

Wydział Inżynierii Produkcji
Szkoła Główna Gospodarstwa Wiejskiego



dr inż. Radosław Winiczenko

Modelowanie i optymalizacja wybranych procesów w przemyśle rolno-spożywczym z wykorzystaniem algorytmów genetycznych

Autoreferat przedstawiający opis dorobku i osiągnięć naukowych

Załącznik 2 do wniosku
o przeprowadzenie postępowania habilitacyjnego
(wersja polska)

Warszawa, 2018 r.

Spis treści

1. Imię i nazwisko.....	3
2. Posiadane stopnie naukowe i dyplomy.....	3
3. Informacja o dotychczasowym zatrudnieniu w jednostkach naukowych.....	3
4. Wskazania osiągnięcia naukowego wynikającego z art.16 ust. 2 ustawy z dnia 14.03. 2003 roku o stopniach naukowych i tytule naukowym oraz o stopniach i tytule w zakresie sztuki (Dz.U. z 2014r., poz.1852).....	3
4.1. Wykaz wybranego cyklu publikacji (autorzy, tytuły publikacji, nazwa czasopisma, nazwa wydawnictwa, rok wydania, wskaźnik Impact Factor w roku wydania oraz punktacja MNiSW).....	3
4.2. Omówienie celu naukowego cyklu publikacji.....	5
4.2.1 Wprowadzenie do modelowania i optymalizacji.....	5
4.2.2 Cel badań.....	9
4.3. Syntetyczne omówienie publikacji wchodzących w skład osiągnięcia naukowego.....	10
4.4. Podsumowanie.....	32
4.5. Literatura.....	33
5. Opis pozostałych osiągnięć naukowych.....	38
5.1 Przed doktoratem.....	38
5.2 Po doktoracie.....	39
6. Syntetyczna charakterystyka dorobku naukowego.....	41

1. Imię i nazwisko

Radosław Antoni Winiczenko

2. Posiadane stopnie naukowe i dyplomy z podaniem nazwy, miejsca i roku ich uzyskania oraz tytuł rozprawy naukowej

- **doktora:** dyscyplina naukowa: budowa i eksploatacja maszyn, Politechnika Warszawska, Wydziału Inżynierii Produkcji, 2002 r. „Struktura i właściwości żeliwa sferoidalnego zgrzanego tarciowo”.
- **magistra inżyniera:** kierunek mechanika i budowa maszyn, Uniwersytet Techniczno-Przyrodniczy, Wydział Mechaniczny, 1998 r. ”Oddziaływanie struktury żeliwa sferoidalnego na stan połączenia tego żeliwa ze stalą austenityczną w złączu zgrzanym tarciowo”
- świadectwo ukończenia studiów podyplomowych w zakresie zarządzania przedsiębiorstwem na wspólnym rynku europejskiej, Szkoła Główna Handlowa, Kolegium Gospodarki Światowej, 2000 r.

3. Informacja o dotychczasowym zatrudnieniu w jednostkach naukowych

asystent, Szkoły Główna Gospodarstwa Wiejskiego, Wydziału Inżynierii Produkcji, 2002-2003

adiunkt, Szkoła Główna Gospodarstwa Wiejskiego, Wydziału Inżynierii Produkcji, 2003-nadal

4. Wskazania osiągnięcia naukowego wynikającego z art.16 ust. 2 ustawy z dnia 14.03. 2003 roku o stopniach naukowych i tytule naukowym oraz o stopniach i tytule w zakresie sztuki (Dz.U. z 2014r., poz.1852)

Osiągnięciem naukowym będącym podstawą habilitacji jest cykl publikacji powiązanych tematycznie (siedem publikacji 1-7) pod wspólną nazwą:

„Modelowanie i optymalizacja wybranych procesów w przemyśle rolno-spożywczym z wykorzystaniem algorytmów genetycznych”.

4.1. Wykaz wybranego cyklu publikacji (autorzy, tytuły publikacji, nazwa czasopisma, nazwa wydawnictwa, rok wydania, wskaźnik Impact Factor w roku wydania publikacji oraz punktacja MNiSW)

1. Kaleta A., Górnicki K., **Winiczenko R**, Chojnacka A. Evaluation of drying models of apple (var. Ligol) dried in a fluidized bed dryer. **Energy Conversion and Management, Elsevier**, V. 67, 179-185, 2013. (IF—3,590, 45 pkt). Mój udział 30 %
2. Kaleta A, **Winiczenko R**, Górnicki K, Choińska A. Empirical modelling of dry matter of solid changes during the rehydration of dried apples pretreated by different methods before drying. **Ann. Warsaw Univ. of Life Sci-SGGW Agriculture** 63, 81-88, 2, 2014. (6 pkt MNiSW). Mój udział 30 %
3. **Winiczenko R**. Algorytmy genetyczne i ich zastosowania. **Postępy Techniki Przetwórstwa Spożywczego**, 107-110. 4, 2008. (4 pkt MNiSW). Mój udział 100 %
4. **Winiczenko R** chapter of "Optimization", Ed by Agnieszka Kaleta. Optimization of the apple drying and rehydration processes using evolutionary algorithms. **Warsaw University of Life Sciences Press**. 2014. (5 pkt MNiSW). Mój udział 90 %
5. **Winiczenko R**, Górnicki K, Kaleta A, Mańkowska-Janaszek M. Optimisation of ANN topology for predicting the rehydrated apple cubes colour change using RSM and GA. **Neural Computing and Applications, Springer**, 1-15, 2, 2016. (IF—2,505, 20 pkt). Mój udział 80 %
6. **Winiczenko R**, Górnicki K, Kaleta A, Martynenko A, Janaszek-Mańkowska M, Trajer J. Multi-objective optimization of convective drying of apple cubes. **Computers and Electronics in Agriculture, Elsevier**, 341–348, 2018. (IF—2,427, 40 pkt). Mój udział 60 %
7. **Winiczenko R**, Górnicki K, Kaleta A, Janaszek-Mańkowska M, Trajer J. Multi-objective optimization of the apple drying and rehydration processes parameters. **Emirates Journal of Food and Agriculture, College of Food and Agriculture, United Arab Emirates University**, 30 (1), 1-9, 2018. (IF—0,609, 20 pkt). Mój udział 60 %

Publikacje 1,5,6,7 to czasopisma z listy JCR, publikacje 2,3 to czasopisma z wykazu B MNiSW, publikacja 4, to wyodrębniony rozdział z monografii

Sumaryczny Impact Factor (dla cyklu publikacji w latach publikacji) wynosi $\sum \text{IF} = 9,131$.

Sumaryczna punktacja wg MNiSW (dla cyklu publikacji w latach publikacji) wynosi **140 pkt**.

Oświadczenie współautorów określające indywidualny wkład każdego z nich w powstanie publikacji zamieszczono w **Załączniku 4**.

4.2. Omówienie celu naukowego cyklu publikacji

4.2.1 Wprowadzenie do modelowania i optymalizacji

Na model matematyczny rozważanego zjawiska składają się zwykle równania wyrażające zależności (stwierdzone doświadczalnie) między wielkościami fizycznymi występującymi w badanym zjawisku. Pamiętać zawsze należy, iż model oraz oparte na nim przewidywanie zjawisk, czyli *modelowanie* zawsze opisuje rzeczywistość jedynie w sposób mniej lub bardziej przybliżony, przyjmując szereg założeń. Z tego względu wyniki uzyskane na podstawie danego modelu należy interpretować z dużą ostrożnością. Modelowanie matematyczne umożliwia rozwiązywanie problemów, których nie można zbadać doświadczalnie, gdyż są zbyt trudne, niebezpieczne, kosztowne lub też zbyt złożone do analizy teoretycznej (Żurek i Henrichs, 2007). Podstawowym zadaniem modelowania matematycznego jest symulacja złożonych zjawisk fizycznych występujących w danym środowisku. Odbywa się to poprzez rozwiązanie właściwego układu równań matematycznych, wyprowadzonych na podstawie konkretnego fizycznego modelu danego układu. Modelowanie matematyczne umożliwia przekształcenie modelu ciągłego, zazwyczaj opisanego np. układem równań różniczkowych zwyczajnych lub cząstkowych, w formę nieciągłą (dyskretną), którą można rozwiązać numerycznie, poprzez użycie stosownych algorytmów. Zasada modelowania polega na wykorzystaniu zestawu równań matematycznych, które mogą odpowiednio opisać daną operację (Winger, 1960).

Matematyczne modelowanie jest popularnym narzędziem badawczym wykorzystywanym do opisu przebiegu operacji technologicznych występujących w sektorze rolno-spożywczym (Falade i Solademi, 2010). Przykładem może być proces suszenia. W tym przypadku modelowanie matematyczne umożliwia prognozowanie szybkości suszenia i jego efektywności w różnych warunkach procesu. Dokładna predykcja może ustalić najlepszą jakość produktu finalnego, a także zmniejszyć czas jego wytwarzania (Colak i Hepbasli, 2009). Modele matematyczne zaproponowane do opisanego przebiegu suszenia produktów rolnych generalnie dzielą się na trzy kategorie, modele teoretyczne, pół-teoretyczne i empiryczne (Meziane, 2011).

Modele teoretyczne oparte są na ogólnej teorii wymiany masy i praw dotyczących wymiany ciepła. Zatem mogą wyjaśniać zjawiska występujące podczas suszenia. Z drugiej

strony, modele te są trudniejsze w stosowaniu niż pół-teoretyczne i modele empiryczne. Modele teoretyczne są czasochłonne i uwzględniają między innymi; współczynnik dyfuzji wilgoci, krytyczną zawartość wilgoci, geometrię cząstek oraz skurcz. Modele teoretyczne zostały wykorzystane do opisanie przebiegu procesu wielu suszonych produktów rolnych.

Przewagą modeli pół-teoretyczne i empirycznych w symulacjach procesu suszenia jest ich łatwość w użyciu, ale ich zastosowania są ograniczone i ważne tylko w zakresie warunków suszenia prowadzonych podczas eksperymentu (Meziane, 2011). Modele pół-teoretyczne są na ogół bezpośrednio wyprowadzane z ogólnego rozwiązania poprzez uproszczenie drugiego prawa Ficka. Modele empiryczne opisują bezpośrednią relację pomiędzy średnią zawartością wilgoci a czasem suszenia. Pomijają podstawy procesu suszenia, a ich parametry nie mają znaczenia fizycznego (Menges i Ertekin, 2006). Wśród tych modeli, model Lewisa (Newtona), model Page'a, zmodyfikowany model Page'a, model Hendersona i Pabisa, model logarytmiczny, model dwuczłonowy oraz dwuczłonowy model wykładniczy są najczęściej używane do modelowania procesu suszenia różnych produktów rolnych (Syahrul i inni., 2003, Jaros i Pabis, 2006, Zielińska i Markowski, 2007, Kaleta i Górnicki, 2010, Stakić i Urošević, 2011).

Opisane powyżej modele matematyczne są przydatne do przeprowadzenia procesu optymalizacji, której głównym celem jest zwiększanie efektywności procesu, aż do osiągnięcia pewnego optimum. Przy czym stosując procedury optymalizacyjne nie należy koncentrować się jedynie na osiągnięciu optimum. Bardzo istotna jest efektywność procesu poszukiwania. Nadrzędnym celem optymalizacji jest ulepszenie procesu, natomiast osiągnięcie optimum jest znacznie mniej ważne w przypadku systemów złożonych (Goldberg, 2003). Optymalizacja obejmuje zarówno studia ilościowe rozwiązań optymalnych jak i metody ich wyznaczania. Teoria optymalizacji zajmuje się tym jak opisać i osiągnąć najlepsze rozwiązanie, gdy wiemy już, jak mierzyć i zmieniać dobre i złe (Beightler i inni 1979).

W literaturze wyróżnia się konwencjonalne metody poszukiwania (analityczne, przeglądowe oraz losowe). Metody analityczne będące przedmiotem intensywnych studiów dzielą się na metody bezpośrednie i pośrednie. Celem metod pośrednich jest szukanie lokalnych ekstremów poprzez rozwiązywanie układów równań nieliniowych otrzymanych przez przyrównanie gradientu funkcji do zera. W przypadku funkcji gładkiej, określonej na obszarze otwartym, poszukiwanie potencjalnych maksimum możemy ograniczyć do zbioru punktów, dla których nachylenie stycznej do wykresu funkcji jest równe zero w każdym z

kierunków. Celem metod bezpośrednich jest znalezienie lokalnego maksimum poprzez „skakanie” na wykresie funkcji w kierunku wyznaczonym przez lokalny gradient. Aby dostać się na lokalny wierzchołek należy wspinać się po zboczu wzdłuż najbardziej stromej z możliwych dróg. Zastosowanie powyższych metod analitycznych jest uzależnione od istnienia pochodnych (tj. dobrze określonych kątów nachylenia).

Metody analityczne są przeznaczone głównie dla funkcji ciągłych. Tymczasem rzeczywisty świat optymalizacji jest jednak pełen nieciągłości i obszernych przestrzeni o skomplikowanej topologii, dlatego też analityczne metody pośrednie i bezpośrednie mają tutaj ograniczony charakter (Michalewicz, 1999).

Celem metod przeglądowych jest obliczanie funkcji celu poprzez przeglądanie po kolei wszystkich punktów przestrzeni. W tym przypadku mamy do czynienia ze skończoną przestrzenią poszukiwania lub jej dyskretnym odpowiednikiem przestrzeni nieskończonej. Przy czym w praktyce metoda enumeracyjna znalazła swoje zastosowanie w małych przestrzeniach poszukiwań. W dużych przestrzeniach poszukiwań metoda ta automatycznie staje się nieefektywna.

