

MODELOWANIE PROCESÓW PRZETWÓRCZYCH Z UŻYCIEM SZTUCZNYCH SIECI NEURONOWYCH

Jerzy Langman, Norbert Pedryc


Katedra Inżynierii Mechanicznej i Agrofizyki, Uniwersytet Rolniczy Kraków

Streszczenie. Na jakość produktów w największym stopniu wpływa surowiec zastosowany w procesie. Przygotowanie surowców oraz sam proces przetwórczy można traktować jako procesy powtarzalne, jednakże surowiec jako materiał biologiczny cechuje się dużym zróżnicowaniem występującym w obrębie tej samej odmiany. Podjęto więc prace mające na celu powiązanie cech jakościowych surowca z gotowym produktem. Do realizacji modelowania procesu wypieku zastosowano SSN. W pracy przedstawiono optymalną architekturę sztucznej sieci neuronowej do realizacji postawionego celu.

Słowa kluczowe: Sztuczne sieci neuronowe, proces wypieku chleba, jakość pieczywa

Wprowadzenie

Proces przetwórstwa rolno-spożywczego jest procesem skomplikowanym, w trakcie którego zachodzi wiele reakcji chemicznych. Jakość uzyskanego produktu zależy od parametrów procesu przygotowania surowców jak i przebiegu samego procesu. O ile procesy przygotowania surowców i obróbki termicznej możemy standaryzować, to z uwagi na silnie nieliniowe zależności między jakością użytych surowców (opisaną wieloparametrowo) a jakością produktów (też określoną kilkoma parametrami) są skomplikowane i trudne do określenia. Dlatego do formalizacji opisu związków między jakością surowca a jakością uzyskanego produktu, przy stałych parametrach przygotowania ciasta jak i jego obróbki termicznej, użyto sztucznych sieci neuronowych (SSN). Funkcje czarnej skrzynki zrealizowano za pomocą SSN (rys. 1).



Rys. 1. Schemat ideowy czarnej skrzynki wykorzystujący sztuczne sieci neuronowe jako moduł obliczeniowy

Fig. 1. Schematic diagram of a black box with artificial neural networks as the computational module

Cel i zakres pracy

Celem pracy było opracowanie modelu matematycznego opisującego jakość pieczywa w zależności od parametru podstawowego surowca jakim jest mąka. Z uwagi na trudności w znalezieniu zależności analitycznych opisujących związek między parametrami mąki a jakością otrzymanego z niej pieczywa postanowiono wykorzystać w tym celu sztuczne sieci neuronowe, które można traktować jako pewną odmianę modeli analitycznych opisujących dany proces lub zjawisko. Sztuczne sieci neuronowe można zaliczyć do modeli niejawnych, gdzie powiązania analityczne pomiędzy wejściem a wyjściem zawarte są w wagach połączeń międzyneuronowych w postaci niejawnej, a obliczenia przeprowadzane są z użyciem jawnych, uniwersalnych algorytmów zależnych od rodzaju i typu sieci neuronowej [Osowski 1996].

Zakres pracy obejmuje utworzenie modelu neuronowego ujmującego związek między jakością mąki a jakością uzyskanego pieczywa poprzez określenie zbioru wag połączeń międzyneuronowych w procesie uczenia sieci metodą wstecznej propagacji błędu. W tym celu należy przygotować zbiory uczące i testujące sztuczną sieć neuronową. Dane do utworzenia tych dwóch zbiorów uzyskano w wyniku badań przeprowadzonych w laboratorium. Wyniki badań empirycznych pozyskane do zbudowania modelu procesu wypieku chleba określały najważniejsze parametry mąki oraz podstawowe parametry uzyskanego z tej mąki pieczywa. Ostatnim etapem jest przeprowadzenie procesu uczenia i testowania sieci neuronowej dla różnych konfiguracji SSN.

Określenie zbioru danych

Danymi wejściowymi są parametry opisujące [Horubałowa, Haber 1994, Drzazga 1980] jakość mąki, takie jak:

- liczba sedymentacji,
- liczba opadania,
- procentowa zawartość białka,
- procentowa zawartość glutenu,
- wodochłonność.

