

## **METODYKA BADAWCZA ORAZ PRZYGOTOWANIE ZBIORÓW UCZĄCYCH DLA SIECI NEURONOWYCH IDENTYFIKUJĄCYCH JAKOŚĆ KOMPOSTU**

Artur Jakubek, Piotr Boniecki, Jacek Dach

*Institut Inżynierii Rolniczej, Uniwersytet Przyrodniczy w Poznaniu*

**Streszczenie.** Nie istnieje tania i szybka metoda określania stopnia dojrzałości kompostu, która mogłaby zostać przeprowadzona przez osobę nie posiadającą doświadczenia w tej dziedzinie. Podjęto zatem próbę jej estymacji wykorzystując jako narzędzie sztuczne sieci neuronowe. Opisana metodyka przedstawia kolejne etapy prac badawczych przeprowadzonych w celu pozyskania reprezentatywnych danych do trenowania inteligentnych systemów klasyfikujących.

**Słowa kluczowe:** kompost, analiza obrazu, sieci neuronowe, sztuczna inteligencja


### **Wstęp**

Członkostwo w Unii Europejskiej zobowiązuje rolników do przestrzegania Kodeksu Dobrej Praktyki Rolniczej. Ma on za zadanie kształtować prawidłową postawę wobec przepisów prawnych oraz poprzez szereg wskazówek i zakazów uczyć jak ograniczać ujemny wpływ rolnictwa na środowisko. W gospodarstwie rolnym powinno się stworzyć warunki do selektywnej zbiórki i zagospodarowania odpadów organicznych poprzez usuwanie ich na przyzmy kompostowe, względnie na przyzmy obornika [Duer i in. 2002].

Produktem końcowym prawidłowego kompostowania jest neutralna biologicznie i chemicznie materia o wysokiej wartości nawozowej, korzystnie wpływająca na środowisko glebowe oraz rośliny. Proces kompostowania wiąże się z zapewnieniem optymalnych warunków środowiskowych dla organizmów rozkładających materię w sposób tlenowy. Niezbędny jest odpowiedni skład chemiczny materii (stosunek węgla do azotu 25:1), wilgotność ok 55–75%, zawartość wolnych przestrzeni ok 50–65% oraz odpowiednie napowietrzanie, itd. [Dach, Zbytek 2007].

W optymalnych warunkach proces kompostowania podzielić można na cztery charakterystyczne fazy:

- faza wstępnego kompostowania – gwałtowny wzrost temperatury,
- faza intensywnego kompostowania – rozkład związków łatwo ulegających biodegradacji,
- faza przemian (kompostowanie właściwe) – spadek temperatury, przekształcenie trudno rozkładających się związków, spadek objętości odpadów,
- faza dojrzewania kompostu (kompostowanie wtórne) – tworzy się frakcja stabilna biologicznie – humus.



Źródło: [Jędrzak 2007]

Rys. 1. Przebieg zmian temperatury oraz pH w czasie kompostowania  
 Fig. 1. The course of temperature and pH value changes during composting

Analizując wykres 1 można zauważyć wyraźny spadek temperatury między czwartym, a szóstym tygodniem, co jest sygnałem zakończenia intensywnych przemian prowadzonych przez mikroorganizmy termofilne. Materia osiąga status tzw. młodego kompostu.

Chociaż temperatura wewnątrz pryzmy jest ważnym parametrem określającym fazę procesu, to jednak nie jest wystarczającym [Dach, Zbytek 2006]. Istnieje problem z precyzyjnym określeniem momentu ustania intensywnych przemian tlenowych i przejścia materiału w fazę dojrzewania biochemicznego, podczas którego może być on składowany w znacznie większych pryzmach, co pozwala zaoszczędzić miejsce na kompostowni. Często stosuje się wskaźniki fizyczne takie jak: zapach, gęstość usypowa, pH czy barwa, czy też chemiczne jak zawartość materii organicznej i popiołu, azotu amonowego czy PWK (pojemność wymiany kationowej). Metody te wymagają jednak dużej wiedzy i doświadczenia w metodyce i interpretacji wyników oraz przede wszystkim specjalistycznej aparatury. Jest więc zatem niedostępna dla przeciętnego użytkownika, a wykonanie ich na zlecenie trwa czasem nawet powyżej tygodnia.

## Cel i zakres badań

Celem badań jest wytworzenie sztucznej sieci neuronowej do automatycznego określania dojrzałości kompostu na podstawie obrazów pozyskanych cyfrowym aparatem fotograficznym. Realizacja założonego celu przebiega wieloetapowo, zaczynając od przygotowania stanowiska badawczego, poprzez przeprowadzenie serii doświadczeń, akwizycję obrazów pobranych próbek, ekstrakcję wybranych cech charakterystycznych, budowę zbioru uczącego, a na wytworzeniu i walidacji modelu neuronowego kończąc.