Z powodu licznych ograniczeń związanych z zastosowaniem wcześniej omawianych metod optymalizacyjnych, w ostatnim czasie dość dużą popularnością cieszą się algorytmy poszukiwania losowego. Przy czym błędzenie przypadkowe oraz inne metody losowe oparte na szukaniu i zapamiętywaniu najlepszego rozwiązania są często dyskwalifikowane pod względem efektywności.

Choć opisane tu metody tradycyjnej optymalizacji, a także ich warianty i kombinacje z powodzeniem są wykorzystywane w różnorodnych zastosowaniach, to jednak są uważane za metody mało odporne na złożone poszukiwania. Na przykład technika gradientowa daje dobre wyniki, ale w wąskiej klasie problemów przestaje jednak być efektywna poza tą klasą. Metody przeglądowe z kolei stają się nieefektywne w całym spektrum problemowym. Dowiedziono jednak teoretycznie i empirycznie, że *algorytmy genetyczne* stanowią „odporną” metodę poszukiwania w skomplikowanych przestrzeniach. Przez „odporność” tutaj należy rozumieć kompromis między efektywnością a skutecznością konieczną do przeżycia osobników w różnorodnych środowiskach (Michalewicz, 1999).

Wśród metod losowych na szczególną uwagę zasługują *algorytmy genetyczne*, będące przykładem procedury używającej wyboru losowego w poszukiwaniu najlepszego rozwiązania w zakodowanej przestrzeni poszukiwań. Metoda ta swoje działanie zawdzięcza

mechanizmom, które od lat występują się w przyrodzie. Algorytmy genetyczne są wolne od zasadniczych ograniczeń nakładanych przez mocne założenia o przestrzeni poszukiwań takich jak ciągłość, jednomodalność funkcji celu oraz istnienie pochodnych. Ponadto algorytmy genetyczne w odróżnieniu od tradycyjnych metod optymalizacji nie przetwarzają bezpośrednio parametrów zadania, lecz ich zakodowaną postać, bazują na populacji, korzystają jedynie z funkcji celu, stosują probabilistyczne, a nie deterministyczne reguły wyboru.

Optymalizacja procesów, jak również stosowanie algorytmów genetycznych nie jest tematem nowym. Obecnie algorytmy genetyczne są wykorzystywane głównie w programowaniu komputerów, w zagadnieniach optymalizacyjnych, prognozowaniu, klasyfikowaniu i automatycznym wnioskowaniu, rozpoznawaniu obrazów, sterowaniu, syntezie i optymalizacji układów (mechanicznych, elektronicznych), strategii gier, analizie danych (dopasowaniu, modelowaniu), zarządzaniu i inżynierii produkcji (Knosala, 2002, Cagnoni i inni., 2007). Często współpracują one z innymi metodami sztucznej inteligencji: sztucznymi sieciami neuronowymi (Gen i Cheng, 2000), systemami rozmytymi (Gen i inni, 2008) oraz coraz częściej eksploracji danych (Cox, 2005) tworząc z nimi hybrydowe metody obliczeniowe.

Algorytmy genetyczne mogą być doskonałym narzędziem optymalizacyjnym, które z powodzeniem może być zastosowane w przemyśle rolno-spożywczym. Zakłady produkcyjne w przemyśle spożywczym wyposażone są w liczne linie technologiczne do wytwarzania żywności. Maszyny i urządzenia, które stanowią elementy składowe tych linii produkcyjnych wymagają ciągłej optymalizacji. Optymalizacja może dotyczyć parametrów procesów technologicznych takich jak temperatura czy ciśnienie oraz parametrów procesu takich jak zapotrzebowanie mocy czy wydajność. Istnieje również duże zróżnicowanie w konstrukcjach i parametrach pracy tych maszyn i urządzeń, które wynika z różnorodności przetwarzanych surowców, wytwarzanych produktów i zmienności ich właściwości (Lenart, 2003).

W inżynierii rolniczej natomiast algorytmy ewolucyjne były stosowane sporadycznie zarówno w kraju jak i zagranicą. Autorzy w pracy (Morimoto inni., 1997) wykorzystali sztuczne sieci neuronowe i algorytmy genetyczne do kontroli procesu przechowywania owoców. Autorzy wskazali potrzebę zastosowania hybrydowego system służącego do doboru parametrów wejściowych (temperatury, gęstości) oraz wyjściowych (koloru, ubytku masy, twardości) w celu poprawienia jakości przechowywanych owoców. Zauważyli również,

że kompleksowy system sztucznych sieci neuronowych i algorytmów genetycznych ma przewagę nad tradycyjnymi technikami obliczeniowymi wykorzystywanymi w zagadnieniach związanych z rolnictwem. Wykorzystaniem algorytmów genetycznych i sztucznych sieci neuronowych zajmowali się również (Fang inni., 2005), przy czym algorytmy genetyczne zastosowali oni do uczenia sieci neuronowych.

4.2.2 Cel badań

Z powyższego przeglądu literatury wynika, że brak jest opracowań dotyczących optymalizacji procesów suszenia i rehydratacji z wykorzystaniem algorytmów genetycznych, brak jest również kompleksowego systemu, opisującego proces rehydratacji wraz ze zmianami wybranych cech produktów. Procesy suszenia, a następnie rehydratacji produktów rolniczych wiążą się z dużymi zmianami struktury, barwy, geometrii tych produktów. Parametry procesów suszenia i rehydratacji wpływają na wielkość tych zmian, wobec czego można poszukiwać takich parametrów prowadzenia tych procesów, przy których produkt finalny będzie charakteryzował się najmniejszymi zmianami w stosunku do produktu świeżego.

Celem podjęcia badań byłoby modelowanie i optymalizacja obu procesów ze względu na najmniejsze zmiany jakościowe uzyskanego końcowego produktu z wykorzystaniem zaawansowanych algorytmów genetycznych. Zastosowanie tych metod jest konieczne ze względu na złożoność postawionego zadania optymalizacyjnego.

Duża złożoność różnych operacji technologicznych występujących w przemyśle rolno-spożywczym plus poszerzona wiedza na temat ewolucyjnego działania mechanizmów tych algorytmów wskazuje na potrzebę *opracowania kompleksowego systemu do modelowania i optymalizacji* procesów suszenia i rehydratacji. Głównym elementem nowego podejścia byłoby stworzenie uniwersalnego narzędzia optymalizacyjnego, opartego głównie na sztucznej inteligencji. Stworzenie hybrydowej metody, która wykorzystywałaby doskonałe właściwości aproksymujące sztucznych sieci neuronowych oraz optymalizujące algorytmów genetycznych z uwzględnieniem optymalizacji wielokryterialnej było najlepszym rozwiązaniem.

4.3. Syntetyczne omówienie publikacji wchodzących w skład osiągnięcia naukowego

[Praca 1]

Celem pracy [1] było zbadanie procesu suszenia kinetyki jabłek odmiany *Ligol* w suszarce ze złożem fluidalnym oraz modelowanie procesu suszenia jabłka za pomocą modeli teoretycznych, pół-teoretycznych oraz empirycznych dostępnych w literaturze. W pracy określono także wpływ temperatury powietrza suszącego na parametry modeli procesu suszenia. Skurcz kostek jabłek podczas suszenia mierzono w celu oceny zmian jakościowych suszonych jabłek. Wykorzystane modele zostały przedstawione w Tabeli 1 w publikacji [1]. Dodatkowo trzy nowe modele empiryczne zostały opracowane przez autorów (rów. 1-3).

$$MR = a \exp(-kt^n) \quad (1)$$

$$MR = a \exp(-kt^n) + (1 - a) \exp(-gt^n) \quad (2)$$


$$MR = a \exp[-(kt)^n] + b \exp[-(gt)^n] \quad (3)$$

Opracowane modele są różnymi modyfikacjami modelu Page'a (równanie 4).

$$MR = \exp(-kt^n) \quad (4)$$

Modele zostały użyte do opisanie zachowania się suszu jabłek (odmiany *Ligol*) suszonego w suszarce ze złożem fluidalnym. Szczegółowe dane dotyczące użytego materiału i zrealizowanego eksperymentu przedstawiono w paragrafie 2 artykułu [1]. Przydatność nowych modeli do opisanie charakterystyki procesu suszenia została porównana z dokładnością szesnastu modeli dostępnych w literaturze. Dokładności modeli zostały zmierzone przy użyciu współczynnika korelacji (R), błędu średniej kwadratowej ($RMSE$) i zredukowanego chi-kwadrat (χ^2).

Rysunek 1 pokazuje, że im wyższa temperatura powietrza, tym krótszy jest czas suszenia, a wyższa szybkość suszenia. Krzywe suszenia w temperaturze 70 i 80°C są prawie zbieżne w czasie pod koniec procesu suszenia. Podobne relacje zauważono w przypadku suszenia plasterków jabłka (Vega-Gálvez i inni., 2008), plasterków banana (Nguyen i Price, 2007), plasterków marchwi (Prakash i inni., 2004), tort głogowy (Wang i inni., 2011), plastrów słodkich ziemniaków (Falade i Solademi, 2010) plastrów ziemniaczanych (Akpınar i inni., 2003) i kielków brązowego ryżu (Cheevitsopon i Noomhorm, 2011).



Rysunek.1. Zawartość wilgoci w czasie oraz prędkości suszenia z zawartością wilgoci dla kostek z jabłek suszonych w różnej temperaturach (—·—) 40 °C, (—·—) 50 °C, (— —) 60 °C, (— —) 70 °C i (—) 80 °C.

Rysunek 2 przedstawia dane eksperymentalne skurczu i wartości prognozowane według następującego równania liniowego:

$$\frac{V}{V_0} = 0,7701 \frac{M}{M_0} + 0,2343 \quad (R^2 = 0,9977) \quad (5)$$

gdzie V to objętość w m^3 ; V_0 to objętość początkowa w m^3 ; M to zawartość wody; M_0 to początkowa zawartość wody. Równanie liniowe jest bardzo często używane do opisu skurczu produktów rolnych. Z przeprowadzonego eksperymentu okazuje się, że temperatura nie ma wpływu na skurcz objętościowy kostek jabłka, co jest zgodne z opublikowanymi wynikami w literaturze (Rahman i Kumar, 2006, Ochoa i inni., 2007).



Rysunek. 2. Dane eksperymentalne skurczu kostek jabłek suszonych w różnych temperaturach powietrza i aproksymacja liniowa (równanie 5); (□) 40 °C, (■) 50 °C, (▲) 60 °C, (●) 70 °C and (◆) 80 °C.

Modele teoretyczne dają wyjaśnienie zjawisk zachodzących podczas procesu suszenia, ale są trudne w zastosowaniu w porównaniu do modeli pół-teoretycznych i empirycznych. Dlatego, jeśli jest potrzebny jedynie opis krzywych suszenia, to wtedy lepiej zastosować pół-teoretyczne i empiryczne modele. Taka potrzeba występuje zwłaszcza w praktyce.

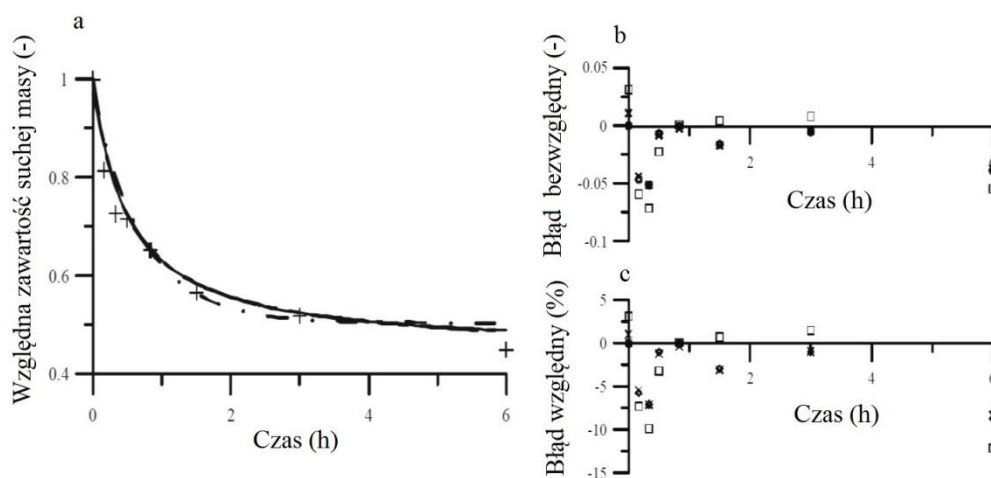
Trzy nowe opracowane modele opisane w równaniach 1-3 w wystarczający sposób opisały charakterystykę procesu suszenia kostek jabłek ($R > 0,997$). Model Page'a (równanie 4) i jeden z empirycznych modeli sformułowanych przez autorów tego badania model 1 można uznać za najbardziej odpowiedni ($R > 0,9977$, $RMSE = 0,0094-0,0167$, $\chi^2 = 0,0001-0,0002$). Wartości stałej szybkości suszenia k i współczynnika dyfuzji wilgoci wzrastały wraz ze wzrostem temperatury powietrza suszącego. Współczynnik dyfuzji wilgoci wahał się w zakresie od $2,01 \times 10^{-10}$ do $6,85 \times 10^{-10} \text{ m}^2/\text{s}$. Równanie liniowe skorelowano z danymi skurczu kostek jabłek. Temperatura suszenia nie miała wpływu na skurcz kostek z jabłek.

[Praca 2]

W pracy [2] przeprowadzono empiryczne modelowanie zmian masy suchej substancji w procesie rehydratacji suszonych jabłek poddanych różnym metodom obróbki wstępnej przed suszeniem. Badano pięć empirycznych modeli: Pelega, Pilosof-Boquet-Batholomai, Singh i Kulshrestha, Witrowej-Rajchert oraz Wesołowskiego, pod kątem ich przydatności do opisu zmian masy suchej substancji suszonych jabłek w procesie ich rehydratacji.

