

Magdalena TRZOS

Instytut Technologii Eksploatacji – PIB, Radom

MODELOWANIE WPLYWU PARAMETRÓW PROCESU OSADZANIA POWŁOK NA WŁAŚCIWOŚCI WARSTW

Słowa kluczowe

Modelowanie, modele charakterystyk, sztuczne sieci neuronowe, właściwości powłok.

Streszczenie

W artykule przedstawiono problemy modelowania wybranych właściwości warstw, otrzymywanych w procesach osadzania powłok metodami PAPVD. Analizie zostały poddane powłoki nanoszone z wykorzystaniem dwóch różnych komercyjnych urządzeń. Technika modelowania została zastosowana w celu opracowania modeli, pozwalających na prognozowanie właściwości warstw na podstawie parametrów procesu osadzania. W procesie modelowania, z zastosowaniem metody sztucznych sieci neuronowych, zostały wykorzystane zbiory danych z eksperymentów badawczych i procesów technologicznych. Przeprowadzone badania pozwoliły na opracowanie modeli tylko dla niektórych z analizowanych charakterystyk, głównie ze względu na występujące niedostatków w zbiorach danych. Wpłynęło to zasadniczo na organicznie możliwości opracowania modeli. Należy jednak podkreślić, że uzyskane w trakcie badań wyniki uzasadniają zastosowanie sieci neuronowych do opisu badanych procesów i budowy modeli prognostycznych.

Wprowadzenie

W rezultacie prowadzonych od wielu lat w Instytucie Technologii Eksploatacji badań w obszarze technologii nanoszenia powłok generowane są obszernie zbiory wyników doświadczalnych, opisujących procesy oraz charakterystyki efektów ich realizacji, do których należą np. właściwości uzyskiwanych warstw [1–4]. Wnioski wynikające z analizy wyników w znacznej mierze wpływają na wzrost doświadczenia i pogłębianie wiedzy badaczy. Wiedza ta jest wykorzystywana w procesach opracowywania nowych technologii, uzyskiwania nowych rozwiązań oraz projektowania właściwości nowych warstw. Wykorzystanie możliwości informacyjnych zawartych w danych uzyskanych w wyniku przeprowadzonych licznych eksperymentów badawczych wydaje się być jednak zbyt małe zarówno w procesach wspomagających opracowania nowych technologii, jak również w doborze parametrów procesu, w celu uzyskania żądanych charakterystyk produktu. Istotny problem stanowi więc poszukiwanie metod wspomagających wykorzystanie danych z eksperymentów badawczych i praktyki wynikającej z realizacji procesów technologicznych w rozwoju technologii warstwy wierzchniej.

Znaczącą rolę w rozwiązywaniu zadań prognostycznych odgrywają techniki modelowania. Ich zastosowanie do budowy modeli prognozujących wybrane charakterystyki warstw, w zależności od parametrów procesu, powinny z jednej strony dostarczyć narzędzia prognostycznego, z drugiej dać możliwość uporządkowania informacji zawartej w zgromadzonych danych. W analizowanym przypadku ze względu na złożoność zagadnienia, występujące braki danych oraz systematyczne zwiększanie zawartości bazy danych (poprzez uzupełnianie jej o wyniki rezultatów kolejnych przeprowadzonych procesów nanoszenia warstw), a w związku z tym zapewnienie możliwości uwzględniania nowych danych w obliczeniach, zaproponowano metodę sztucznych sieci neuronowych do opracowania modeli prognozowania właściwości nanoszonych powłok. Metoda sztucznych sieci neuronowych z powodzeniem wykorzystywana jest w licznych praktycznych aplikacjach [5–9].

Celem przeprowadzonych badań było zastosowanie metody sztucznych sieci neuronowych do opracowania modeli, opisujących relacje pomiędzy parametrami procesu a wybranymi charakterystykami warstw.

