

Sieci neuronowe MLP w badaniu chropowatości powierzchni R_a i R_z

MLP neural networks in the study of surface roughness R_a and R_z

IZABELA ROJEK
PAWEŁ TWARDOWSKI*

DOI: 10.17814/mechanik.2016.8-9.235

Omówiono modele sieci neuronowych jednokierunkowych wielowarstwowych ze wsteczną propagacją błędu (MLP). Modele te zastosowano do oceny chropowatości R_a i R_z . Badania wykonano na danych rzeczywistych wybranego przedsiębiorstwa. Dane te zostały zebrane podczas procesu obróbki rowków pod pierścienie w tłokach silników samochodowych. SŁOWA KLUCZOWE: sieć neuronowa, chropowatość powierzchni, analiza, ocena

The article discusses the models of one-directional multilayer neural networks with error backpropagation (MLP). These models were used to evaluate the surface roughness of R_a and R_z . The study was performed on real data of the selected enterprise. These data were gathered during the process of machining grooves under the rings of the pistons in automobile engines.

KEYWORDS: neural network, surface roughness, analysis, evaluation

Istotnym parametrem w ocenie jakości powierzchni jest chropowatość powierzchni obrobionej określona za pomocą R_a (średniego arytmetycznego odchylenia profilu od linii średniej) i R_z (największej wysokości profilu) [1]. Jednak pomiar parametru R_z był wykonany przyrządem starszej generacji (wysokość chropowatości według dziesięciu punktów profilu), co było zgodne z wycofaną normą PN-87/M-04256/02.

W kraju i na świecie przeprowadzono szereg badań dotyczących kontroli i przewidywania chropowatości powierzchni, w tym z zastosowaniem sztucznych sieci neuronowych. W artykułach [2÷5] przedstawiono badania dotyczące kontroli i przewidywania parametrów chropowatości R_a , R_z i R_{max} . Pomiar były wykonywane na jednej tokarce, a do przewidywania użyto sieci MLP. Na wejściu sieci podano głębokość skrawania a_p , prędkość skrawania v_c i prędkość posuwu v_f . Na wyjściu sieci były parametry chropowatości R_a , R_z i R_{max} . Wyniki uzyskane przez sieci MLP porównywano z wartościami rzeczywistymi i dały one dobre rezultaty.

W artykule prezentowane jest inne podejście do badania chropowatości powierzchni. Wcześniejsze badania dotyczyły kontroli, a przede wszystkim przewidywania chropowatości ze względu na parametry obróbki. W artykule autorzy skupili się na kontroli wartości parametrów chropowatości R_a i R_z . Opracowane modele mogą służyć do sygnalizowania, czy parametr chropowatości jest w normie, czy poza nią. W przypadku wyjścia poza zakres dopuszczalny aplikacja z modelami sieci może informować o konieczności korekty parametrów skrawania. Badania przeprowadzono na kilku obrabiarkach, co może również wskazać, która obrabiarka jest najlepsza.

* Dr inż. Izabela Rojek (izarojek@ukw.edu.pl) – Instytut Mechaniki i Informatyki Stosowanej, Uniwersytet Kazimierza Wielkiego w Bydgoszczy; dr hab. inż. Paweł Twardowski (pawel.twardowski@put.poznan.pl) – Instytut Technologii Mechanicznej, Wydział Budowy Maszyn i Zarządzania Politechniki Poznańskiej

Przygotowanie badań

Pomiary parametrów chropowatości R_a i R_z wykonano na pięciu obrabiarkach: S8A, S8L, S8H, S8111 i PDK 741. Na rys. 1 pokazano fragment karty pomiarowej parametru chropowatości R_a . Analogicznie wyglądała karta pomiarowa dla R_z .

Na podstawie kart pomiarowych przygotowano pliki uczące sieci neuronowych, osobno dla każdego z parametrów R_a i R_z .

Wstępne przetwarzanie danych odgrywa ważną rolę zarówno podczas uczenia, jak i testowania sieci neuronowych. Na tym etapie należy rozwiązać takie problemy, jak dobór cech, ich selekcja czy wybór odpowiednich przykładów. Kolejnym problemem związanym ze wstępnym przetwarzaniem danych jest reprezentacja wartości symbolicznych przez sieć neuronową. Ze względu na wartości symboliczne (parametry jakościowe) na wejściach i wyjściach sieci neuronowych liczba wejść i wyjść sieci została zwiększona.