## **Materiał badawczy i stanowisko pomiarowe**

Materiał, na którym przeprowadzany jest eksperyment pochodzi ze specjalnych komór o pojemności 160 dm<sup>3</sup>, które zachowują warunki panujące wewnątrz przymy. Zastosowano quasidynamiczny system reaktorowy z pionowym napowietrzaniem w trybie ciągłym [Dach i in. 2003].

W trakcie trwania procesu kompostowania stosuje się jedno- lub dwukrotne mieszanie odpadów w celu uniknięcia tworzenia się stref beztlenowych i poprawienia jednorodności odpadów pod względem zarówno chemicznym jak i wilgotnościowym. Takie napowietrzania są wykonywane w skali rzeczywistej 1-3 razy przy pomocy aeratora ciągnikowego lub rozrzutnika obornika [Zbytek, Dach 2006]. Badaniu poddawane są próbki będące mieszaniną dwóch rodzajów materiału organicznego, jednym z nich jest w każdym przypadku osad ściekowy wymieszany ze słomą pszenną, rzepakową, kukurydzianą suchą oraz kukurydzianą wilgotną.

Z uwagi na eksperymentalny charakter pomiarów konieczne było zapewnienie jednakowych warunków oświetleniowym podczas procesu akwizycji obrazu. W tym celu zastosowano szczelnie zamykaną komorę z własnym oświetleniem oraz otworem na obiektyw. Zrezygnowano także z automatycznego doboru ustawień aparatu cyfrowego na rzecz stałych, wybieranych manualnie.

### **Akwizycja obrazu**

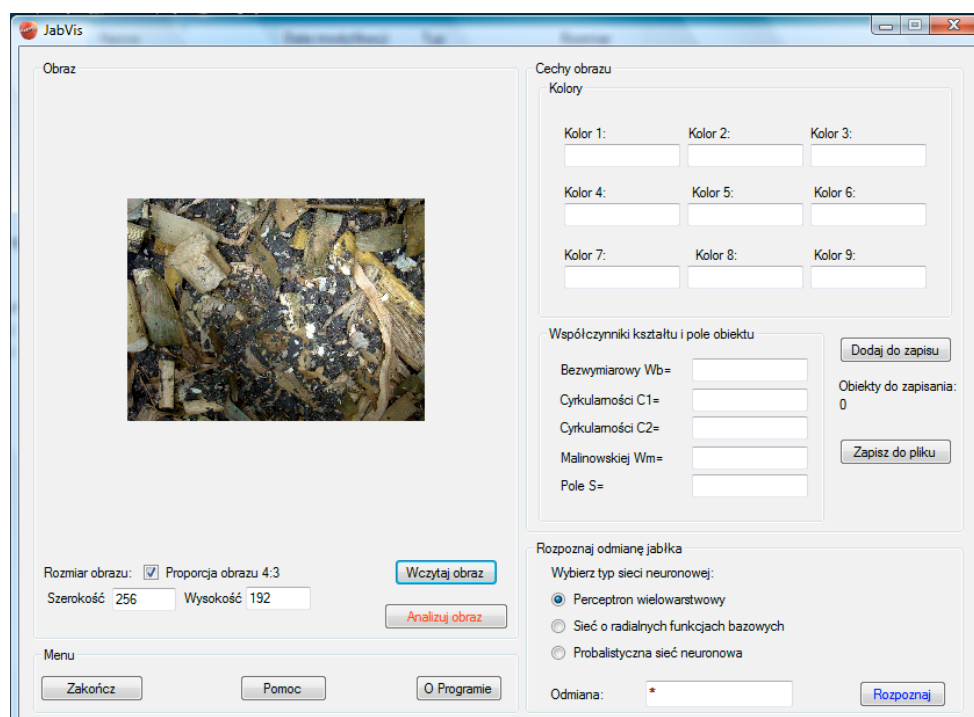
Materiał badawczy rozłożony równomiernie na powierzchni 0.25 m<sup>2</sup> fotografowany jest w dwóch rodzajach oświetlenia (światło białe oraz UVA) z odległości ok. 0,40 m. Z uwagi na dynamicznie zachodzące zmiany w początkowych fazach procesu, próbki pobierane są ze średnią częstotliwością raz na 3–7 dni (większa częstotliwość w pierwszych 10 dniach doświadczenia). Następnie dzielone są na trzy mniejsze części i kolejno fotografowane. Dzięki temu otrzymuje się zestaw obrazów reprezentujących nie tylko zmiany występujące w trakcie trwania procesu, ale także przedstawiające ewentualne niejednorodności występujące w przekroju przymy.

Bardzo ważnymi zmiennymi, które należy kontrolować są parametry ustawienia aparatu. Czułość ISO80, wraz z minimalną przesłoną F2.8 i czasem naświetlania rzędu 0,07 s. dla światła białego oraz 0,25 s. dla ultrafioletu, pozwoliły osiągnąć odpowiednią ekspozycję obrazu. Przy minimalnej wartości przysłony otrzymuje się najmniejszą głębię ostrości i co za tym związane najmniej ostre zdjęcia. Zwiększając jednak wartość F należałoby znacznie wydłużyć czas naświetlania lub zwiększyć czułość matrycy ISO, co z kolei znacznie zwiększyłoby udział tzw. szumu i mogłoby negatywnie wpłynąć na próbkowanie koloru.