Danymi wyjściowymi są natomiast parametry opisujące jakość uzyskanego w warunkach laboratoryjnych pieczywa. Są nimi:

- rozmiękczenie,
- energia wzrostu,
- objętość chleba,
- wydajność mąki,
- czas stałości,
- liczba jakości,
- liczba chleba.

Powyższy zbiór parametrów wejściowych jak i wyjściowych opisuje jakość surowca oraz uzyskanego po przeprowadzonym w kontrolowanych i powtarzalnych warunkach wypieku.

Z uwagi, iż zarówno parametry określające jakość mąki jak też parametry określające jakość uzyskanego pieczywa są wyrażone liczbami z zakresu $<1, 300>$ należy je poddać normalizacji aby na wejście sieci podawać liczby z zakresu $<0, 1>$ oraz na wyjściu sieci

otrzymywać odpowiedzi jako liczby z zakresu $\langle 0, 1 \rangle$ [Żurada i in. 1996]. Gwarantuje to wykorzystanie nieliniowych fragmentów funkcji aktywacyjnych poszczególnych warstw sieci neuronowej.


Zastosowano dwie metody normalizacji danych:

- w pierwszej przyjęto, iż wartość 0 danych poddanych normalizacji odpowiada wartości 0 danych znormalizowanych, natomiast wartości maksymalnej danych poddanych normalizacji W_{\max} odpowiada wartość 1 danych znormalizowanych. Wartości pośrednie dla zbioru $(0, W_{\max})$ mają swój odpowiednik w zbiorze $\langle 0, 1 \rangle$.
- w drugiej metodzie wykorzystano zależność (1):

$$W_{\text{normal}} = \frac{W_i - W_{\min}}{W_{\max} - W_{\min}}, \quad (1)$$

gdzie:

- W_{\min} – wartość minimalna zbioru danych poddanych normalizacji,
- W_{\max} – wartość maksymalna zbioru danych poddanych normalizacji,
- W_i – wartość poddana normalizacji,
- W_{normal} – wartość znormalizowana.



Rys. 2. Budowa sieci neuronowej wykorzystanej do modelowania procesu wypieku: I_n – wejścia, H_n – neurony warstwy ukrytej, F_1, F_2 – funkcja aktywacji, O_n – wyjście, W_n, V_n – wagi połączeń międzyneuronowych

Fig. 2. The structure of neural network employed in baking process modelling: I_n – inputs, H_n – hidden layer neurons, F_1, F_2 – activation function, O_n – output, W_n, V_n – weights of interneural connections

Architektura sztucznej sieci neuronowej

Wykorzystano sieć o następującej architekturze uczonej wsteczną propagacją błędów:

- 5 wejść, na które podawane są wielkości określające jakość mąki,
- 7 wyjść, na których po przeliczeniu wartości parametrów mąki przez wytrenowaną sieć otrzymujemy parametry uzyskanego pieczywa,
- 5 - 50 neuronów w warstwie ukrytej.

Funkcje aktywacji: tangens hiperboliczna i liniowa.

Proces uczenia i testowania sieci

W trakcie procesu uczenia dobierano tak liczbę neuronów w warstwie ukrytej, aby sieć w najlepszy sposób zachowała zdolność do uogólniania.

Dla zobrazowania różnic pomiędzy efektami uczenia się sieci przedstawiono na rys. 3 oraz rys. 4 fragmenty plików testujących oraz odpowiedzi sieci wytrenowanej.

Warstwa ukryta – 10 neuronów

```
60.7762 78.8025 82.5821 23.2562 76.3846 81.1268 74.8034
97.4400 84.7208 34.5396 112.2100 75.8591 58.6467 72.4753
618.4140 609.6755 604.1058 618.3323 615.5797 634.3212 626.7501
73.3690 72.6611 72.4212 73.8221 72.9830 75.2834 74.6964
7.9030 6.1807 4.0526 12.9933 5.2991 6.2995 6.0413
81.0332 66.7001 62.2326 140.4052 58.2126 73.5340 69.1163
151.6108 149.2030 142.4581 148.8511 150.7870 173.7451 158.0386
```

Plik testujący

```
55.0000 65.0000 70.0000 30.0000 70.0000 80.0000 90.0000
89.0000 84.0000 40.0000 108.0000 80.0000 55.0000 78.0000
600.0000 610.0000 600.0000 620.0000 630.0000 640.0000 640.0000
73.8000 74.3000 74.2000 72.6000 74.4000 74.5000 74.4000
7.7000 6.7000 4.2000 13.0000 5.2000 6.5000 5.7000
85.0000 75.0000 65.0000 140.0000 53.0000 75.0000 65.0000
143.0000 149.0000 140.0000 150.0000 161.0000 179.0000 167.0000
```

Rys. 3. Fragment wyników testowania sieci dla 10 neuronów w warstwie ukrytej. Górna część zawiera odpowiedź sieci, natomiast dolna część przedstawia uzyskane laboratoryjnie wyniki określające jakość pieczywa

Fig. 3. A fragment of network testing results for 10 neurons in the hidden layer. The upper section contains network response, whereas the lower part shows results obtained in laboratory conditions that determine bread quality

Warstwa ukryta – 40 neuronów

55.4188 67.1019 70.7379 29.6733 71.9110 79.6284 88.3916
 88.4710 84.6307 40.4839 107.6462 80.5484 55.5650 73.9789
 599.7471 612.3336 600.6889 618.0610 630.1033 640.3534 633.2476
 73.5800 74.3808 74.1186 72.6444 74.8188 74.7620 74.3471
 7.7247 6.6780 4.1829 12.9483 5.1347 6.4921 5.7497
 86.3994 76.1887 65.3218 139.3639 51.8857 74.2804 64.4921
 145.0798 149.1449 140.5129 149.8848 158.8670 178.9819 161.3198

Plik testujący

55.0000 65.0000 70.0000 30.0000 70.0000 80.0000 90.0000
 89.0000 84.0000 40.0000 108.0000 80.0000 55.0000 78.0000
 600.0000 610.0000 600.0000 620.0000 630.0000 640.0000 640.0000
 73.8000 74.3000 74.2000 72.6000 74.4000 74.5000 74.4000
 7.7000 6.7000 4.2000 13.0000 5.2000 6.5000 5.7000
 85.0000 75.0000 65.0000 140.0000 53.0000 75.0000 65.0000
 143.0000 149.0000 140.0000 150.0000 161.0000 179.0000 167.0000

Rys. 4. Fragment wyników testowania sieci dla 40 neuronów w warstwie ukrytej. Górna część zawiera odpowiedź sieci, natomiast dolna część przedstawia uzyskane laboratoryjnie wyniki określające jakość pieczywa

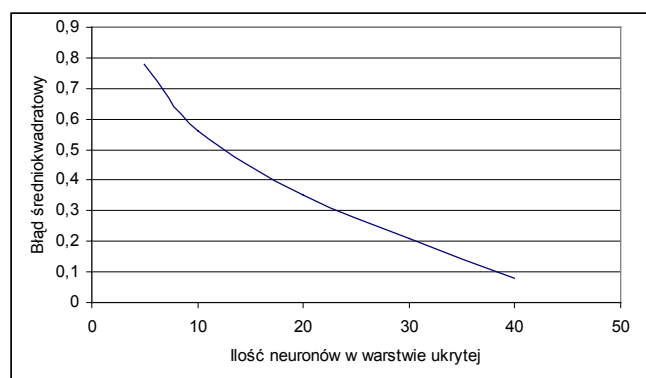
Fig. 4. A fragment of network testing results for 40 neurons in the hidden layer. The upper section contains network response, whereas the lower part shows results obtained in laboratory conditions that determine bread quality

Ostatecznie ustalono liczbę neuronów w warstwie ukrytej na poziomie 40, co jest rozwiązaniem optymalnym, gdyż gwarantuje zachowanie zdolności sieci do uogólniania. Przejawia się to najniższym błędem przetwarzania sieci w procesie testowania. Zbyt mała liczba neuronów w warstwie ukrytej powodowała wzrost błędów podczas uczenia i testowania sieci (rys. 3.), gdyż zbyt mała liczba połączeń międzyneuronowych nie zapewnia odpowiedniej pojemności informacyjnej sieci, zbyt duża liczba neuronów w warstwie ukrytej powodowała szybkie uczenie sieci w mniejszej liczbie powtórzeń, natomiast podczas testowania sieci błąd jej przetwarzania wzrasta [Tadeusiewicz i in. 2007]. Jest to spowodowane tym, że sieć uczy się na pamięć i przy zbyt dużej liczbie połączeń międzyneuronowych traci zdolność do uogólniania. Określenie optymalnej liczby neuronów w warstwie ukrytej polega na obserwacji błędów uczenia sieci oraz jej testowania przy zmiennej liczbie neuronów warstwy ukrytej i na tej podstawie określa się ich liczbę, tak aby błąd uczenia i testowania sieci był najmniejszy (rys. 5).