Materiałem badawczym były 10-milimetrowe plastry jabłek suszone w warunkach konwekcji wymuszonej (w temperaturze $60 \text{ }^\circ\text{C}$ i przy prędkości czynnika suszącego 2 m/s). Przed suszeniem krajanek jabłek poddawano następującym metodom obróbki wstępnej (w temperaturze $20 \text{ }^\circ\text{C}$): 10 min w soku jabłkowym, a następnie 10 min pod ciśnieniem pomniejszonym o $0,02 \text{ MPa}$, 30 min w 61,5 procentowym roztworze sacharozy, 120 min w 61,5 procentowym roztworze sacharozy. Proces rehydratacji prowadzono w wodzie destylowanej w $20, 45, 70$ i $95 \text{ }^\circ\text{C}$, soku jabłkowym w $20 \text{ }^\circ\text{C}$, 0,5-procentowym roztworze kwasu cytrynowego w $20 \text{ }^\circ\text{C}$. Miarą dokładności dopasowania danych otrzymanych z modeli do danych empirycznych były: pierwiastek błędu średniokwadratowego (RMSE), współczynnik determinacji (R^2) oraz zredukowany chi-kwadrat (χ^2).

Weryfikację rozważanych modeli empirycznych dla rehydratowanych plastrów jabłek pokazano na rysunku. 3.



Rysunek 3. Weryfikacja rozważanych modeli empirycznych dla rehydratowanych plastrów jabłek (obróbka wstępna przed suszeniem w 20 °C w soku jabłkowym przez 10 minut i następnie 10 min pod obniżonym ciśnieniem 0.02 MPa, suszone w suszarce konwekcyjnej w temperaturze 60 °C i prędkości czynnika suszącego 2 m/s) zanurzone w wodzie destylowanej w 20 °C: (a) względna zawartość suchej masy w funkcji czasu; (+) dane eksperymentalne, (—)model Pelega, (- - -) model Pilosof-Boquet-Batholomai, (- - -) model Singha i Kulshrestha, (- -) model Witrowej-Rajchert, (- • -) model Wesołowskiego, (b) błąd bezwzględny aproksymowanej krzywej rehydratacji; (o)model Pelega,(Δ) model Pilosofa-Boquet-Batholomai, (◇) model Singha i Kulshrestha, (x) model Witrowej-Rajchert, (□)model Wesołowskiego, (c) błąd względny aproksymowanej krzywej rehydratacji; (o)model Pelega,(Δ) model Pilosofa-Boquet-Batholomai, (◇) model Singha i Kulshrestha, (x) model Witrowej-Rajchert, (□)model Wesołowskiego.

Wszystkie badane modele empiryczne, oprócz modelu Wesołowskiego, można uznać za odpowiednie do opisu zmian masy suchej substancji w suszonych jabłkach w procesie ich rehydratacji ($RMSE = 0,022-0,199$, $R^2 = 0,808-0,934$, $\chi^2 = 0,001-0,046$). Badane metody obróbki wstępnej miały wpływ na wartość równowagowej masy suchej substancji, ale nie zaobserwowano wyraźnych tendencji.

Praca [3]

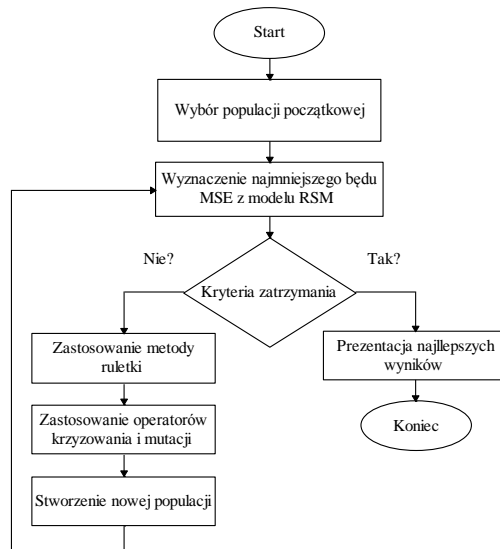
Celem pracy [3] było przedstawienie zasady działania algorytmów genetycznych, jako doskonałego narzędzia optymalizacyjnego, które z powodzeniem może być zastosowane w przemyśle rolno-spożywczym. W artykule tym przedstawiono ogólną zasadę działania algorytmów genetycznych i ich zastosowanie w wybranych gałęziach inżynierii produkcji.

Prostota działania algorytmów genetycznych i ich naturalność sprawiły, że stały się obiecującą metodą rozwiązań trudnych problemów technologicznych. Obecnie algorytmy genetyczne znalazły bardzo szerokie zastosowanie. Używane są one, bowiem w szeregowaniu zadań, modelowaniu finansowym, optymalizacji czy harmonogramowaniu (Zieliński, 2000). Algorytmy genetyczne zdobywają coraz szersze obszary zastosowań w środowiskach naukowych, inżynierskich i w kręgach biznesu. Przyczyna jest oczywista: algorytmy genetyczne stanowią nieskomplikowane, a przy tym potężne narzędzie poszukiwań lepszych rozwiązań.

Algorytmy genetyczne (z ang. Genetic Algorithms, GAs) stanowią (naśladując naturalną ewolucję) metodę rozwiązywania problemów, głównie zadań optymalizacyjnych. Cechuje je duża uniwersalność oraz prostota procedur przeszukiwań najlepszych rozwiązań metodą stochastyczną (Michalewicz, 1999). Algorytmy genetyczne są procedurami przeszukiwania opartymi na mechanizmach doboru naturalnego i dziedziczenia. Korzystają z ewolucyjnej zasady przeżycia osobników najlepiej przystosowanych stosując probabilistyczne, a nie deterministyczne reguły wyboru (Rutkowska i inni., 1999). Klasyczny algorytm genetyczny przebiega wg schematu przedstawionego na rysunku 4.

Na początku odbywa się losowy wybór osobników (chromosomów) do populacji początkowej. Chromosomy są reprezentowane przez ciągi binarne o określonej długości. Następnie dokonuje się oceny przystosowania osobnika w populacji na podstawie obliczonej funkcji przystosowania. Jeśli spełniony jest warunek końcowy (zatrzymania), następuje zapamiętanie najlepszego chromosomu. Jeśli nie, to następnym krokiem jest selekcja osobników. W selekcji osobników naśladuje się mechanizm przeżycia w naturze. Oczekujemy, że osobnik o najwyższym stopniu przystosowania uzyska liczne potomstwo, tj. pomnoży swój materiał genetyczny do następnego pokolenia. Natomiast osobniki o najniższym stopniu przystosowania powinny być wyeliminowane z procesu prokreacji. Najbardziej popularnymi

metodami selekcji są: metoda ruletki, turniejowa czy metoda rankingowa. Kolejnym ważnym etapem działania algorytmu genetycznego jest zastosowanie operatorów genetycznych.



Rysunek.4. Schemat działania klasycznego algorytmu genetycznego.

W klasycznym algorytmie genetycznym występują dwa podstawowe operatory genetyczne: operator krzyżowania oraz mutacji. Krzyżowanie polega na wymianie fragmentu genotypu pomiędzy dwoma osobnikami. Proces ten odbywa się z założonym wcześniej prawdopodobieństwem p_k . Mutacja polega na zmianie wartości pojedynczego genu na przeciwny z prawdopodobieństwem p_m . Osobniki (chromosomy) otrzymane w wyniku działania operatorów genetycznych wchodzi w skład nowej populacji, która automatycznie staje się populacją bieżącą dla danej iteracji. Dla każdej następnej iteracji oblicza się wartość funkcji przystosowania i sprawdza się warunek zatrzymania (rys. 4). Jeśli warunek zatrzymania nie jest spełniony dalej przechodzi się do selekcji i kolejnych etapów algorytmu. Jeśli warunek jest spełniony wyprowadza się wynik w postaci chromosomu o największej wartości funkcji przystosowania (Rutkowski, 2008).

Algorytmy genetyczne mogą również służyć do optymalizacji systemów sterujących procesami technologiczno-transportowymi. Duże znaczenie i udział w logistyce przemysłu rolno-spożywczego mają maszyny i urządzenia transportowe, które gwarantują przepływ masy towarowej przychodzącej i wychodzącej w obrębie wydziałów produkcyjnych i poszczególnych stanowisk. Istotną rolę odgrywa tu specjalistyczny transport żywca, zbóż,

mleka, owoców i warzyw, mięsa czy innych surowców, który wymaga wyposażenia w systemy sterujące procesami technologicznymi (Lenart, 2003). Systemy te mogą być wspomagane procedurami poszukiwania lepszych rozwiązań za pomocą metod sztucznej inteligencji.

Praca [4]

W rozdziale „Optimization” znajdującej się w monografii naukowej w pracy [4] rozwiązano problem zadania optymalizacyjnego procesów suszenia i rehydratacji za pomocą dwóch metod: metody powierzchni odpowiedzi RSM (z ang. Responce Surface Methodology) (RSM) oraz wielokryterialnego algorytmu genetycznego MOGA (z ang. Multi-objctive Genetic Algorithm). Zasadę działania tego algorytmu rozwinęto w pracy [7].

W zadaniu optymalizacyjnym przyjęto, że parametrami wpływającymi na jakość uzyskanego w procesach suszenia i rehydratacji produktu są podstawowe parametry tych procesów takie jak temperatura suszenia (T_d), prędkość powietrza suszącego (V) i temperatura rehydratacji (T_r). Przyjęto również, że jakość uzyskanego produktu jest określona za pomocą barwy, objętości, zawartości wody i zawartości suchej substancji, ponieważ celem prezentowanych wyników badań jest wskazanie możliwości wykorzystania algorytmów ewolucyjnych i zastosowanych narzędzi do optymalizacji omawianych procesów. Wskaźniki oceny jakościowej opisano w równaniach (7-21).

Zatem celem podjętego badania było zbadanie wpływu parametrów suszenia: (temperatura powietrza suszącego), (prędkość powietrza suszącego) i parametrów rehydratacji: (temperatura wody destylowanej) na jakość jabłek nawadnianych oraz optymalizacja tych parametrów w oparciu o jakość rehydratowanego produktu. Barwę, skurcz, zdolność pochłaniania wody (WAC), zdolność utrzymywania suchej masy (DHC) badano jako parametry jakościowe jabłek uwodnionych, stosując standardowe procedury omówione poniżej.

Barwa produktu spożywczego jest jednym z najważniejszych czynników jakościowych, który odgrywa znaczącą rolę w jego wyglądzie i akceptowalności. Różnicę barwy (ΔE_{94}) obliczono zgodnie ze wzorem sformułowanym przez Witt (2007)

$$\Delta E_{94} = \sqrt{\left(\frac{\Delta L^*}{K_L S_L}\right)^2 + \left(\frac{\Delta C^*}{K_C S_C}\right)^2 + \left(\frac{\Delta H^*}{K_H S_H}\right)^2} \quad (7)$$

where S_L S_C S_H oznaczają funkcje ważenia dostosowujące wewnętrzną nierównomierną strukturę CIEL^{*} a^{*} b^{*}, które mogą być uzyskana za pomocą równań (8)-(10)

$$S_L = 1 \quad (8)$$

$$S_C = 1 + 0.045 \cdot C^* \quad (9)$$

$$S_H = 1 + 0.015 \cdot C^* \quad (10)$$

K_L K_C K_H są współczynnikami parametrycznymi opisującymi wpływ zmiany od warunków odniesienia. Dla warunków odniesienia, wszystkie z nich są ustawione na 1 (CIE, 2004). Parametry ΔL^* , ΔC^* , ΔH^* oznaczają odpowiednio różnicę między badaną (T) i standardowa (S) próbką pod względem luminancji, nasycenia i barwy i mogą być obliczone według formuł (11)-(14)

$$\Delta L^* = L_T^* - L_S^* \quad (11)$$

$$\Delta C^* = C_T^* - C_S^* \quad (12)$$

$$\Delta H^* = 2\sqrt{C_T^* \cdot C_S^*} \cdot \sin\left(\frac{\Delta h^*}{2}\right) \quad (13)$$

- wskaźnik jakościowy (Sh) określano na podstawie zmian objętości próbek jabłek.

Sh obliczono jako

$$Sh = \frac{V_r}{V_{fm}} \quad (14)$$

gdzie V_{fm} i V_r oznaczają odpowiednio początkową objętością świeżego materiału (przed suszeniem) i końcową (po rehydratacji).

Lewicki (1998) wskazuje, że pewne wskaźniki (np. WAC, DHC i RA) są miarą procesów, jakie zachodzą podczas rehydratacji. Wskaźniki te, wyrażają wielkość uszkodzeń w tkance w wyniku suszenia.

- wskaźnik WAC (z ang. Water Absorption Capacity) określa stratę zdolności suszu do absorpcji wody spowodowana zmianami w materiale podczas suszenia. Im mniejsza jest jego wartość, tym większa jest strata.

$$WAC = \frac{M_r(100 - s_r) - M_d(100 - s_d)}{M_0(100 - s_0) - M_d(100 - s_d)} \quad (15)$$

gdzie M jest masą, s jest to zawartość suchej substancji (%), indeksy dolne d , 0 i r odnoszą się odpowiednio do suszu, produktu świeżego i rehydratu.

$$\text{przy czym } 0 \leq \text{WAC} \leq 1 \quad (16)$$

- wskaźnik DHC (z ang. Dry Matter Holding Capacity) określa rozmiar uszkodzeń tkanki materiału i zdolność materiału do utrzymywania suchej substancji. Im mniejsza jego wartość tym większe uszkodzenie tkanki materiału.

$$\text{DHC} = \frac{M_r s_r}{M_d s_d} \quad (17)$$

$$\text{przy czym } 0 \leq \text{DHC} \leq 1 \quad (18)$$

- wskaźnik RA (z ang. Rehydration Ability) jest miarą zdolności materiału do rehydratacji. Im mniejsza jego wartość tym większe uszkodzenie tkanki materiału podczas suszenia.

$$\text{RA} = \text{WAC} \cdot \text{DHC} \quad (19)$$

$$\text{przy czym } 0 \leq \text{RA} \leq 1 \quad (20)$$

Levi i in. (1988) zaproponował indeks DML (z ang. Dry Matter Loss), który wyraża utratę suchej substancji podczas rehydratacji. Został on obliczony na podstawie poniższej formuły.

$$\text{DML} = \frac{\text{sucha masa przed rehydratacją} - \text{sucha masa po rehydratacji}}{\text{sucha masa przed rehydratacją}} \quad (21)$$

Dodatkowo w pracy zastosowano modelowanie neuronowe zmian wybranych wskaźników jakościowych rehydratowanych jabłek, którego celem było określenie wpływu istotnych parametrów procesu suszenia i rehydratacji, które decydują o jakości produktu końcowego i umożliwią w tym zakresie optymalizację. W tym celu przyjęto założenia, że przedmiotem badań są jednakowe kostki jabłek (10 mm x 10 mm x 10 mm) suszone przy stałych parametrach procesu suszenia (temperatura i prędkość suszenia) oraz rehydratowane w stałych parametrach procesu rehydratacji (medium i temperatura). Zakres zmian obejmował temperaturę suszenia 50–70 °C, prędkość powietrza suszącego 0,01–6 m/s i temperaturę rehydratacji 20–95 °C.

Modele neuronowe pozwoliły na ocenę ważności wpływu zmiennych wejściowych (analiza wrażliwości) i przeprowadzenie symulacji w celu wyznaczenia bardziej szczegółowych wyników potrzebnych do optymalizacji. Wykonano po 125 symulacji dla każdej zmiennej wyjściowej przy następujących zmiennościach temperatury suszenia: 50, 55,

60, 65 i 70 °C, prędkości suszenia: 0.01, 1.5, 3, 4.5 i 6 m/s oraz temperatury rehydratacji 20, 40, 60, 80, and 90 °C.

Nie udało się opracować zadowalającego modelu neuronowego, opisującego zmiany zawartości suchej substancji – wskaźnik DHC. DHC nie został zatem dalej wykorzystany w zadaniu optymalizacyjnym. Dalsze badania będą miały na celu opracowanie takiego neuronowego modelu DHC, który byłby zadowalający. Być może należałoby dodatkowo uzależnić wskaźnik DHC od innych (oprócz T_r , T_d i V) parametrów procesów suszenia i rehydratacji. Autorzy przewidują również badanie neuronowych modeli opisujących zmiany suchej substancji, opisane innym parametrem niż DHC w kolejnych publikacjach. Wyniki uzyskane z utworzonych sieci neuronowych posłużyły do zbudowania matematycznych modeli wybranych cech jakościowych jabłek, które następnie wykorzystano w celach optymalizacyjnych.

Metoda RSM jest wykorzystywana do opisu zmiany barwy surowców roślinnych pod wpływem procesu suszenia. Metoda powierzchni odpowiedzi została zaproponowana przez Boxa i Wilsona w (1951) roku. Jest to jedna z częściej stosowanych metod metamodelowania, wykorzystywanych do rozwiązywania problemów wielokryterialnych. Metoda powierzchni odpowiedzi pozwala znaleźć związek między jedną lub kilkoma wartościami wejściowymi i wyjściowymi. Pozwala ona na uzyskanie statystycznie akceptowalnych wyników przy ograniczonej liczbie eksperymentów (Box i inni., 2005).

W wielu zadaniach coraz częściej mamy do czynienia z wieloma kryteriami jednocześnie. W takich przypadkach mówimy, że jest to problem optymalizacji wielokryterialnej lub polioptymalizacji. Zagadnienia te są od dawna przedmiotem zainteresowania badaczy stosujących tradycyjne techniki optymalizacji i poszukiwania. Jedną z metod klasycznych stanowi metoda ważonych celów, w której poszczególne funkcje celów łączy się w jedną funkcję celu F

$$F(x) = \sum_{i=1}^k (w_i f_i(x)) \quad (22)$$

gdzie wagi $w_i \in [0,1]$ i $\sum_{i=1}^k (w_i = 1)$. Inne wektory wag dają inne rozwiązania *paretooptymalne*.

W przypadku optymalizacji wielokryterialnej pojęcie rozwiązania optymalnego nie jest tak oczywiste jak w przypadku jednego kryterium. Jeżeli z góry nie zgadzamy się porównać ze sobą wartości różnych kryteriów (powiedzmy, jabłek i gruszek), to musimy

zapropionować taką definicję optymalności, która respektuje integralność każdego z nich. Takie podejście nosi nazwę optymalności w *sensie Pareto*. Wygodnie jest sklasyfikować możliwe rozwiązania zadań optymalizacji wielokryterialnej, jako rozwiązania zdominowane i niezdominowane (paretooptymalne). Rozwiązanie x jest zdominowane, jeśli istnieje dopuszczalne rozwiązanie y nie gorsze od x we wszystkich współrzędnych, tzn. dla wszystkich celów, f_i ($i=1, \dots, k$) lub $f_i(x) \leq f_i(y)$ dla wszystkich $1 \leq i \leq k$ – dla maksymalizowanych celów. Jeśli rozwiązanie nie jest zdominowane przez żadne inne rozwiązanie dopuszczalne, nazywane jest rozwiązaniem niezdominowanym (paretooptymalnym). Wszystkie paraoptymalne rozwiązania mogą być ważne (Michalewicz, 1999).

Metodę powierzchni odpowiedzi RSM oraz metodą wielokryterialnego algorytmu genetycznego MOGA opisano szczegółowo w pracy [7]. Cel i zakres optymalizacji przedstawiono w Tabeli 1.

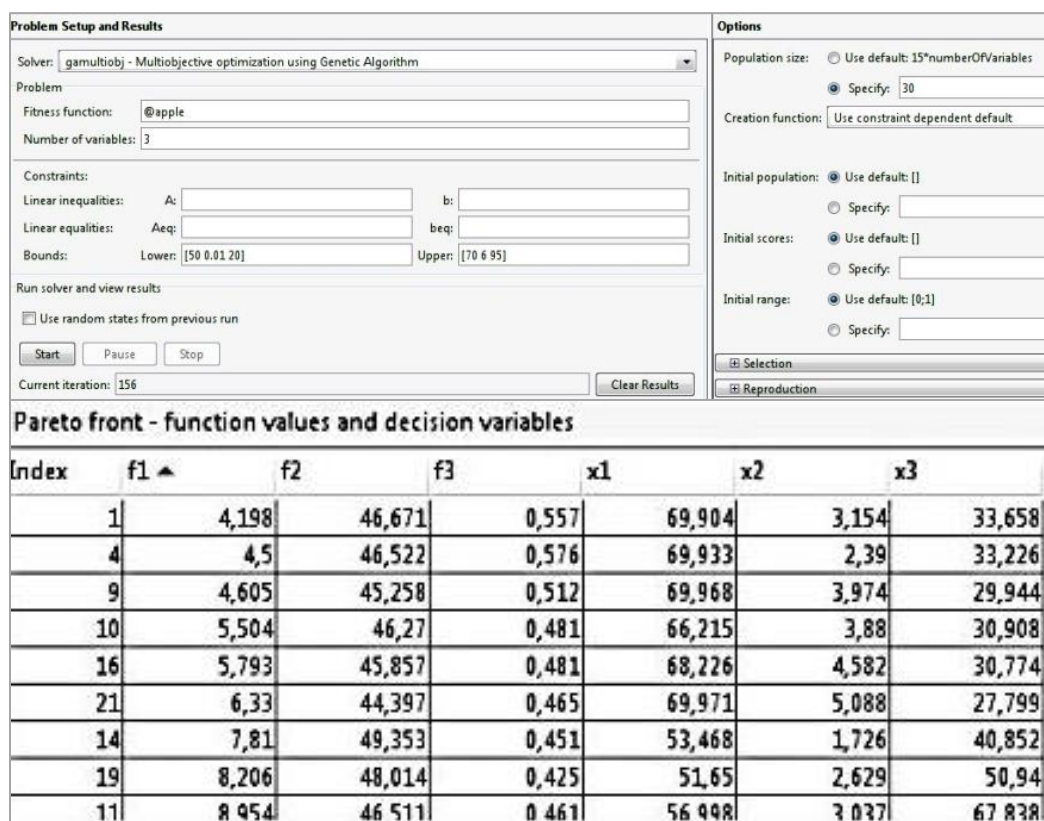
Optymalne wartości zmiennych procesowych, metodą RSM z wykorzystaniem oprogramowania Design Expert, wyniosły: 65 °C dla temperatury suszenia, 2,8 m/s dla prędkości powietrza suszącego oraz 52 °C dla temperatury rehydratacji. Przewidywane wartości zmiany barwy, Sh i WAC dla suszonych jabłek, a następnie w tych warunkach ponownie uwodnionych wyniosły odpowiednio 5,97, 50,68 % i 0,58.

Tabela. 1 Kryteria optymalizacji dla różnych czynników i odpowiedzi

Czynniki i odpowiedzi	Cel i ograniczenia	dolne	górne
Temperatura suszenia, °C	w zakresie	50	70
Prędkość suszenia, m/s	w zakresie	0.01	6
Temperatura rehydratacji, °C	w zakresie	20	95
Zmiana barwy, ΔE_{94}	Minimalizacja	4	28
Sh, %	Maksymalizacja	29	54
WAC	Maksymalizacja	0.2	0.7

Wykresy powierzchni odpowiedzi przedstawiające wpływ poszczególnych parametrów suszenia i rehydratacji, na jakość jabłek nawadnianych przedstawiono na rysunkach 6,7, 6,8 i 6,9 na końcu monografii [4].

Rysunek 5 przedstawia wyniki z optymalizacji przeprowadzonej za pomocą algorytmu wielokryterialnego MOGA odpowiednio ustawionych od najmniejszej do największej wartości ΔE_{94} (kolumna oznaczona jako f1). W kolumnach f2 i f3 przedstawiono wyniki dla skurczu oraz WAC. Kolumny x1, x2 oraz x3 oznaczają odpowiednio: temperaturę suszenia, prędkość suszenia oraz temperaturę rehydratacji.



Rysunek. 5. Wyniki optymalizacji za pomocą wielokryterialnego algorytmu genetycznego MOGA.

Wyniki optymalizacji procesów suszenia i rehydratacji uzyskane przy użyciu dwóch metod: RMS i MOGA są porównywalne. Najkorzystniejszym wariantem jest suszenie jabłek w temperaturze: 65–70°C, przy prędkości czynnika suszącego 2,8–3,1 m/s, natomiast optymalną temperaturą rehydratacji suszu z jabłek w wodzie jest 34–52 °C.

Uzyskane w wyniku optymalizacji temperatury suszenia są powszechnie używane w suszarnictwie, natomiast prędkości powietrza suszącego wskazują, że proces suszenia trudno byłoby prowadzić zarówno w standardowej suszarce tunelowej (zbyt duża prędkość czynnika suszącego), jak i fluidyzacyjnej (zbyt mała prędkość). Obecnie konstruuje się suszarki, w

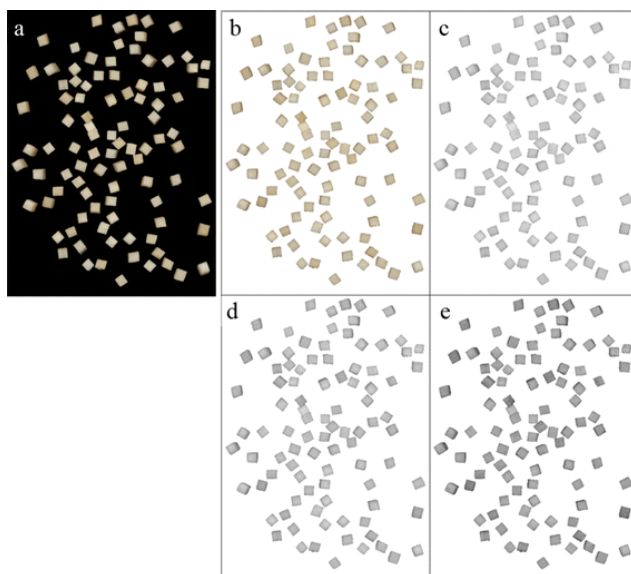
których w celu zwiększenia ich wydajności (zwiększania szybkości suszenia – intensywności wymiany masy) stosuje się wysokie wartości prędkości suszącego czynnika. Uzyskana wartość temperatury rehydratacji wskazuje, że do procesu rehydratacji należy wodę podgrzać, co wiąże się z nakładami energetycznymi, lecz powoduje to jednocześnie, że proces będzie trwał krócej, a produkt (rehydrat) uzyska się szybciej w porównaniu z rehydratacją w temperaturze pokojowej (ok. 20 °C).

Prezentowany przykład optymalizacji stanowi pierwszy etap badań. Prace nad optymalizacją procesów suszenia i rehydratacji były kontynuowane w kolejnych artykułach naukowych [5-7].

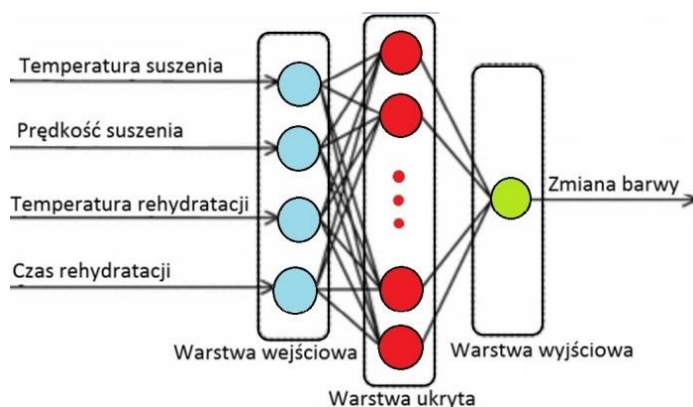
Praca [5]

W pracy [5] opracowano efektywną metodę optymalizacji będącą kombinacją metody powierzchni odpowiedzi (RSM) i algorytmu genetycznego (GA) w celu znalezienia optymalnej topologii sztucznych sieci neuronowych (SSN). Metoda ta została użyta do przewidywania zmiany barwy w uwodnionych kostkach z jabłek przedstawionych na rysunku 6. Wyznaczenie najlepszej topologii sieci neuronowej do prognozowania zmiany barwy było zwykle poddawane metodą prób i błędów, co jest procedurą bardzo czasochłonną, na co zwrócono uwagę we wcześniejszej pracy [4]. Optymalizacja parametrów sieci neuronowej wymaga konstruowania dużej liczby różnych topologii, które muszą być następnie trenowane i testowane. Jednak przy wyborze nie ma generalnej zasady doboru wartości zmiennych do budowania sieci neuronowych. Również zależy to od złożoności modelowanego systemu.

W omawianej pracy opracowano wielowarstwowy model SSN wstecznej propagacji błędów o jednej zmiennej wyjściowej (zmiana barwy) oraz z czterema zmiennymi wejściowymi (temperatura powietrza suszącego, prędkość suszenia, temperatura wody destylowanej i czas rehydratacji). Schemat optymalizowanej architektury sieci neuronowej pokazano na rysunku 7.

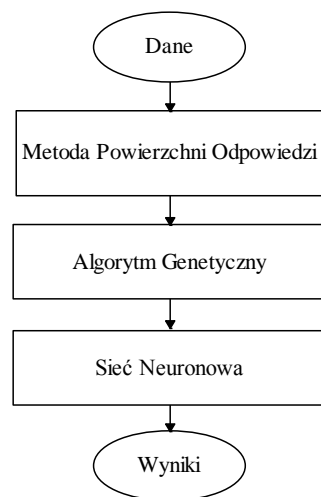


Rysunek.6. Oryginalny obraz cyfrowy surowych jabłek - a, b-wstępnie przetworzony obraz wyodrębniony z tła obrazu i podzielony na kanały c-R, d-G, e-B.



Rysunek. 7. Schemat architektury sieci neuronowej.

Model predykcyjny dla topologii SSN w warunkach działania najlepszego średniego błędu kwadratowego (MSE) na próbkach walidacyjnych utworzono za pomocą metody RSM. Do znalezienia optymalnej topologii sieci SSN model RSM został połączony z efektywnym algorytmem genetycznym. Schemat blokowy działania symulowanego procesu przedstawiono na rysunku 8.



Rysunek.8. Schemat blokowy hybrydowego inteligentnego procesu

Zaproponowany hybrydowy system RSM-GA-SN został krótko opisany poniżej. Ten system obejmuje następujące kroki:

Krok 1 - Zbieranie danych

Krok 2 - Projektowanie eksperymentu i opracowanie funkcji celu za pomocą RSM

Krok 3 - Optymalizacja architektury sieci neuronowej za pomocą AG

Krok 4 - Prognozowanie zmiany barwy za pomocą SN

Krok 5 - Przedstawienie wyników

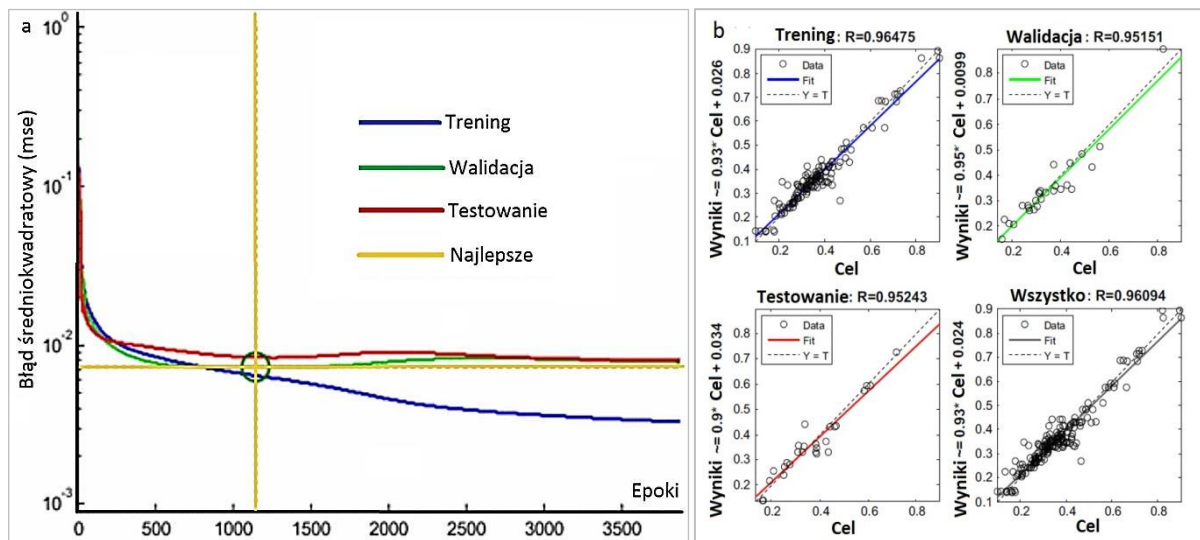
W procesie uczenia sieci neuronowej parametry wejściowe takie jak liczba neuronów w warstwie ukrytej (x_1), współczynnik uczenia (x_2), liczba epok (x_3), stała momentu (x_4) oraz liczba przebiegów (x_5) były kluczowymi parametrami, które mogą wpływać na efektywność symulacji sieci neuronowej. Zakres tych zmiennych wejściowych w optymalizowanym modelu przedstawiono w tabeli 2. Zmienne wejściowe zostały szczegółowo omówione w pracy [A5].

Tabela 2. Zakres zmiennych do uczenia sieci neuronowych

Parametry uczenia	Dolna	Górna
x_1 : Liczba neuronów	2	16
x_2 : Współczynnik uczenia	0.01	0.4
x_3 : Liczba epok	300	5000
x_4 : Stała momentu	0.1	0.9
x_5 : Liczba przebiegów	3	7

Optymalna sieć neuronowa osiągnęła najmniejszy błąd MSE, kiedy liczba neuronów ukrytych, współczynnik uczenia, stała momentu, liczba epok i liczba treningów wyniosły odpowiednio: 13, 0,33, 0,89, 3869 i 3. MSE optymalnej topologii sieci neuronowej na

próbek walidacyjnych wyniósł 0,0072095 (rys. 9a). Okazało się, że optymalną topologię sieci można uznać za bardzo dokładną w prognozowaniu zmiany barwy w uwodnionych kostkach z jabłek. Średni błąd bezwzględny (MAE) i współczynnik regresji (R) dla optymalnej topologii SSN wyniosły odpowiednio 0,0259 i 0,96475 dla zbioru trenującego, 0,0399 i 0,95243 dla testującego i 0,0264 i 0,95151 dla zbioru walidacyjnego (rys. 9b). Wyniki modelu testowane na nowych próbkach, dla których uzyskano doskonałą zgodność między danymi eksperymentalnymi a prognozowanymi ze współczynnikiem $R^2 = 0,97$.



Rysunek.9. Wyniki współczynnika determinacji R dla poszczególnych zbiorów (trenującego, testującego i walidacyjnego) zoptymalizowanej sieci neuronowej.

W pracy zaproponowano wydajne, hybrydowe inteligentne narzędzie do znalezienia optymalnej topologii sieci neuronowych. Optymalna topologia sieci neuronowej była bardzo efektywna do prognozowania zmiany barwy w uwodnionych kostkach z jabłek. Udoskonalona metoda optymalizacji znacznie redukuje liczbę wykonywania eksperymentów w porównaniu do bardziej kosztownych metod uczenia.

Praca [6]

Celem pracy [6] było opracowanie i weryfikacja nowatorskiego podejścia do optymalizacji wielokryterialnej (MOO), opartego na modelowaniu neuronowym parametrów jakościowych produktów i zaawansowanego algorytmu genetycznego (NSGA II) w celu wyznaczenia optymalnego w sensie *Pareto* zakresu warunków procesu suszenia, wymaganych dla uzyskania wysokiej jakości suszonych kostek z jabłek. Jest to nowatorskie podejście w optymalizacji wielokryterialnej. W większości prac autorzy (Erbay i Icier, 2009, Sturm i inni., 2012, Gupta i inni., 2013, Aghilinategh i inni., 2015) do optymalizacji wielokryterialnej procesu suszenia, autorzy używali tylko metodę powierzchni odpowiedzi (RSM).

Kluczową kwestią związaną z suszeniem jest właściwy dobór parametrów procesu w celu uzyskania akceptowalnej jakości produktu końcowego (Jokiniemi i Ahokas, 2014). Dlatego optymalizacja warunków suszenia jest konieczna, aby zachować najlepsze cechy surowca. Większość badań optymalizacyjnych w inżynierii żywności odnosi się do optymalizacji jednokryterialnej z wykorzystaniem metody powierzchni odpowiedzi (Yazgi i Degirmencioglu, 2007, Balasubramani i inni., 2013, Rouissi i inni., 2013). Metoda RSM została z uznaniem przyjęta, jako skuteczne narzędzie do optymalizacji parametrów suszenia. Optymalizacja wielokryterialna była rzadko wdrażana w przemyśle spożywczym, prawdopodobnie ze względu na matematyczną złożoność (Abakarov i inni., 2009). Tylko nieliczni badacze proponowali wielokryterialną analizę procesów żywieniowych, takich jak suszenie (Nazghelichi i inni., 2011), przetwarzanie termiczne (Sendín i inni., 2010), lub pieczenie (Hadiyanto i inni., 2009, Goñi i Salvadori, 2012). Jedno z pierwszych badań MOO w zakresie optymalizacji schematu przepływu w wielostronnym systemie wyparnym zostało opublikowane w pracy Nishitani i Kunugita (1979). Inne interesujące zastosowanie MOO dla parownika opisano w pracy Sharma i inni., (2012).

Suszenie konwekcyjne nadal pozostaje najczęstszą metodą konserwacji żywności, ponieważ jest najbardziej wydajną i najtańszą. Dlatego rozsądne jest poszukiwanie narzędzi lub metod do optymalizacji procesu suszenia, aby zapewnić produktom odwodnionym wysoką jakość, szczególnie tym, którym poddawane są procesowi rehydratacji.

W pracy tej z powodzeniem zastosowano wielokryterialną optymalizację dla suszonych kostek z jabłek przy jednoczesnej minimalizacji zmiany barwy (CD), maksymalizacji

stosunku objętościowego (VR) i zdolności pochłaniania wody (WAC), przy czym różnica barwy była określana według równania Shanada, (2007).

Funkcje celu wykorzystywane przez algorytm wielokryterialny MOO powinny opisać związki pomiędzy zmiennymi procesowymi temperaturą (T) i prędkością suszenia (v) a parametrami jakościowymi CD, VR i WAC suchego materiału. Ponieważ analityczne formy tych zależności nie są znane, zostały one aproksymowane za pomocą sztucznej sieci neuronowej (rys. 10) i przedstawione w postaci matematycznej w równaniach (23-25)

$$CD = 1.28 \cdot F_1 + 2.32 \cdot F_2 - 0.36 F_3 + 0.15 \cdot F_4 + 0.06 \cdot F_5 + 0.49 \quad (23)$$

$$VR = -0.09 \cdot F_1 - 0.42 \cdot F_2 + 0.06 \cdot F_3 - 0.14 \cdot F_4 - 0.22 \cdot F_5 + 0.98 \quad (24)$$

$$WAC = -0.23 \cdot F_1 - 0.32 \cdot F_2 + 0.086 \cdot F_3 - 0.09 \cdot F_4 - 0.08 \cdot F_5 + 0.82 \quad (25)$$

gdzie $F_{(i=1,2,3,4,5)}$ to parametry wyliczone:

$$F_i = (1 + \exp(-W_i))^{-1} \quad (26)$$

gdzie $W_{(i=1,2,3,4,5)}$ to parametry wyznaczone jako suma wag sieci neuronowej:


$$W_i = D_{1i}T + D_{2i}v + D_{3i} \quad (27)$$

Wagi i biasy D_{ji} dla suszonych kostek z jabłek stosowane w równaniu (27) podana w Tabeli 3. Funkcje celu, określone w równaniach (23-25), były używane do optymalizacji wielokryterialnej.

Tabela 3. Wagi i biasy dla suszonych kostek z jabłek

i	D_{1i}	D_{2i}	D_{3i}
1	6.86	11.98	-18.89
2	-1.82	-14.33	-0.35
3	43.34	-1.44	-36.95
4	43.08	0.68	-34.09
5	-43.17	-0.71	30.86

Trzy warstwowa sieć neuronowa, której topologię pokazano na rysunku 10 jest doskonałym aproksymatorem (Cybenko, 1989). Zadanie SNN polegało na odwzorowaniu dwóch zmiennych wejściowych (T i v) na trzy wyjścia (CD, VR i WAC) w celu uzyskania współczynnika wysokiej korelacji (R), najniższego błędu średniokwadratowego (MSE).