1. Charakterystyka obiektu modelowania

Badania modelowe przeprowadzono na podstawie wyników badań powłok azotku chromu osadzanych metodami PAPVD [3]. Powłoki tego typu charakteryzują się drobnoziarnistą strukturą oraz niskim poziomem naprężeń, dzięki czemu możliwe jest uzyskiwanie grubych powłok nawet do 50 μm . W warunkach tarcia suchego, jak również w styku smarowanym, powłoki te wykazują

niższy współczynnik tarcia w stosunku np. do powłok TiN, charakteryzują się wysoką odpornością na utlenianie w podwyższonych temperaturach oraz dobrymi właściwościami antykorozyjnymi. Wymienione cechy przyczyniają się do szerokiego wykorzystywania powłok CrN w licznych aplikacjach, np. są one nanoszone na narzędzia do obróbki skrawaniem, formy do ciśnieniowego odlewania aluminium, stosowane w przemyśle tworzyw sztucznych oraz do poprawy trwałości części maszyn itp.

Badania dotyczyły powłok, uzyskanych poprzez osadzanie z wykorzystaniem metody łukowo-próżniowej na dwóch komercyjnych urządzeniach: urządzeniu MZ 383 firmy METAPLAS IONON oraz urządzeniu NNW 6,614 typu *Butat*. Powłoki uzyskiwano przy różnych parametrach procesu. Zmianie podlegały: ciśnienie azotu, temperatura osadzania powłoki, ujemne napięcie polaryzacji oraz sumaryczny prąd źródeł. W wyniku przeprowadzonych procesów uzyskano powłoki różniące się zarówno grubością, wartością parametru chropowatości, morfologią powierzchni, jak również procentową zawartością pierwiastków oraz strukturą sieci krystalograficznej składników fazowych. Powłoki wykazywały również zróżnicowane właściwości mechaniczne (moduł Younga, adhezję).

Wyniki eksperymentów przedstawiają wybrane aspekty, dotyczące niektórych właściwości warstw, uzyskanych dla zadanych wartości parametrów procesu. Zakres danych możliwych do wykorzystania w procesie modelowania jest obecnie ograniczony ze względu na brak odpowiednio zorganizowanego systemu baz, zawierających dane o przeprowadzonych procesach. Taki stan rzeczy spowodował znaczne różnice zarówno w sposobie, jak i rodzaju rejestrowanych danych pochodzących z eksperymentów badawczych, pomiarów oraz przeprowadzonych procesów nanoszenia powłok z wykorzystaniem różnych urządzeń. Dlatego też proces modelowania warunkowany był dostępnością zarejestrowanych danych. W modelowaniu wykorzystano metodę sztucznych sieci neuronowych do odwzorowania zależności pomiędzy właściwościami powłok a parametrami procesu nanoszenia powłok.

2. Metoda modelowania

Na podstawie analizy potrzeb w zakresie opracowania modeli prognostycznych, jak również możliwości modelowania warunkowanych dostępnymi zbiorami danych na obecnym etapie rozwoju systemu dokumentowania wyników badań, został przyjęty plan postępowania. Do opracowania modeli wykorzystany został pakiet *Statistica Neural Networks* [10].

Zgodnie z przyjętym algorytmem, w pierwszej fazie modelowania procesu nanoszenia powłok zostały przeanalizowane zbiory danych, charakteryzujących przeprowadzone procesy oraz właściwości uzyskanych powłok. W modelowaniu uwzględniono parametry procesu stanowiące zmienne niezależne modelu oraz charakterystyki warstwy, które uwzględniano w kolejnych opracowywanych modelach jako zmienne wyjściowe (tab. 1).

Tabela 1. Zmienne wejściowe i wyjściowe uwzględnione w procesie modelowania

Nazwa zmiennej	Rodzaj	Oznaczenie	typ
Urządzenie	wejściowa	GRUPA	nazwa
Ciśnienie azotu [mbar]	wejściowa	CISNIENIE	liczba
Temperatura osadzania powłoki [°C]	wejściowa	TEMP	liczba
Ujemne napięcie polaryzacji podłoża [V]	wejściowa	NAPIECIE	liczba
Sumaryczny prąd źródeł [A]	wejściowa	PRAD	liczba
Grubość powłoki [μm]	wyjściowa	GRUBOSC	liczba
Zawartość N [%]	wyjściowa	N	liczba
Zawartość Cr [%]	wyjściowa	CR	liczba
Chropowatość powierzchni Ra	wyjściowa	RA	liczba
Moduł Younga [GPa]	wyjściowa	YOUNG	liczba
Adhezja [N]	wyjściowa	LC1, LC2	liczba

Na kolejnym etapie przeprowadzono badania związane z budową modeli o wielokrotnych wyjściach. W celu opracowania modeli o strukturze sieci neuronowej, zbiory danych doświadczalnych opisujące właściwości warstw i parametry procesu nanoszenia zostały podzielone odpowiednio na wektor: uczący, weryfikacyjny i testowy. Pozwoliło to na opracowanie modelu oraz sprawdzenie jego zdolności do uogólniania wyniku. Na podstawie analizy procesu oraz danych z eksperymentów podjęto decyzję o budowie czterech modeli neuronowych, opisujących kolejno: grubość, skład fazowy, moduł Younga oraz adhezję powłok jako funkcje parametrów procesu. Zaplanowano również opracowanie modelu o wielu wyjściach (zmiennych zależnych), stanowiących zestaw charakterystyk warstwy. Przyjęta metoda uwzględniła analizę wrażliwości wejść modelu, na podstawie których szacowano oddziaływanie poszczególnych parametrów procesu na zmienną (zmienne) zależną. W procesie analizy wrażliwości obliczane są błędy sieci dla przypadków uczących i walidacyjnych, które są odniesieniem przy ocenie wrażliwości poszczególnych wejść. Wrażliwość oceniana jest za pomocą trzech parametrów: ranga, błąd i iloraz. *Błąd* jest głównym parametrem oceny i wskazuje na jakość sieci, przy pominięciu analizowanej zmiennej. Duża wartość parametru *błąd* oznacza, że sieć przy pominięciu zmiennej znacznie traci na jakości. Parametr *iloraz* jest otrzymywany w wyniku podzielenia wartości parametru błędu, określonego przy pominięciu zmiennej przez błąd obliczony dla sieci ze wszystkimi wejściami. Wartości ilorazu mniejsze od jedności oznaczają zatem poprawienie jakości modelu przy pominięciu zmiennej.


Jakość opracowanych modeli neuronowych analizowana była na podstawie charakterystyk regresyjnych oraz względnego błędu popełnianego przez sieć, zdefiniowanego jako stosunek modułu różnicy wartości wzorcowej i obliczonej do wartości wzorcowej.

3. Wyniki modelowania

Model 1: Analiza wpływu parametrów procesu na grubość osadzanych powłok

Badania zostały ukierunkowane na opracowanie modelu opisującego grubość powłok, otrzymywanych w procesach nanoszenia na dwóch rodzajach urządzeń. W modelu przyjęto wielkości wejściowe opisujące proces osadzania powłok oraz grubość powłoki jako wielkość wyjściową.

Badaniom poddano ponad 200 sieci różnych typów i o różnych strukturach. Najlepsze wyniki uzyskiwano dla sieci typu *perceptron trójwarstwowy*. Średnie wartości błędów opracowanych wybranych modeli neuronowych przedstawiono na rys. 1.



Rys. 1. Średnie błędy względne modeli typu MLP

Zaprezentowane wyniki wskazują na znaczące błędy modeli (powyżej 10%). Szczegółowa analiza dotycząca poszczególnych przypadków wykazuje znaczne różnice dopasowania modelu do przypadków, np. sieć MLP121, wykazująca największe tego typu różnice, dla najlepiej odwzorowanego wektora popełnia błąd 0,3%, zaś najgorsze odwzorowanie tej sieci to błąd ponad 80%. Tak duże różnice dotyczą co prawda tylko pojedynczych wektorów z grupy uczących i mogą świadczyć o błędach w zbiorze danych, np. wynikających z pomiarów, to jednak powinny być dokładnie przeanalizowane. Wnioski z tego rodzaju analizy stanowić mogą istotne wskazówki, przydatne w procesie modelowania.

Kolejny etap badań w kierunku poprawy jakości modelu, nie tylko zmniejszenia błędu modelu, ale również uproszczenia struktury, dotyczył analizy wrażliwości wejść. W tab. 2 przedstawiono przykładowy wynik analizy wrażliwości wejść (sieć MLP120 (5:7:1)). Parametr *ranga* numeruje zmienne w porządku ich ważności dla modelu, przyjmując jako kryterium wartość parametru *błąd*.

Rezultaty przeprowadzonych badań dotyczących wrażliwości wejść analizowanego zbioru modeli neuronowych wskazują na zdecydowanie najmniejsze znaczenie dla jakości modelu wielkości wejściowej TEMP (temperatury osadzania powłok). W każdym z analizowanych przypadków wejście to posiadało rangę 5. Najistotniejszym wśród wejść okazała się wielkość GRUPA (rodzaj urzą-

dzenia). Przeprowadzone eksperymenty dla modelu z pominięciem wejścia TEMP wykazały pogorszenie jakości odwzorowania.

Tabela 2. Analiza wrażliwości wejść sieci MLP120

	GRUPA	CISNIENIE	TEMP.	NAPIĘCIE	PRĄD
Dane uczące					
Ranga	1	4	5	3	2
Błąd	1,248	0,397	0,372	0,418	0,667
Iloraz	3,390	1,079	1,009	1,137	1,811
Dane walidacyjne					
Ranga	1	2	5	3	4
Błąd	1,608	0,415	0,118	0,172	0,147
Iloraz	22,342	5,763	1,637	2,387	2,038

Jak wykazała analiza wrażliwości wejść, jakość odwzorowania analizowanej charakterystyki najsilniej zależy od urządzenia zastosowanego w procesie osadzania warstw, dlatego też na kolejnym etapie modelowania charakterystyki zostały przeprowadzone badania oddzielnie dla urządzeń MZ 383 (*model 1a*) oraz NWW6,61 (*model 1b*).

Model 1a

Przebadano ponad 200 sieci odwzorowujących grubość warstw osadzanych z zastosowaniem urządzenia MZ 383. Błędy popełniane przez sieci przy obliczaniu grubości warstwy przekraczały dla każdego zbudowanego modelu ponad 10%. W wielu wypadkach błąd ten był znacznie większy i sięgał ponad 20%. W wielu modelach udało się osiągnąć błąd walidacji znacznie mniejszy (rzędu nawet 0,6% (sieć MLP78)), ale i w tym przypadku błąd modelu wyniósł ponad 17%, co czyni model nieprzydatnym do zastosowania.

Przeprowadzone badania wykazały, że w zależności od przyjętych przypadków walidacyjnych występują różnice w określeniu rangi wrażliwości wejść. Różnice tego typu występują również pomiędzy rangami, określonymi dla przypadków uczących i walidacyjnych. Oznacza to, że nie można jednoznacznie wskazać wejścia najbardziej i najmniej znaczącego, a odrzucenie niektórych wielkości wejściowych może powodować wystąpienie znacznych błędów przy wyliczaniu grubości dla pojedynczych przypadków. Dlatego też, w dalszych badaniach przyjęto założenie o niezmiennianiu liczby zmiennych wejściowych.

Na kolejnym etapie badań, zmierzających do poprawy jakości opracowywanego modelu, analizie zostały poddane błędy popełniane dla poszczególnych przypadków przez wybrane modele o najlepszej jakości. Jak wynika z przeprowadzonej analizy błędów, niemal wszystkie zbadane sieci największy błąd popełniały przy obliczaniu wartości grubości dla przypadku oznaczonego nr 26. Natomiast dla przypadku 7 błędy popełniane przez modele neuronowe zawsze przekraczały 17%.

Na podstawie zaobserwowanych faktów można więc było wnioskować o występujących błędach w danych. Dlatego też zostały przeprowadzone dodatkowe badania z wyłączeniem wskazanych przypadków z procesu uczenia sieci. W pierwszej kolejności wyłączono przypadek 26. Jakkolwiek nastąpiła znaczna poprawa jakości uzyskiwanych modeli, to błąd modelu pozostawał nadal na dość wysokim poziomie. Najlepsza sieć obciążona była błędem ponad 10%, a różnice pomiędzy błędami wyliczania poszczególnych przypadków sięgały nawet 35%.

Kolejny etap badań został przeprowadzony po usunięciu również przypadku 7. Po tej zmianie można było zaobserwować znaczną poprawę jakości budowanych modeli, uzyskano dobre rezultaty, a błędy najlepszych opracowanych modeli utrzymywały się na poziomie 3%. W tab. 3 przedstawiono statystyki regresyjne modelu najlepiej odwzorowujących badany obiekt (po usunięciu danych dla przypadku nr 7).

Tabela 3. Statystyki regresyjne modelu MLP 193

	Uc. GRUBOŚĆ	Wa. GRUBOŚĆ
Średnia	1,324	2,725
Odchylenie standardowe	0,941	1,421
Średni błąd	0,019	-0,046
Odchylenie błędu	0,027	0,026
Średni błąd bezwzględny	0,022	0,046
Iloraz odchylenia	0,028	0,018
Korelacja	1	1

Analiza statystyk regresyjnych wskazuje dobrą jakość modelu MLP 193. Jest to sieć typu *perceptron wielowarstwowy* z jedną warstwą ukrytą, w której zastosowano logistyczną funkcję aktywacji.

Analiza wrażliwości dla wybranej sieci (rys. 2) wskazuje na istotność wszystkich wielkości wejściowych. Najniższy iloraz wynosi ponad 3, a więc można się spodziewać, że odrzucenie nawet najmniej istotnego wejścia spowoduje znaczne pogorszenie jakości obliczeń.

	CISNIENI	TEMP	NAPIECIE	PRAD
Ranga	4	2	1	3
Błąd	0,2204013	0,5117941	0,7430551	0,4091387
Iloraz	6,737685	15,64559	22,71525	12,5074
Ranga	3	1	2	4
Błąd	0,377737	0,6164786	0,4521136	0,1375087
Iloraz	8,259723	13,48013	9,886065	3,006811

Rys. 2. Wyniki analizy wrażliwości wejść modelu neuronowego MLP193

Model 1b

Analogiczne badania przeprowadzono w celu opracowania modelu grubości powłoki osadzanej z zastosowaniem urządzenia NWW6,61. W przypadku tego urządzenia wszystkie zarejestrowane procesy były prowadzone dla tej samej wartości prądu, dlatego też w modelowaniu uwzględniono trzy wielkości wejściowe: ciśnienie, temperatura, napięcie.

Zostały opracowane i przebadane różne struktury sieci neuronowych modelujące grubość powłoki nanoszonej przy wykorzystaniu urządzenia NWW6,61. Jak wynika z analizy wyników przeprowadzonych badań, najlepsze rezultaty modelowania otrzymano przy wykorzystaniu sieci typu *perceptron wielowarstwowy* z sigmoidalną funkcją aktywacji.

Przeprowadzono analizę błędów popełnianych przez różne sieci przy wyliczaniu grubości dla różnych parametrów procesu. Analiza wskazała na dwa, obciążone największym błędem, przypadki. Przypadki te wykazywały największe błędy również przy zmianie parametrów uczenia sieci i różnie wybieranych przypadkach walidacyjnych.

Przeprowadzone kolejne badania, z wyłączeniem pierwszego z nich, nie dały znaczącej poprawy modelu. Zaobserwowano nawet pogorszenie jego działania przy wyliczaniu grubości powłok dla niektórych parametrów procesu. Natomiast zdecydowana poprawa nastąpiła po wykluczeniu drugiego z tych przypadków (oznaczonego nr 14). Najlepsza opracowana sieć neuronowa wykazała bardzo dobre dopasowanie do reprezentowanego procesu we wszystkich badanych przypadkach parametrów procesu. Błędy popełniane przez ten model nie przekroczyły 1% dla żadnego z poszczególnych wektorów wejściowych, natomiast względny błąd modelu wyniósł poniżej 0,5%.

Najlepiej dopasowana w tej sytuacji sieć oznaczona MLP20_b1 to perceptron wielowarstwowy z sześcioma neuronami w jednej warstwie, ukrytej o sigmoidalnej funkcji aktywacji i funkcji liniowej w warstwie wyjściowej. Wyniki analizy wrażliwości oraz statystyki regresyjne dla tej sieci przedstawiono na rys. 3.

a)

	CIŚNIENI	TEMP	NAPIECIE
Ranga	2	1	3
Błąd	0,1682274	0,2856217	0,07308
Iloraz	7,458931	12,66401	3,240042
Ranga	2	1	3
Błąd	0,1539352	0,2361306	0,07101
Iloraz	5,689418	8,727345	2,624668

b)

	Uc. GRUBO	Wz. GRUBO
Średnia	3,88	4,04
Odch. std.	0,4607602	0,09899
Średni błąd	-0,008082	0,01749
Odch. błędu	0,02354	0,0292
Śr. bł. bezwz.	0,0208	0,02065
Iloraz odch.	0,05109	0,2949566
Korelacja	0,9987307	1

Rys. 3. Okna: analizy wrażliwości (a) i statystyk regresyjnych (b) dla sieci MLP20_b1

Przeprowadzony proces modelowania charakterystyki grubości warstwy w efekcie doprowadził do opracowania dwóch modeli: *Model 1a* (sieć MLP_193) oraz *Model 1b* (sieć MLP20_b1), reprezentujących procesy prowadzone odpowiednio na urządzeniach: MZ83 i NWW6,61.

Model 2: Analiza wpływu parametrów procesu na zawartość Cr i N w nanoszonych warstwach CrN

Kolejną charakterystyką poddaną badaniom modelowym była zawartość Cr i N w nanoszonych powłokach CrN na urządzeniu NWW6,61. Badaniom poddano kilkadziesiąt sieci różnych typów. Jak wynika z serii przeprowadzonych badań, najlepsze odwzorowanie badanego procesu uzyskano w modelu neuronowym typu *perceptron wielowarstwowy* z sigmoidalną funkcją aktywacji w warstwie ukrytej, uzyskując w ten sposób *Model 2* (sieć MLP21), błąd opracowanego modelu nie przekraczał 3%.

Model 3: Analiza wpływu parametrów procesu na chropowatość nanoszonych warstw

Została podjęta próba opracowania modelu, odwzorowującego parametr chropowatości R_a w zależności od parametrów procesu nanoszenia warstwy z wykorzystaniem urządzenia NWW6,61. Skonstruowano serię modeli neuronowych o różnej architekturze. W procesie opracowania modeli wykorzystywano różne parametry uczenia oraz losowo wybierane przypadki wektorów uczących i walidacyjnych. Analiza wyników wskazuje na zbyt duże błędy popełniane przez wszystkie modele przy wyliczaniu wartości wyjściowej. W wielu modelach obserwowane są znaczne różnice pomiędzy błędami uczenia a walidacji. Wskazuje to na trudność dopasowania wartości wag połączeń neuronowych w taki sposób, aby model właściwie opisywał zarówno przypadki wytypowane do uczenia, jak również był zdolny do uogólniania wyniku. Najlepszy opracowany model, w którym błędy uczenia i walidacji były na porównywalnym poziomie, wykazywał znaczny błąd obliczeń (niewiele poniżej 6%).