### **Ekstrakcja cech obrazu i formowanie zbioru uczącego**

Otrzymane obrazy poddawane są procesowi ekstrakcji cech za pomocą systemu informatycznego JabVis. Aplikacja została wytworzona w ramach pracy badawczej mającej na celu identyfikację odmian jabłek. Składa się z dwóch modułów mogących działać niezależnie. Pierwszy przeznaczony jest do ekstrakcji cech charakterystycznych z obrazu. Automatycznie pobiera dziewięć próbek koloru oraz oblicza współczynniki kształtu t.j.

współczynnik bezwymiarowy, współczynnik Malinowskiej, dwa współczynniki cyrkularności (C1 oraz C2) oraz współczynnik Pole zdefiniowany jako ilość pikseli tworząca dany obiekt na obrazie. Drugi moduł pozwala natomiast identyfikować odmianę jabłka na podstawie wyekstrahowanych cech wykorzystując jeden z trzech alternatywnych modeli neuronowych zaimplementowanych w systemie. Użytkownik ma do wyboru: sieć typu perceptron, sieć o radialnych funkcjach bazowych oraz sieć probabilistyczną.



*Źródło: opracowanie własne autorów*

Rys. 2. Zrzut ekranu aplikacji JabVis  
Fig. 2. Screen dump of the JabVis application


Aplikacja JabVis została wytworzona w celu identyfikacji odmian jabłek, ale moduł przeznaczony do ekstrakcji cech charakterystycznych jest na tyle utylitarny, że pozwala próbować także obrazy kompostu. Możliwość zapisu danych do pliku CSV (ang. Comma Separated Values – wartości rozdzielone przecinkiem) umożliwia szybkie tworzenie zbiorów uczących.

Zgodnie z przyjętą metodyką jako zmienne niezależne stanowi dziewięć próbek koloru oraz współczynnik bezwymiarowy. Określa on iloraz sumy pikseli frakcji wyróżniających się z tła pod względem jasności do liczby pikseli całego obrazu. Podjęto w ten sposób próbę oceny porowatości kompostowanych odpadów poprzez ocenę ilości wolnych przestwo-

rów powietrznych. Pobrana próbka nie posiada oczywiście takiej samej liczby wolnych przestrzeni powietrznych jak materia. Zauważono jednak, że im bardziej wilgotny kompostowany materiał, tym łatwiej zbija się w większe frakcje łatwo rozpoznawalne w świetle ultrafioletowym. Im więcej takich frakcji znajduje się na obrazie i im bardziej są widoczne, tym mniej wolnych przestrzeni powietrznych i mniejsza porowatość. Może to z kolei wpływać na nieprawidłowy lub zaburzony przebieg procesu tlenowego rozkładu i świadczyć o zbyt dużej wilgotności kompostowanych odpadów [Dach, Zbytek 2007].

Zmienna zależna przyjmuje jeden z trzech ściśle określonych stanów, a mianowicie: „Materiał nieprzekompostowany”, „Materiał w trakcie kompostowania”, „Gotowy kompost”. Klasyfikacja poszczególnych próbek do przyjętych klas odbywa się na podstawie kompleksowo przeprowadzanych badań fizykochemicznych kompostowanej materii.

Utworzona w ten sposób tablica decyzyjna, złożona z dziesięciu zmiennych wejściowych oraz jednej wyjściowej służy do trenowania sztucznych sieci neuronowych. Poniżej przedstawiono schemat warstwy wejściowej i wyjściowej sieci neuronowej. Warstwę ukrytą stanowią neurony sigmoidalne lub radialne. Niezależnie jednak od ich rodzaju sztuczne sieci neuronowe wykazują nie tylko zdolność uczenia, ale także uogólniania nabytej wiedzy. Same są w stanie stworzyć potrzebny model, rola użytkownika sprowadza się do zebrania reprezentatywnych danych manifestujących określone zależności oraz zainicjowania działania wybranego algorytmu uczącego [Boniecki 2008].



Źródło: opracowanie własne autorów

Rys. 3. Schemat wejść i wyjść sieci neuronowej  
 Fig. 3. Diagram showing neural network inputs and outputs

## Wnioski

Pierwsze próbne wyniki uczenia pozwalają wysnuć wnioski o słuszności postawionych założeń i trafności przyjętej metodyki. Zastosowanie sztucznych sieci neuronowych do analizy dojrzałości kompostu na podstawie obrazów pozyskanych cyfrowym aparatem fotograficznych może być więc drogą do opracowania łatwej i – co niezwykle istotne

w warunkach rzeczywistych – szybkiej metody określania momentu zakończenia intensywnych przemian zachodzących w kompostowanej materii.

## Bibliografia

- Boniecki P.** 2008. Elementy modelowania neuronowego w rolnictwie. WUP Poznań. s. 12-17.
- Dach J., Jędrus J., