcia: prędkość cięcia $v = 1150$ mm/min, moc $P = 2,15$ kW, częstotliwość $f_{Hz} = 1280$ Hz, ciśnienie gazu 0,06 MPa, położenie ogniskowej +13 mm oraz tlen jako gaz roboczy.

Nagniatanie toczne zostało przeprowadzone na tokarce uniwersalnej C11/MB. Na rys. 6 przedstawiono uproszczony schemat stanowiska oraz kinematykę nagniatania. Jako narzędzie wykorzystano nagniatąk, składający się z zespołu wywierającego siłę docisku oraz elementu nagniatającego, którym była kulka wykonana z azotku krzemu (Si_3N_4) o średnicy $d_N = 8$ mm. Do przeprowadzenia obróbki nagniataniem próbek płaskich wykorzystano specjalny uchwyt w kształcie tarczy (1) z czterema rowkami na próbki (3), który wykonywał ruch obrotowy. Nagniatąk (2), zamocowany w imaku, wykonywał ruch posuwowy f , będąc równocześnie dociskany ze stałą siłą F do przedmiotu obrabianego. Proces nagniatania tocznego został zrealizowany przy zmiennych parametrach :

- $F = 300N \div 930N$,
- $f = 0,05$ mm/obr. $\div 0,4$ mm/obr.



Rys. 6. Schemat procesu nagniatania tocznego: 1 – uchwyt, 2 – nagniatąk, 3 – próbka


Pomiary chropowatości powierzchni wykonano za pomocą profilografometru laboratoryjnego Surtronic 3+ firmy Taylor Hobson.

W wyniku eksperymentu otrzymano dwa 25 elementowe wektory danych wejściowych posuwu f i siły docisku F oraz odpowiadające im wartości uzyskanej chropowatości powierzchni R_a (Tab.1). Wykorzystując funkcję (1) i (2) z biblioteki Matlaba zbudowano model, którego postać graficzną przedstawia rys. 7.

W tabeli 1 pokazano również wartości R_a prognozowane przez nauczonego model neuronowy.

Tab. 1. Dane do uczenia sieci i wyniki testu odwzorowania przez sieć neuronową

Dane do uczenia sieci				Wartość z testowanego modelu	Błąd bezwzględny
Lp.	f [mm/obr]	F [N]	R_a [μm]	R_a [μm]	
1	0,05	300	1,87	1,92	0,05
2	0,11	300	1,97	2,00	0,03
3	0,17	300	2,07	2,04	-0,03
4	0,28	300	2,18	2,11	-0,07
5	0,4	300	2,33	2,30	-0,03
6	0,05	400	1,73	1,79	0,06
7	0,11	400	1,88	1,90	0,02
8	0,17	400	2,02	1,99	-0,03
9	0,28	400	2,12	2,11	-0,01
10	0,4	400	2,28	2,29	0,01
11	0,05	510	1,55	1,64	0,09
12	0,11	510	1,75	1,78	0,03
13	0,17	510	1,92	1,92	0,00
14	0,28	510	2,09	2,13	0,04
15	0,4	510	2,18	2,19	0,01
16	0,05	720	1,28	1,41	0,13
17	0,11	720	1,51	1,57	0,06
18	0,17	720	1,72	1,74	0,02
19	0,28	720	1,92	1,94	0,02
20	0,4	720	2,06	1,96	-0,10
21	0,05	930	1,09	1,17	0,08
22	0,11	930	1,26	1,33	0,07
23	0,17	930	1,41	1,47	0,06
24	0,28	930	1,64	1,64	0,00
25	0,4	930	1,79	1,70	-0,09



Rys. 7. Graficzna postać dwuparametrycznego modelu procesu nagniatania wygenerowana w wyniku nauczania sieci neuronowej na danych z eksperymentów

Na ilustracji graficznej modelu widoczna jest powierzchnia reprezentująca osiągnięty poziom chropowatości Ra w funkcji możliwych kombinacji posuwu i docisku nagniataka. Analizując graficzną postać funkcji opisującej zależność chropowatości powierzchni poddanej procesowi nagniatania, można zauważyć, że jest ona nieliniowa. Ponadto, minimalna wartość chropowatości jest osiągalna dla skrajnie małego posuwu i maksymalnego docisku oznacza to niską wydajność stanowiska roboczego. Jednakże części obrabiane tą technologią mogły mieć, zgodnie z dokumentacją konstrukcyjną chropowatość Ra nie większą niż $2\mu\text{m}$.