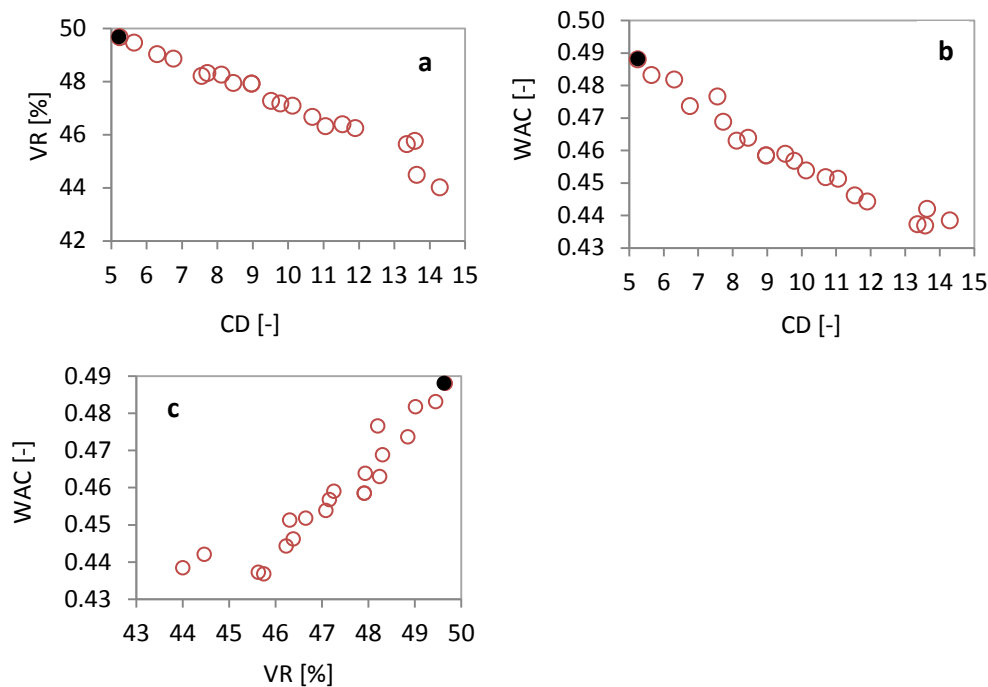
Rys.10. Architektura sieci neuronowej.

Wyniki walidacji modelu przedstawiono w tabeli 4 w pracy [6]. Walidację przeprowadzono przy użyciu tego samego zestawu doświadczalnego, aby wykazać wiarygodność oczekiwanych wartości. W tych samych warunkach suszenia tj. $T=65\text{ }^{\circ}\text{C}$ i $v=1,0\text{ m/s}$ wartości CD , VR i WAC wyznaczone eksperymentalnie odpowiednio wyniosły 5,41, 51,1 % i 0,48, co jest bardzo zbliżone do wartości prognozowanych (5,24, 49,66 % i 0,49). Maksymalny błąd bezwzględny uzyskany w procesie walidacji wyniósł 3,24 %, co oznacza wysoką dokładność proponowanego modelu.

W pracy stwierdzono, że zależności między zmiennymi procesowymi a cechami jakościowymi kostek jabłek są nieliniowe, a sieć neuronowa z funkcją sigmoidalną jest wystarczającą, do prognozowania jakości wysuszonych kostek z jabłek.

Opracowano nowatorską metodę do optymalizacji wielokryterialnej, opartą na sztucznej sieci neuronowej, algorytmie genetycznym i optymalizacji w sensie *Pareto*. Zestaw optymalnych rozwiązań *Pareto* został opracowany przy pomocy elitarnego algorytmu genetycznego (NSGA II). Optymalne rozwiązanie w sensie *Pareto* dla określonych warunków osiągnięto w temperaturze powietrza 65°C i prędkości suszenia $1,0\text{ m/s}$, dla których wskaźniki jakościowe odpowiednio wyniosły: $CD=5,24$, $VR=49$, oraz $WAC=66\%$ (rys. 11).

Najlepsze rozwiązanie zaobserwowano w przypadku każdej kombinacji parametrów jakościowych, tj. pomiędzy CD i VR (rys. 11a), CD i WAC (rys. 11b) i VR i WAC (rys. 11c). Jak można zauważyć na rysunku 11a i b, następuje zmniejszanie parametrów VR i WAC podczas wzrostu CD . Natomiast na rys. 11c zaobserwowano zwiększanie WAC przy zwiększeniu VR . Ponadto nie zaobserwowano konfliktu funkcji celu.



Rysunek.11. Dwuwymiarowe obrazy w sensie *Pareto*, (●) oznaczają najlepsze rozwiązanie.

Parametry procesu suszenia jabłek, uzyskane w wyniku optymalizacji tego procesu, mogą być zalecane do zastosowań przemysłowych. Zastosowanie temperatur w zakresie (61–65°C) i prędkości powietrza (0,7-1,8 m/s) w procesie suszenia jabłek pozwala uzyskać produkt o wysokiej jakości.

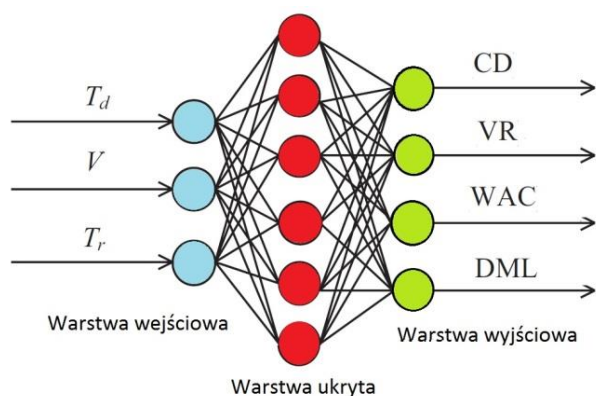
Praca [7]

Celem pracy [7] było zbadanie wpływu parametrów suszenia i rehydratacji na jakość uwodnionych jabłek oraz optymalizację tych parametrów w oparciu o jakość produktów nawadnianych. Większość badań optymalizacyjnych w inżynierii spożywczej odnosi się do optymalizacji jednokryterialnej. Tylko nieliczni autorzy stosowali strategie wielokryterialne w takich procesach spożywczych, jak: suszenie (Olmos i inni., 2002; Shahraki i inni., 2014), obróbka cieplna (Chen i Ramaswamy, 2002; Sendín i inni., 2010), pieczenie (Hadiyanto i inni., 2009, Białobrzewski i inni., 2009; Goni i Salvadori, 2012), smażenie (Amiryousefi i inni.,

2014). W przeanalizowanych dotychczas publikacjach nie było prac dotyczących optymalizacji procesów suszenia i rehydratacji przy użyciu algorytmu genetycznego.

Do modelowania, symulacji i optymalizacji procesów suszenia i rehydratacji została z powodzeniem opracowana hybrydowa metoda składająca się ze sztucznej sieci neuronowej (SNN) i wielokryterialnego algorytmu genetycznego (MOGA) opisanego szczegółowo w pracy [8]. Metodę tę zastosowano do tkanki jabłkowej, w której uwzględniono jednoczesną maksymalizację stosunku objętościowego (VR) i zdolności pochłaniania wody (WAC), minimalizację zmian barwy (CD) i utraty suchej masy (DML).

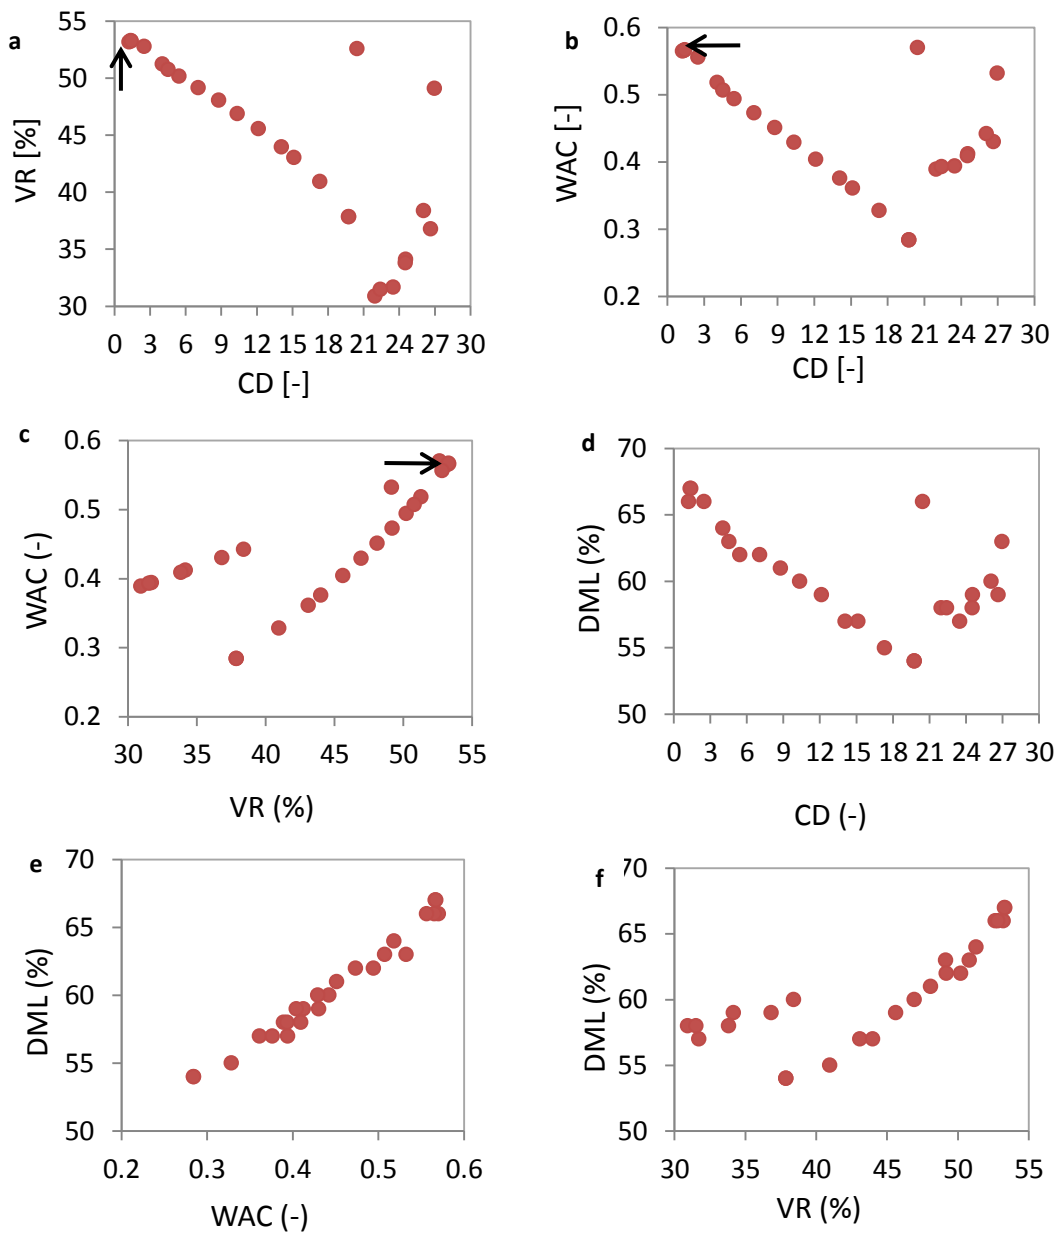
Optymalna architektura sieci neuronowej została zbudowana jako 3-6-4 z funkcjami aktywacji w warstwie ukrytej i wyjściowej "logsig" (rys. 12). Oprogramowanie MATLAB zostało zastosowane na wszystkich etapach uczenia i testowanie modelu neuronowego. SSN została uczona algorytmem Levenberga-Marquardta.



Rysunek. 12. Trzy warstwowa sieć neuronowa.

Zakres parametrów suszenia i rehydratacji wynosił odpowiednio: 50-70 °C (temperatura suszenia, T_d), 0,01-6 m/s (prędkość powietrza suszącego, V) i 20-95 °C (temperatura rehydratacji, T_r). Dodatkowo w pracy [7] opracowano wzory matematyczne do wyznaczania parametrów jakościowych uwodnionego jabłka.

Najlepsze rozwiązanie znaleziono tylko dla wskaźników: CD , VR i WAC ($T_d=50,1^\circ\text{C}$, $V=0,03$ m/s oraz $T_r=67,5$ °C), dla których wartości CD , VR i WAC odpowiednio wyniosły: 1,20, 53,2% i 0,57. Zestaw *Pareto* jest prezentowany w procesie oddzielnie, aby pokazać niezdominowane punkty tworzące dwuwymiarowy front w sensie *Pareto* (rys. 13).



Rysunek. 13. Dwuwymiarowe zestawy rozwiązań w sensie *Pareto*, pomiędzy a-VR i CD, b-AC i CD, c-WAC i VR, d-DML i CD, e-DML i WAC oraz f-DML i VR, (\rightarrow) oznacza najlepsze rozwiązanie.

Najlepsze rozwiązanie (oznaczone strzałkami) istnieje tylko pomiędzy CD i VR (rys. 13a), CD i WAC (rys. 13b) oraz VR i WAC (rys. 13c). Dla tych rysunków (biorąc pod uwagę najmniejszą wartość CD) optymalne wartości parametrów, uzyskane przez algorytm MOGA wyniosły: 50,1 °C dla temperatury suszenia, 0,03 m/s dla prędkości suszenia i 67,3 °C dla

temperatury nawodnienia. Dla suszonego jabłka i następnie ponownie uwodnionego w tych warunkach, wartości CD, VR i WAC odpowiednio wyniosły 1,34, 53,2 % i 0,57 (patrz ID = 1 w Tabeli 2 w pracy [7]). Nie znaleziono optymalnego zestawu punktu rozwiązania w sensie *Pareto*, w którym wszystkie rozważane funkcje (minimalne CD i DML oraz maksymalne VR i WAC) jednocześnie osiągnęłyby wartości optymalne. Taka sytuacja dotyczy głównie wskaźnika DML. Poprawa wskaźnika DML, powoduje pogorszenie drugiego parametru jakości (rys. 13d-f). Parametr ten pozostaje w stałym w konflikcie z pozostałymi. W takim przypadku rozwiązaniem jest utworzony przez zestaw niezdominowanych rozwiązań w sensie *Pareto*, gdzie wybór jednego rozwiązania nad drugim zależy od wymagań stawianych inżynierowi procesu a odpowiednia kombinacja zmiennych może być wybrana z rozwiązania *Pareto* zgodnie z jego preferencjami.