W procesie uczenia uzyskano błędy rzędu 2–5%, natomiast w procesie testowania 4–10%.

Uzyskane wyniki pozwalają na stwierdzenie, iż zastosowanie sztucznych sieci neuronowych do formalizacji zapisu procesu wypieku pieczywa z mąki o znanych parametrach jest możliwe. Uzyskane parametry otrzymanego po wypieku pieczywa obarczone są stosunkowo niewielkim błędem w porównaniu z parametrami uzyskanymi podczas wypieku laboratoryjnego, lecz możliwość szybkiego uzyskania parametrów gotowego produktu pozwala na stwierdzenie, iż zaproponowana metoda jest poprawna. Najlepsza architektura

sztucznej sieci neuronowej przedstawia się następująco: 5 wejść, 7 wyjść, 40 neuronów w warstwie ukrytej, funkcja aktywacji warstwy ukrytej – tangens hiperboliczny, funkcja aktywacji warstwy wyjściowej – liniowa.



Rys. 5. Zmiana błędu średniokwadratowego w procesie uczenia sieci po 20000 powtórzeniach jako funkcji liczby neuronów w warstwie ukrytej

Fig. 5. Mean square error change in network teaching process after 20000 repetitions as a function of the quantity of neurons in the hidden layer

Wnioski

1. Przeprowadzone badania potwierdzają słuszność podjętego rozwiązania formalizacji zapisu procesu wypieku chleba z użyciem SSN.
2. Na wejście sieci trzeba podać dane w postaci znormalizowanej $\langle 0, 1 \rangle$.
3. Wynik przetwarzania sieci trzeba poddać przeskalowaniu w zakresie $\langle 0, 1 \rangle$ do wartości rzeczywistych (proces odwrotny do normalizacji).
4. Optymalną architekturą sieci okazał się układ: 5 wejść, 7 wyjść i 40 neuronów w warstwie ukrytej. Funkcją aktywacji warstwy ukrytej był tangens hiperboliczny, a warstwy wyjściowej – funkcja liniowa.

Bibliografia

- Horubałowa A., Haber T.** 1994. Analiza techniczna w piekarstwie. Wydawnictwa Szkolne i Pedagogiczne. Warszawa. ISBN 83-02-02615-8.
- Drzazga B.** 1980. Analiza techniczna w przemyśle spożywczym. Wydawnictwa Szkolne i Pedagogiczne. Warszawa. ISBN 83-02-06665-6.
- Tadeusiewicz R., Gonciarz T., Borowik B., Leper B.** 2007. Odkrywanie właściwości sieci neuronowych przy użyciu programów w języku C#. Polska Akademia Umiejętności Kraków. ISBN 978-83-60183-53-3.
- Żurada J., Barski M., Jędruch W.** 1996. Sztuczne sieci neuronowe. Wydawnictwo Naukowe PWN. Warszawa. ISBN 83-01-12106-8.
- Osowski S.** 1996. Sieci neuronowe w ujęciu algorytmicznym. WNT Warszawa. ISBN 83-2-04-2197-7.

MODELLING OF FOOD-PROCESSING WITH THE USE OF ARTIFICIAL NEURAL NETWORKS

Abstract. Raw product used in the process has most significant impact on the quality of product. Preparation of raw products and processing itself may be treated as repeatable processes, however raw product consisting of biological material is characterised by high diversification occurring within the same variety. Therefore, measures have been taken in order to link qualitative properties of raw product with finished product. The ANN have been employed to carry out baking process modelling. The work presents an optimal artificial neural network architecture allowing to achieve a defined goal.

Key words: artificial neural networks, bread baking process, bread quality

Adres do korespondencji:

Jerzy Langman; rtlangma@cyf-kr.edu.pl
Katedra Inżynierii Mechanicznej i Agrofizyki
Uniwersytet Rolniczy w Krakowie
ul. Balicka 120
30-148 Kraków