Po wprowadzeniu do wybranego katalogu w Chmurze obliczeniowej modelu procesu o nazwie `net_ng`, operator uruchomił wykonanie funkcji `Par_nag` poszukiwania parametrów nagniatania dla zadanej wartości chropowatości powierzchni $Ra_{\text{zad}}=2\mu\text{m}$:

$$W = \text{Par_nag}(\text{net_ng}, f_{\text{min}}, f_{\text{max}}, F_{\text{min}}, F_{\text{max}}, n, Ra_{\text{zad}}, \text{erT}) \quad (4)$$

gdzie:

$f_{\text{min}}, f_{\text{max}}=[0,05, 0,4]$ – minimalna i maksymalna wartość posuwu definiująca przestrzeń poszukiwań;

$F_{\min}, F_{\max} = [300, 930]$ - minimalna i maksymalna wartość docisku definiująca przestrzeń poszukiwań;

$n = 25$ - początkowa liczebność danych wejściowych generujących siatkę modelu;

$erT = 0,1$ - dopuszczalna różnica między wartością chropowatości Ra_{zad} a wartością wygenerowaną przez aplikację;

W - jest wektorem zawierającym wartość posuwu, nacisku oraz błędu dla wygenerowanego rozwiązania.

W wyniku obliczeń funkcja wygenerowała wartości wektora W :

- zalecany posuw nie większy niż $W(1) = f = 0,385 \text{ mm/obr.}$;

- zalecany docisk nagniatka nie mniejszy niż $W(2) = F = 667,5 \text{ N}$;

- możliwy teoretyczny błąd osiągniętej chropowatości $W(3) = er = 0,002 \mu\text{m}$;

Wynik ten poddano walidacji generując wartość Ra wprost z modelu neuronowego:

$$Ra = \text{net_ng}([W(1); W(2)]) \quad (5)$$

Wynik obliczeń dla opisanego przykładu: $Ra = 1.9978 \mu\text{m}$

3. Wnioski

Zaproponowana koncepcja doboru parametrów wielowejsciowego procesu wytwarzania opiera się na założeniu, że znany jest model funkcyjny definiujący wpływ poszczególnych parametrów sterujących na efekt końcowy realizacji procesu technologicznego. Jak wynika z naszych doświadczeń oraz doniesień literaturowych [5], zastosowanie sieci neuronowych jako nośnika informacji o zachowaniu się obiektu sterowanego może być efektywnie wykorzystane. Warunkiem jest zapewnienie wiarygodnych o odpowiedniej długości ciągów uczących, pozwalających na przetestowanie i walidację otrzymanego modelu.

Rozwiązanie zagadnienia odwrotnego od klasycznego sposobu wykorzystania istniejącego modelu pozwala na uproszczenie procesu podejmowania decyzji dotyczących doboru właściwego zbioru parametrów wejściowych dla pożądanego rezultatu procesu.

Usytuowanie systemu obliczeniowego w Chmurze obliczeniowej pozwala na dostęp mobilny do aplikacji oraz zapewnia wystarczającą moc obliczeniową w przypadkach znacznej liczby parametrów sterujących procesem.

Literatura

1. Nurmi, D., Wolski, R., Grzegorzczak, C., Obertelli, G., Soman, S., Youseff, L.,: A Technical Report on an Elastic Utility Computing Architecture Linking Your Programs to Useful Systems . Tech. Rep. 2008-10, University of California, Santa Barbara, October 2008.
2. Ostanin A.: Metody optymalizacji z Matlab. Wyd. NAKOM Poznań 2014.
3. Pratap R.: MATLAB 7 dla naukowców i inżynierów, PWN Warszawa 2012.
4. Ramirez W.F., Computational Methods for Process Simulation, 2nd ed., Butterworth-Heinemann, 2007;
5. Tadeusiewicz R.: Sieci neuronowe. Akademicka Oficyna Wydawnicza, Warszawa 1993;
6. Zaleski K.: Wpływ parametrów fizycznego modelowania procesu nagniatania dynamicznego rozproszonego na chropowatość powierzchni obrobionej,

- W: Współczesne problemy w technologii obróbki przez nagniatanie, T. 2, Włodzimierz Przybylski [Red.], Gdańsk, Politechnika Gdańska, 2008, s. 9-16.
7. http://www.mathworks.com/products/matlab-mobile/?s_tid=srchtitle
 8. <http://www.mathworks.com/products/neural-network/>
 9. <https://www.mathworks.com/products/parallel-computing.html>.

Prof. dr hab. inż. Jerzy LIPSKI
Katedra Organizacji Przedsiębiorstwa
Politechnika Lubelska
ul. Nadbystrzycka 38
20-618 Lublin
Tel. (+48 81) 538 44 80,
e-mail: j.lipski@pollub.pl

Dr hab. inż. Kazimierz ZALESKI, prof. P.L.
Dr inż. Agnieszka SKOCZYŁAS
Katedra Podstaw Inżynierii Produkcji
Politechnika Lubelska
ul. Nadbystrzycka 36
20-618 Lublin
Tel. (+4881) 538 42 38,
e-mail: k.zaleski@pollub.pl
a.skoczylas@pollub.pl