4.4. Podsumowanie

Modelowanie oraz nowatorskie podejście do rozwiązania zadań w inżynierii rolniczej o problematyce złożonej, oparto głównie na zaawansowanej optymalizacji wielokryterialnej z wykorzystaniem metod sztucznej inteligencji. Takie podejście przyczyniło się przede mnie do:

- opracowania nowych matematycznych modeli dla procesu suszenia kostek z jabłek w złożu fluidalnym,
- stwierdzenia dużej zgodności wyników symulacyjnych z nowymi pomiarami,
- wykazanie przydatności zastosowania istniejących w literaturze modeli empirycznych do opisu procesu rehydratacji plasterów z jabłek poddanych różnym metodom obróbki wstępnej przed suszeniem,
- opracowania dokładnych matematycznych modeli uzyskanych za pomocą sieci neuronowych do opisu zmian cech jakościowych suszonego i uwodnionego jabłka,
- opracowania matematycznych modeli uzyskanych metodą RSM do opisu zmian cech jakościowych rehydratowanego jabłka,
- wykazanie wpływu istotnych parametrów procesu suszenia i rehydratacji, które decydują o jakości produktu finalnego,
- sformułowanie wielokryterialnego zadania optymalizacyjnego,

- opracowania uniwersalnego narzędzia badawczego do oceny wielokryterialnej, zweryfikowanego na przykładzie zmian jakościowych produktów występujących w procesie suszenia i rehydratacji,
- wykazania uniwersalności zastosowanej metody. Metoda została skutecznie sprawdzona do opisu zmian jakościowych produktu zarówno podczas suszenia oraz podczas rehydratacji,
- udoskonalenia hybrydowej metody optymalizacyjnej do szybkiej oceny jednokryterialnej,
- opracowaniu optymalnego zestawu parametrów procesu suszenia i rehydratacji pod kątem lepszej jakości produktu finalnego,
- opracowania nowatorskiego podejścia do optymalizacji wielokryterialnej w sensie *Pareto*, opartego na sztucznej sieci neuronowej i algorytmie genetycznym.

Przeprowadzone badania empiryczne i symulacyjne uzupełniają stan wiedzy w zakresie modelowania i wielokryterialnej optymalizacji procesów suszenia i rehydratacji, leżących w obszarze zainteresowań inżynierii rolniczej. Opracowany komputerowy system optymalizacji wielokryterialnej umożliwi tworzenie norm i zaleceń prowadzenia procesów suszenia jak i rehydratacji dowolnych produktów rolniczych.

4.5. Literatura

- Abakarov A, Sushkov Y, Almoncid S. and Simpson R. 2009. Multiobjective optimization approach: Thermal food processing. *J. Food Sci.* 74:472–487.
- Aghilinategh N, Rafiee S, Hosseinpour S, Omid M, Mohtasebi S.S. 2015. Optimization of intermittent microwave–convective drying using response Surface methodology. *Food Sci. Nutrit.* 3 (4), 331–341.
- Akpınar E, Midilli A, Bicer Y. 2003. Single layer drying behaviour of potato slices in a convective cyclone dryer and mathematical modeling. *Energy Convers Manage*, 44, pp. 1689-1705.
- Amiryousefi M.R, Mohebbi M, Khodaiyan R and Ahsaee M.G. 2014. Multi-objective optimization of deep-fat frying of ostrich meat plates using multi-objective particle swarm optimization (MOPSO). *J. Food Process. Pres.* 38:1472–1479.
- Balasubramani P, Viswanathan R, Vairamani M. 2013. Response surface optimization of process variables for microencapsulation of garlic (*Allium sativum* L.) oleoresin by spray drying. *Biosyst. Eng.* 114 (3), 205–213.

Beightler C.S, Philips D.T, Wilde D.J. 1979. Foundation of optimization (2nd. Ed.). Englewood Cliffs, NJ: Prentice-Hall.

Białobrzewski I, Danowska-Oziewics M, Karpińska-Tymoszczyk M, Nalepa B, Markowski M and Myhan R. 2009. Turkey breast roasting - Process optimization. *J. Food Eng.* 96:394–400.

Box G.E.P, Wilson K.B. 1951. On the experimental attainment of optimum conditions *J. R. Stat. Soc. Ser. B Stat. Methodol.*, 13, pp. 1-45.

Box G.E.P., Hunter J.S., Hunter W.G. 2005. *Statistics for Experimenters: Design, Innovation, and Discovery* (2nd ed.), Wiley-Interscience, Hoboken, NJ.

Cagnoni S, Lutton E, Olague G. 2007. *Genetic and evolutionary computation for image processing and analysis*. Hindawi Publishing Corporation, New York.

Cheevitsopon E, Noomhorm A. 2011. Effect of paraboiling and fluidized bed drying on the physicochemical properties of germinated brown rice. *Int J Food Sci Technol*, 46, pp. 2498-2504.

Chen C.R and Ramaswamy H.S. 2002. Modeling and optimization of constant retort temperature (CRT) thermal processing using coupled neural networks and genetic algorithms. *J. Food Process Eng.* 25:351-379

CIE Technical Report. 2004. *Colorimetry*. 3rd edition. CIE Publication 15:2004. CIE Central Bureau, Vienna.

Colak N, Hepbasli A. 2009. A review of heat pump drying: Part 1–Systems, models and studies. *Energy Convers Manage*, 50, pp. 2180–2186.

Cox E. 2005. *Fuzzy modeling and genetic algorithms for data mining and exploration*. Elsevier, San Francisco.

Cybenko G. (1989). Approximations by superpositions of sigmoidal functions", *Mathematics of Control, Signals, and Systems*, 2(4):303–314.

Erbay Z, Icier, F. 2009. Optimization of hot air drying of olive leaves using response surface methodology. *J. Food Eng.* 91, 533–541.

Falade K.O, Solademi O.J. 2010. Modelling of air drying of fresh and blanched sweet potato slices. *Int J Food Sci Technol*, 45 pp. 278–288.

Fang J, Wang S, Zhang C. 2005. Application of genetic algorithm trained artificial neural network to identify tomatoes with physiological diseases. *Nature and Science* 3(2):52–57.

Gen M, Cheng R, Lin L. 2008. *Network models and optimization, multiobjective genetic algorithm approach*. Springer.

- Gen M, Cheng R. 2000. Genetic algorithm and engineering optimization. Wiley, New York.
- Goldberg D.E. 2003. Algorytmy genetyczne i ich zastosowania. WNT, Warszawa
- Goni SM and Salvadori V.O. 2012. Model-based multi-objective optimization of beef roasting. *J. Food Eng.* 111:92–101.
- Gupta M.K, Sehgal V.K, Arora S. 2013. Optimization of drying process parameters for cauliflower drying. *J. Food Sci. Technol.* 50 (1), 62–69.
- Hadiyanto H, Boom R.M, van Straten G, van Boxtel A.J.M, and Esveld D.C. 2009. Multi-objective optimization term to improve the product range of baking systems. *J. Food Process Eng.* 32: 709-729.
- Jaros M, Pabis S. 2006. Theoretical models for fluid bed drying of cut vegetables. *Biosys Eng;*93:45–55.
- Jokiniemi H.T, Ahokas J.M, 2014. Drying process optimization in a mixed-flow batch grain dryer. *Biosyst. Eng.* 121, 209–220.
- Kaletka A, Górnicki K. 2010. Some remarks on evaluation of drying models of red beet particles. *Energy Convers Manage;*51:2967–78.
- Knosala R. 2002. Zastosowanie metod sztucznej inteligencji w inżynierii produkcji. WNT, Warszawa.
- Lenart A. 2003. Maszynoznawstwo przemysłu spożywczego, Wydawnictwo SGGW.
- Levi A, Ben-Shalom N, Plat D, Reid D.S. 1988. Effect of blanching and drying on pectin constituents and related characteristics of dehydrated peaches. *Journal of Food Science*, 53, 1187-1190.
- Lewicki P.P. 1998. Some remarks on rehydration of dried foods. *Journal of Food Engineering;* 36:81–87.
- Menges H.O, Ertekin C. 2006. Thin layer drying model for treated and untreated Stanley plums. *Energy Convers Manage*, 47, pp. 2337–2348.
- Meziane S. 2011. Drying kinetics of olive pomace in a fluidized bed dryer. *Energy Convers Manage*, 52 pp. 1644–1649.
- Michalewicz Z. 1999. Algorytmy genetyczne + Struktura danych = Programy ewolucyjne, Wydawnictwo Naukowo-Techniczne WNT, Warszawa.
- Morimoto, T, De Baerdemaeker J and Hashimoto Y. 1997. An intelligent approach for optimal control of fruit-storage process using neural networks and genetic algorithms. *Comput. Electr. Agr.* 18:205-224.

- Nazghelichi T, Aghbashlo M, Kianmehr M.H. 2011. Optimization of an artificial neural network topology using coupled response methodology and genetic algorithm for fluidized bed drying. *Comput. Electron. Agric.* 75, 84–91.
- Nguyen M.H, Price W.E. 2007. Air-drying of banana: influence of experimental parameters, slab thickness, banana maturity and harvesting season. *J Food Eng*, 79 pp. 2000-2007.
- Nishitani H and Kunugita E. 1979. Optimal flow-pattern of multiple effect evaporator systems. *Comput. Chem. Eng.* 3:261–268.
- Ochoa M.R, Kessler A.G, Pirone B.N., Márquez C.A, De Michelis A. 2007. Analysis of shrinkage phenomenon of whole sweet cherry fruits (*Prunus avium*) during convective dehydration with very simple models. *J Food Eng*, 79, pp. 657-661.
- Olmos, A, Trelea I. C, Courtois F, Bonazzi C and Trystram G. 2002. Dynamic optimal control of batch rice drying process. *Dry Technol.* 20:1319–1345.
- Prakash S, Jha S.K, Datta N. 2004. Performance evaluation of blanched carrots dried by three different driers. *J Food Eng*, 62, pp. 305-313.
- Rahman N, Kumar S. 2006. Evaluation of convective heat transfer coefficient during drying of shrinking bodies. *Energy Convers Manage*, 47, pp. 2591-2601.
- Rouissi T, Mahmoudi A, Tyagi R.D, Brar S.K, Prévost D, Surampalli R.Y. 2013. Optimization of spray drying by response surface methodology for the production of *Sinorhizobium meliloti* powder formulation by using starch industry wastewater. *Biosyst. Eng.* 114 (3), 334–343.
- Rutkowska D., Rutkowski L., Piliński M. 1999. *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*. PWN, Warszawa.
- Rutkowski L. 2008. *Computational intelligence. Methods and techniques*. Springer, Berlin.
- Schanda, J. (Ed.), 2007. *Colourimetry Understanding the CIE System*. John Wiley & Sons, Inc., Hoboken, New Jersey, USA.
- Sendín J.H, Alonso A.A and Banga J.R. 2010. Efficient and robust multi-objective optimization of food processing: A novel approach with application to thermal sterilization. *J. Food Eng.* 98:317–324.
- Shahraki M.H, Ziaifar A.M, Kashaninejad S.M and Ghorbani M. 2014. Optimization of pre-fry microwave drying of french fries using response surface methodology and genetic algorithms. *J. Food Process Preserv.* 38:535–550.
- Sharma S, Rangaiah G.P, Cheach K.S. (2012). Multi-objective optimization using MS Excel with an application to design of a falling-film evaporator system. *Food Bioprod. Process.*, 90 (2) pp. 123-134.

- Stakic´ M, Urošević T. 2011. Experimental study and simulation of vibrated fluidized bed drying. *Chem Eng Process*;50:428–37.
- Sturm B, Hofacker W.C, Hensel O. 2012. Optimizing the drying parameters for hotair– dried apples. *Drying Technol.* 30 (14), 1570–1582.
- Syahrul S, Dincer I, Hamdullaphur F. 2003. Thermodynamic modeling of fluidized bed drying of moist particles. *Int J Therm Sci*;42:691–701.
- Vega-Gálvez A, Miranda M, Bilbao-Sáinz C, Urde E, Lemus-Mandaca R. (2008) Empirical modelling of drying process of apple (cv. Granny Smith) slices at different temperatures. *J Food Proc Preserv*, 32, pp. 972-986.
- Wang D.C, Zhang G, Han Y.P, Zhang J.P, Tian X.L. 2011. Feasibility analysis of heat pump dryer to dry hawthorn cake. *Energy Convers Manage*, 52, pp. 2919-2924.
- Winger E. 1960. The unreasonable effectiveness of mathematics in the natural sciences, *communications in pure and applied mathematics*; 13:1–14.
- Witt K. 2007. CIE color difference metrics. [In]: Schanda J. (ed.) *Colorimetry. Understanding the CIE system.* John Wiley and Sons , Inc. Hoboken, New Jersey, US, pp: 79–100.
- Yazgi A, Degirmencioglu A. 2007. Optimization of the seed spacing uniformity performance of a vacuum-type precision seeder using response surface methodology. *Biosyst. Eng.* 97 (3), 347–356.
- Zielinska M, Markowski M. 2007. Drying behaviour of carrots dried in spout-fluidized bed dryer. *Dry Technol*;25:261–70.
- Zieliński J.S. 2000. *Inteligentne systemy w zarządzaniu, Teoria i Praktyka*, PWN, Warszawa.
- Żurek M.B, Henrichs T. 2007. Linking scenarios across geographical scales in international environmental assessments, *Technological Forecasting & Social Change*; 74:1282–1295.