Modelowanie pozostałych charakterystyk


Przeprowadzone badania modelowania charakterystyki *twardość* zakończyły się niepowodzeniem. Jako główną przyczynę niepowodzenia należy wskazać niedostateczną reprezentację procesu przez dostępne, zarejestrowane dane. Modelowanie modułu Younga dało lepsze efekty, jednak najlepsza znaleziona sieć jakkolwiek dała poprawę oszacowania wartości przez model w porównaniu z oszacowaniem na podstawie średniej, to jednak ta poprawa średnio wyniosła ok. 1%. W przypadku charakterystyki *adhezja* zbiór danych reprezentowany zaledwie kilkoma wektorami nie dawał podstaw podjęcia działań, zmierzających do opracowania modelu. Uzyskane modele należy odrzucić jako nieprzydatne do opisu badanych charakterystyk.

Modelowanie wybranych zbiorów charakterystyk

Kolejny etap modelowania dotyczył budowy modelu, opisującego wybrane zbiory kilku charakterystyk, reprezentujących właściwości nanoszonych powłok. Przeprowadzono badania modelu o kilku wyjściach, umieszczając w wektorze wyjściowym grubość zawartość chromu oraz parametr chropowatości Ra. W procesie modelowania wykorzystano zbiór danych, zawierający wyniki pomiaru zawartości Cr i N dla kilku próbek w ramach każdego z wektorów wejściowych opisujących parametry procesu. W przypadku pomiarów grubości i parametru chropowatości Ra dysponowano wyłącznie wartościami średnimi dla poszczególnych wektorów wejściowych. Ze względu na występujące braki danych w wektorach wyjściowych uwzględniono wartości średnie Ra i grubości warstwy. Niestety tak skonstruowane modele wykazywały znaczne błędy obliczeń.

Jak wykazały badania, najlepsze rezultaty otrzymywano przy zastosowaniu liniowego modelu neuronowego, jednak i w tym wypadku błędy wyliczania poszczególnych przeanalizowanych przypadków sięgały niekiedy ponad 10%, a dla wyliczanego parametru Ra nawet ponad 15%.

Kolejne badania dotyczyły budowy modelu opisującego charakterystyki Ra oraz grubości powłoki w zależności od wartości parametrów procesu, stanowiących wektor wejściowy. Dla tych charakterystyk dostępne były dane tego samego rodzaju, tzn. średnie z pomiaru dla każdej z powłok. Na rys. 4 przedstawiono wyniki obliczeń uzyskane przy zastosowaniu wybranych (najlepszych) z opracowanych modeli neuronowych o różnej architekturze.



Rys. 4. Wykresy średnich błędów względnych modeli oraz średnich błędów względnych popelnianych przez poszczególne modele (różne typy sieci oznaczono odpowiednio: 10 (RBF), 9 (liniowa), 20 (MLP)) przy wyliczaniu wartości grubości warstwy i parametru Ra

W przypadku wszystkich opracowanych modeli neuronowych modelujących zbiory charakterystyk, błędy zarówno modelu, jak i jednostkowe błędy wyliczania poszczególnych przypadków przekraczały poziom, który można by uznać za satysfakcjonujący, dlatego też ten sposób odwzorowania charakterystyk warstw uzyskiwanych w wyniku badanych procesów należy uznać za nieodpowiedni, obarczony zbyt dużym błędem.

Podsumowanie

W wyniku przeprowadzonego procesu modelowania charakterystyk warstw uzyskiwanych w procesach plazmowych osadzania powłok opracowano modele, pozwalające na prognozowanie grubości warstwy (*Model 1a i Model 1b*) oraz składu fazowego (*Model 2*) w zależności od parametrów procesu. Wartości średnich błędów względnych tych modeli były na poziomie 3%.

Dokładna analiza zbioru danych oraz sposobu ich rejestracji wskazała na znaczne niedostatki w tym zakresie. Wiele informacji nie mogło być wykorzystanych ze względu na ich charakterystyki trudne do prawidłowej interpretacji. Wpłynęło to zasadniczo na ograniczenie możliwości opracowania modeli. Jednocześnie w trakcie badań wykazano potencjalne zdolności sieci neuronowych do opisu badanych procesów.

Efektywne wykorzystanie tej metody modelowania warunkowane jest dostępem do danych zorganizowanych w odpowiednio opracowanych systemach zasilania informacyjnego. Brak systemu zarządzania danymi powoduje nie tylko trudności w opisie analizowanych charakterystyk oraz wydłużenie czasu uzyskania poszukiwanych rozwiązań, ale może również powodować np. znacznie gorszą jakość opisów czy też utratę cennej informacji zawartej w danych.

Istniejąca potrzeba poszukiwania skutecznych metod wspomagania sterowania procesami osadzania w kierunku zwiększenia możliwości prognozowania właściwości warstw (dotychczasowe metody bazują głównie na doświadczeniu operatorów procesów), wskazuje na konieczność opracowania systemu zasilania informacyjnego o przedmiotowych procesach.

Praca naukowa finansowana ze środków Ministra Nauki i Szkolnictwa Wyższego, wykonana w ramach realizacji Programu Wieloletniego PN „Doskonalenie systemów rozwoju innowacyjności w produkcji i eksploatacji w latach 2004–2008”.

Bibliografia

1. Projekt celowy nr 7 1232 91 C: Technologie nanoszenia wieloskładnikowych i wielowarstwowych powłok przeciwzużyciowych na narzędzia skrawające metodami plazmochemicznymi. Międzyresortowe Centrum Naukowe Eksploatacji Majątku Trwałego, Radom 1994.
2. Projekt celowy nr 7 T08B 003 C/2574: Technologia podwyższania trwałości form ciśnieniowego odlewania aluminium przez wytwarzanie warstw kompozytowych metodą dwustopniowej obróbki powierzchniowej. Sprawozdanie, Instytut Technologii Eksploatacji, Radom 1998.
3. Walkowicz J.: Kształtowanie własności złożonych powłok przeciwzużyciowych przez dobór i optymalizację składu i sposobu ich osadzania. Sprawozdanie, Instytut Technologii Eksploatacji, Radom 1999.

4. Walkowicz J. (red.): Utrzymanie i rozwój Laboratorium Technologii Warstwy Wierzchniej. Sprawozdanie, Instytut Technologii Eksploatacji, Radom 2000.
5. Swingler K.: Applying neural networks. A Practical Guide. Pub Academic Press, 1996.
6. Korbicz J., Obuchowicz A., Uciński D.: Sztuczne sieci neuronowe. Podstawy i zastosowania. Akademicka Oficyna Wydawnicza, Warszawa 1994.
7. Osowski S.: Sieci neuronowe do przetwarzania informacji. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.
8. Frangu L., Ripa M.: Artificial neural networks applications in tribology – a survey. NIMIA-SC2001 – 2001 NATO Advanced Study Institute on Neural Networks for Instrumentation, Measurement and Related Applications: Study Cases Crema, Italy, 2001.
9. Wieczorek T.: Intelligent control of the electric-arc steelmaking process using artificial neural networks. *Comp. Methods in Material Science*, 2006, 6, 1, 9–14.
10. Statistica Neural Networks. StatSoft. 2001.

Recenzent:

Tadeusz WIECZOREK

Modelling the influence of the parameters of processes on coating properties

Key words

Modelling, characteristics models, artificial neural networks, coatings properties.

Summary

Some of the properties of coatings deposited with the use of PAPVD methods were described. The research concerns coatings deposited on two different commercial devices. The modelling technique was applied in order to model development that enables the prediction of layer properties based on the deposition parameters. In this research, the method of artificial neural network was applied for modelling, and data from both research experiments and technological processes were used. As the results of modelling show, only some characteristics were well described by models. That problem mainly appeared because of data shortage causing a limitation in modelling. However, research results justify neural network application for describing the analysed processes and the development of prediction models for coating properties.