| | | | | | | | | | | | | | | | | | | | | | |
|------------|------------|-------|-----|-----|-----|-----|-----|-----|-----|-----|-----|--|--|--|--|--|--|--|---|---|--|
| | powyżej 2 | | | | | | | | | | | | | | | | | | | | |
| | 1,320 | 2,000 | | | | | | | | | | | | | | | | | | | |
| | 1,174 | 1,319 | | | | | | | | | | | | | | | | | | | |
| | 1,027 | 1,173 | | | | | | | | | | | | | | | | | | | |
| | 0,881 | 1,026 | | | | | | | | | | | | | | | | | | | |
| Ra [μm] | 0,734 | 0,880 | | | | | | | | | | | | | | | | | x | x | |
| | 0,587 | 0,733 | | | | | | | | | | | | | | | | | x | | |
| | 0,440 | 0,586 | | | | | | | | | | | | | | | | | x | x | |
| | 0,294 | 0,439 | x | | | | | | | | | | | | | | | | | | |
| | 0,147 | 0,293 | | | | | | | | | | | | | | | | | | | |
| | 0,000 | 0,146 | | | | | | | | | | | | | | | | | | | |
| | poniżej 0 | | | | | | | | | | | | | | | | | | | | |
| | Nr pomiaru | 112 | 114 | 118 | 125 | 127 | 129 | 133 | 139 | 144 | 145 | | | | | | | | | | |

Rys. 1. Fragment karty pomiarowej parametru R_a , w μm

Parametry jakościowe są dodatkowo kodowane w ciągu zero-jedynkowy (np. 001001101). Przykładowo: dla decyzji mamy cztery wartości: *norma*, *ostrzeżenie*, *interwencja* i *brak*. Jest to kodowane w następujący sposób:

- *norma* jest to ciąg 0001,
- *ostrzeżenie* jest to ciąg 0010,
- *interwencja* jest to ciąg 0100,
- *brak* jest to ciąg 1000.

Z jednego wyjścia decyzji powstały w rzeczywistości cztery. Faktyczna liczba wejść i wyjść sieci zależy od liczby przyjmowanych wartości jakościowych.

Fragment pliku uczącego dla parametru R_a pokazano w tabl. I. Dane te dotyczą: strony rowka, zakresu R_a oraz decyzji, czy chropowatość mieści się w normie. Dla parametru R_z plik uczący wyglądał analogicznie.

Struktura pliku testowego i walidacji jest taka sama. Plik uczący zawiera 70% przykładów, plik testowy – 15%, a plik walidacyjny – kolejne 15%. Liczba całkowita przykładów (pomiarów) wyniosła 927.

TABLICA I. Fragment pliku uczącego dla parametru R_a

| we | we | wy |
|--------|---------------|-------------|
| #rowek | #zakres R_a | #decyzja |
| dół | 0,000÷0,116 | norma |
| dół | 0,117÷0,234 | norma |
| dół | 0,470÷0,586 | norma |
| dół | 0,822÷0,939 | ostrzeżenie |
| dół | 1,056÷1,600 | interwencja |
| górze | powyżej 2 | brak |
| górze | 0,147÷0,293 | norma |
| górze | 1,320÷2,000 | interwencja |

Modele sieci neuronowej

Sieci MLP niezmiennie są najbardziej rozpowszechnionymi i uniwersalnymi sieciami neuronowymi stosowanymi do rozwiązywania różnych problemów, w tym technicznych [6].

Sieci MLP zostały zbudowane z jedną warstwą ukrytą. Eksperymenty związane z tworzeniem modeli sieci neuronowych MLP były parametryzowane dwoma parametrami: liczbą neuronów w warstwie ukrytej oraz liczbą epok uczących. W eksperymencie parametr liczba neuronów w warstwie ukrytej przyjmował wartości od 3 do 30, natomiast drugi parametr – liczba epok uczących – przyjmował wartości od 4 do 100. Po zakończeniu każdego eksperymentu przeprowadzone zostały testy, które dostarczały informacji na temat skuteczności sieci. Liczba neuronów w warstwie ukrytej została dobrana eksperymentalnie.

Do uczenia sieci MLP wykorzystano algorytm BFGS (*Broyden-Fletcher-Goldfarb-Shanno*). Jest to jeden z najbardziej efektywnych algorytmów uczenia sieci neuronowych. Przykładowo: zapis BFGS 4 oznacza, że optymalne rozwiązanie otrzymano w 4 iteracjach.

Zastosowano funkcje błędów w postaci funkcji sumy kwadratów (SOS) oraz entropii. Wykorzystano różne funkcje aktywacji w warstwie ukrytej i wyjściowej:

- *Tanh*,
- *Wykładniczą*,
- *Liniową*,
- *Logistyczną*,
- *Softmax*.

Każdy z tych parametrów wpływa na skuteczność sieci neuronowych. W tabl. II zilustrowano parametry opisujące eksperymenty dla różnych struktur sieci MLP. Skuteczność sieci wyrażono w procentach. W eksperymencie wybrano 20 najlepszych sieci neuronowych dla R_a i R_z . W tabelicy pokazano siedem z nich.

Podczas analizy sieci neuronowych (MLP) stwierdzono, że skuteczność sieci zależy od ich parametrów: liczby neuronów w warstwie ukrytej, liczby cykli uczących według określonego algorytmu uczenia, wartości funkcji błędów oraz funkcji aktywacji w warstwie ukrytej i wyjściowej. Analiza wszystkich opracowanych modeli wykazała, że modele sieci MLP 25-20-4, 25-21-4, 25-8-4 i 25-11-4 są najskuteczniejsze w badaniu chropowatości R_a (skuteczność 99,71%), a modele sieci MLP 25-18-4, 25-19-4 i 25-5-4 są najskuteczniejsze w badaniu chropowatości R_z (skuteczność 100,00%).

Oceniano także dokładność (trafność) i stopień pewności sieci neuronowych. Dokładność odnosi się do działania sieci na nowych danych, przy czym stopień pewności wskazuje powiązanie nowych danych wejściowych

z określonymi klasami wzorów. Oba parametry wpływają na skuteczność sieci neuronowych. Im większe są dokładność i stopień pewności, tym lepsza jest zdolność klasyfikacji sieci neuronowych.

TABLICA II. Parametry najlepszych sieci MLP

| Id | Nazwa sieci | Skuteczność sieci, % | Algorytm uczenia | Funkcja błędów | Aktywacja (ukryte) | Aktywacja (wyjście) |
|--------------------|-------------|----------------------|------------------|----------------|--------------------|---------------------|
| Chropowatość R_a | | | | | | |
| 1 | MLP 25-20-4 | 99,71 | BFGS 30 | SOS | Wykładnicza | Liniowa |
| 2 | MLP 25-21-4 | 99,71 | BFGS 15 | Entropia | Wykładnicza | Softmax |
| 3 | MLP 25-8-4 | 99,71 | BFGS 11 | Entropia | Liniowa | Softmax |
| 4 | MLP 25-11-4 | 99,71 | BFGS 7 | Entropia | Liniowa | Softmax |
| Chropowatość R_z | | | | | | |
| 1 | MLP 25-18-4 | 100,00 | BFGS 10 | Entropia | Wykładnicza | Softmax |
| 2 | MLP 25-19-4 | 100,00 | BFGS 46 | SOS | Tanh | Tanh |
| 3 | MLP 25-5-4 | 100,00 | BFGS 46 | SOS | Tanh | Tanh |

Podsumowanie

Opracowane modele w postaci sieci neuronowych są bardzo dobrym narzędziem, które może posłużyć do automatyzacji kontroli pomiaru parametrów chropowatości R_a i R_z . Czujniki mierzące chropowatość podczas obróbki mogą przekazywać wartości tych pomiarów do systemu, który na podstawie modelu sieci neuronowej określa, co powinien zrobić operator. Taki system może ostrzegać operatora, kiedy niezbędna jest interwencja odnośnie do parametrów obróbki procesu.

Wykorzystanie sieci neuronowych pozwala na utworzenie komputerowego systemu wspomagania decyzji, który w sposób automatyczny pozyskuje wiedzę i ma możliwość adaptacji. Jest to szczególnie ważne przy opracowywaniu systemu wspomagania decyzji dla złożonych systemów technicznych, w których następują ciągłe zmiany, jedne podprocesy zależą od innych, wiele czynników zależy jeden od drugiego i każda zmiana systemu powoduje kolejną zmianę.

Korzyści ze stosowania sieci neuronowych wielokrotnie przekraczają pracochłonność ich tworzenia. W rzeczywistości najdłuższym etapem procesu ich tworzenia jest zgromadzenie i przygotowanie danych źródłowych, chociaż dzięki automatycznemu gromadzeniu danych również ten etap ulega skróceniu.

LITERATURA

1. PN-EN ISO 4287:1999 – Specyfikacje geometrii wyrobów – Struktura geometryczna powierzchni: metoda profilowa – Terminy, definicje i parametry struktury geometrycznej powierzchni.
2. Karaye D. „Prediction and control of surface roughness in CNC lathe using artificial neural network”. *Journal of Materials Processing Technology*. Vol. 209 (2009): pp. 3125÷3137.
3. Asiltürk I., Çunkas M. „Modeling and prediction of surface roughness in turning operations using artificial neural network and multiple regression method”. *Expert Systems with Applications*. Vol. 38 (2011): pp. 5826÷5832.
4. Zain A.M., Haron H., Sharif S. „Prediction of surface roughness in the end milling machining using Artificial Neural Network”. *Expert Systems with Applications*. Vol. 37 (2010): pp. 1755÷1768.
5. Senveter J., Klančnik S., Balic J., Cus F. „Prediction of surface roughness using a feed-forward neural network”. *Management and Production Engineering Review*. Vol. 1, No. 2 (2010): pp. 47÷55.
6. Russell S.J., Norvig P. „Artificial intelligence: a modern approach”. New Jersey: Prentice Hall, 2009. ■