5. Omówienie pozostałych osiągnięć naukowo-badawczych

5.1. Przed doktoratem

Pracę naukowo-badawczą rozpocząłem przy realizacji pracy magisterskiej poświęconej zgrzewaniu tarciovemu żeliwa sferoidalnego, która była realizowaną na Wydziale Mechanicznym Akademii Techniczno-Rolniczej w Bydgoszczy.

Zgrzewanie tarciove jest dość ekonomiczną metodą łączenia w stanie stałym różnorodnych materiałów. Technologia ta znalazła szerokie uznanie w wytwarzaniu cylindrycznych elementów dla ciągników i przyczep w przemyśle rolniczym. Typowym przykładem połączeń zgrzanych tarciovo jest wałek kierowniczy ciągnika, sworzeń haka, łącznik kabłąkowy, strzemię wieszaka, czy dźwignie biegów. Celem badań było uzyskanie trwałych połączeń żeliwnych o zadawalającej jakości. Problemem badawczym była niekorzystna, twarda struktura formułowana na granicy złącza. Badania głównie dotyczyły oceny mikrostruktury wykonanych połączeń, badania ich twardości i wytrzymałości na rozciąganie.

Po obronie pracy dyplomowej w 1998 roku rozpocząłem krótką, kilkumiesięczną praktykę przemysłową na stanowisku Inżynier -Technolog w Fabryce Maszyn Żniwnych w Płocku (aktualnie *New Holland*).

W 1998 roku zgłosiłem się na studia doktoranckie realizowane na Wydziale Inżynierii Produkcji Politechniki Warszawskiej (PW). W latach 1998-2002 rozwijałem wiedzę w zakresie zgrzewania tarciovego żeliwa. W swoich badaniach sięgałem po bardziej wyrafinowane techniki badawcze takie jak mikroskopia elektronowa. Badania były realizowane w Zakładzie Odlewnictwa PW w ramach pozyskanego grantu badawczego (KBN Nr. 7TO8B05519) oraz badań statutowych prowadzonych w Katedrze Inżynierii Materiałowej. Badania mikroanalizy rentgenowskiej próbek podjąłem przy współpracy z Instytutem Wojsk Lotniczych w Warszawie. Wyniki z tamtego okresu były prezentowane na **4** międzynarodowych konferencjach naukowych. W okresie przed doktoratem opublikowałem **7** oryginalnych prac twórczych o łącznej liczbie **15 punktów**. W 1999 roku otrzymałem nagrodę naukową zespołową I stopnia Rektora PW. Tytuł doktora nauk technicznych w zakresie budowa i eksploatacja maszyn uzyskałem w 2001 roku.

5.2. Po doktoracie

W 2002 roku podjąłem pracę naukową na Wydziale Inżynierii Produkcji w Szkole Głównej Gospodarstwa Wiejskiego (SGGW) na stanowisku asystenta a rok później na stanowisku adiunkta. Od 2003 rozwijałem prace nad zgrzewaniem tarciovym stopów metali, aluminium oraz wolframu. Prace te koncentrowały się nad modelowaniem i optymalizacją parametrów zgrzewania. W powyższej tematyce nawiązałem współpracę z Instytutem Mechaniki i Poligrafii Politechniki Warszawskiej. Uzyskane wyniki pozwoliły mi na dokonanie *zgłoszenia* pt. „Metoda łączenia żeliwa sferoidalnego za pomocą zgrzewania tarciovego” do Urzędu Patentowego, którego byłem inicjatorem a mój udział oceniam na 50 %. Wyniki z badań struktury, właściwości wytrzymałościowych oraz przebiegu zjawisk fizykochemicznych połączeń tarciovych opublikowałem na liście JCR (prace w załączniku 5). Prace te, koncentrowały się nad zgrzewaniem tarciovym żeliwa sferoidalnego z żelazem sferoidalnym (II.A.3, II.A.8, II.A.9, II.D.4, D.4.20, D.4.21), ze stałą austenityczną (II.A.7), z żelazem Armco (II.A.10) ze stałą niskowęglową (II.A.5), oraz stopu wolframowego ze stopem aluminium (II.A.4). W pracach tych głównie wykorzystywałem mikroskopię świetlną i elektronową, posługując się modelowaniem i optymalizacją. Podjąłem również współpracę z Wydziałem Inżynierii Mechanicznej Uniwersytetu Technologiczno-Przyrodniczego w Bydgoszczy, która zaowocowała kolejnymi publikacjami. Opracowałem modele przebiegu temperatury podczas nagrzewania i chłodzenia próbek oraz przeprowadziłem praktyczną weryfikację tych modeli. Do modelowania wykorzystałem algorytmy genetyczne (II.A3 i II.D.4.1).

Zdobyte doświadczenie w zakresie badań strukturalnych stopów metali za pomocą techniki elektronowej mikroskopii skaningowej i transmisyjnej skutecznie wykorzystałem do obserwacji materiału biologicznego. W ramach wykonywanego projektu badawczego z NCN **“Optymalizacja procesów suszenia i rehydratacji jabłek z wykorzystaniem algorytmów ewolucyjnych”** Nr. NN313780940), którego byłem inicjatorem i wykonawcą. Badania mikrostruktury tkanki biologicznej wykonałem w Centrum Analitycznym SGGW. Wyniki mikrostruktury materiału surowego, suszu oraz rehydratowanego suszu z jabłek przedstawiłem w rozdziale pt. „Microstructure of tissue” znajdującej się w monografii (II.D.1 załącznik 5). Nowatorskim podejściem do badań było wykorzystanie mikroskopii transmisyjnej w odniesieniu do produktu nawadnianego, wysuszonego różnymi metodami. W ramach grantu badawczego opublikowałem kolejne 4 prace (II.D.4.4 do II.D.4.8, załącznik

5), które dotyczyły wpływu metody i parametrów suszenia i rehydratacji, obróbki wstępnej, zastosowania modelowania do opisu procesu suszenia i rehydratacji jabłek.

Poznanie wyżej wymienionych technik badawczych pozwoliło mi na opracowanie 2 rozdziałów podręczników pt. „**Wybrane zagadnienia z mikroskopii świetlnej**” (II.D.3.1) oraz „**Podstawy inżynierii materiałowej w przemyśle rolno-spożywczym**” (II.D.3.2), znajdujących się w wykazie prac (załącznik 5).

Sporą uwagę w pracach naukowych poświęciłem matematycznemu modelowaniu oraz metamodelowaniu za pomocą metod powierzchni odpowiedzi oraz modelowaniu z użyciem sieci neuronowych. Matematyczne modelowanie skutecznie wykorzystałem do opisu krzywych suszenia cząstek świerka, buka, wierzby i olchy. Wyniki zawarto w pracach z listy JCR (II.A1-II.A2) znajdujących się w załączniku 3. Wyniki eksperymentów pokazały, że gatunki drewna oraz temperatura powietrza suszącego mają wpływ na proces suszenia. Dane eksperymentalne dotyczące suszenia uzyskanych cząstek drewna z powodzeniem zostały dopasowane do sześciu modeli empirycznych.

W pracy (II.D.4.2) opracowałem modele neuronowe do wyznaczania temperatury punktu rosy oraz porównałem go z istniejącymi modelami.

Najwięcej uwagi w ostatnim czasie poświęciłem metodzie algorytmów genetycznych i jej skutecznemu zastosowaniu do rozwiązywania problemów w inżynierii produkcji. Algorytmy genetyczne wykorzystałem do optymalizacji pracy pakowarki (II.D.4.10), doboru nastaw (strojeniu) regulatora PID zaimplementowanego w sterowniku *PLC* (II.D.4.9, II.D.4.11), doboru parametrów procesu zgrzewania tarcowego dla żeliwa sferoidalnego (II.A.8), stali niskowęglowej (II.A.5), stali austenitycznej (II.D.4.17, II.D.4.18), w problemie diety (II.D.4.19). Algorytmy genetyczne stosowałem do rozwiązania problemów w zarządzaniu w przemyśle spożywczym (II.D.4.14) i logistyce odzysku (II.D.4.12, II.D.4.13 II.D.4.15 II.D.4.16, II.A.8).

W latach 2013-14 dzięki *Programowi Operacyjnemu Kapitał Ludzki*, podjąłem współpracę z Wydziałem Gospodarki Urzędu Marszałkowskiego Województwa Dolnośląskiego w charakterze recenzenta projektu badawczego “GRANT PLUS”. W sumie wykonałem **6 recenzji grantów doktorskich**.

Zdobyte osiągnięcia naukowe prezentowałem na kilkunastu konferencjach międzynarodowych, w tym **4 to konferencje zagraniczne**. Ogółem było 15 doniesień badawczych.

W latach 2011-13 czynnie brałem udział w prestiżowych konferencjach zagranicznych takich jak „*FOOD ENG'13*”, Turcja, 3rd International ISEKI Food Conference, “*FOOD SCIENCE AND TECHNOLOGY EXCELLENCE FOR A SUSTAINABLE BIOECONOMY*”, Grecja, 5th International Conference „*ON TRENDS IN AGRICULTURAL ENGINEERING*”, Czechy oraz innych międzynarodowych (załącznik 5).

Na przełomie roku 2014/15 opracowałem na zaproszenie wydawnictwa Taylor & Francis Group, USA oryginalny rozdział „*Ductile Irons: Friction welding*” do encyklopedii pt. „*Encyclopedia of Iron, Steel, and Their Alloys*”, ukazanej w 2016 roku.

Po uzyskaniu stopnia doktora **zrecenzowałem 23 międzynarodowe publikacje** naukowe, w tym **16 prac** pochodziło z **listy JCR** (załącznik 5).

Za działalność naukową zostałem uhonorowany **7 nagrodami** (2 indywidualne oraz 5 zespołowych). Nagrody były przyznane przez Rektora SGGW (6) oraz Rektora PW (1) (Tabela. 4). Wykaz nagród znajduje się w załączniku 5.

6. Syntetyczna charakterystyka dorobku naukowego

Wyniki wskaźników oceny bibliometrycznej przedstawiłem w Tabeli 4. Wskaźnik Impact Factor oraz punktacja MNiSW jest zgodna z rokiem publikacji.

Na dotychczasowy dorobek po doktoracie wchodzi kilkadziesiąt recenzowanych artykułów naukowych (załącznik 5), współautorstwo monografii w języku angielskim, 4 autorstwa rozdziałów w podręcznikach, co daje łączną liczbą **580 punktów**. Opublikowałem **14 artykułów** na liście **JCR** (Tabela 5), których pozytywnie recenzowało kilkudziesięciu recenzentów. Pozostałe 23 oryginalne prace z listy *B* ukazały się w *Postęпах Techniki Przetwórstwa Spożywczego* (**7** prac), *Annals of Warsaw University of Life Sciences* (**6** prac), *Agricultural Engineering* (**4** prace), *Gospodarka Materiałowa i Logistyka* (**3**) oraz po 1 pracy w *Technical Sciences*, *Pomiary Automatyka Kontrola* i *Logistyce*. W 8 artykułach z listy JCR byłem autorem korespondującym (8) i autorem pierwszoplanowym (8). Wieloletnia praca badawcza zaowocowała **89** cytowaniami w *bazie Web of Sciences*, sumarycznym impact factorem **IF=25.755** oraz indeksem **Hirsha=5**. Warto podkreślić, że jestem **monoautorem 12** recenzowanych publikacji naukowych w tym 1 z listy JCR.

Ciekawym aspektem dalszych badań może być przeanalizowanie wpływu zastosowanych parametrów procesów suszenia i rehydratacji na ilość zużytej w tych procesach energii oraz uwzględnienie aspektu energetycznego badanych procesów w optymalizacji procesów suszenia i rehydratacji. Dalsze badania naukowe będą prowadzone w kierunku implementacji algorytmów genetycznych do innych produktów biologicznych.

Tabela 4. Ilościowy wykaz najważniejszych osiągnięć naukowo-badawczych

Osiągnięcie	Przed doktoratem	Po doktoracie	Suma
Artykuły w czasopismach z listy JCR	-	14	14
Artykuły w czasopismach z wykazu B	4	23	27
Impact Factor dorobku naukowego	-	25.76	25.76
Indeks Hirscha wg. <i>Web of Science</i>	-	5	5
Liczba cytowań wg. <i>Web of Science</i>	-	89	89
Punktacja za publikacje wg listy <i>MNiSW</i>	15	580	595
Artykuły monoautorskie w czasopismach naukowych	-	12	12
Współautorstwo monografii naukowej	-	1	1
Współautorstwo podręczników i rozdziałów monografii naukowej	-	4	4
Referaty na konferencjach międzynarodowych	4	15	19
Recenzje publikacji międzynarodowych	-	23	23
Nagrody naukowe	1	7	8

Tabela 5. Wykaz wszystkich publikacji z Journal Citation Reports

Czasopismo z JCR	Rok wydania	Impact Factor	Liczba punktów
Computers and Electronics in Agriculture	2018	2.427	40
Emirates Journal of Food and Agriculture	2018	0.609	20
Journal of the Brazilian Society of Mechanical Sciences and Engineering	2018	1.627	15
Drvna Industrija	2017	0.616	20
Journal of Materials Processing Technology	2017	3.647	40
Neural Computing and Applications	2016	2.505	20
Polish Journal of Chemical Technology	2016	0.725	15
International Journal of Advanced Manufacturing Technology	2016	2.209	25
Energy Conversion and Management	2013	3.590	45
Resources, Conservation and Recycling	2013	2.692	35
Industrial Lubrication and Tribology	2013	0.316	15
Transactions of Nonferrous Metals Society of China	2013	1.001	30
Journal of Materials Processing Technology	2013	2.041	40
Materials and Design	2012	1.75	35
Sumaryczna liczba punktów wg. MNiSW			395
Sumaryczny Impact Factor (za lata publikacji)		25.76	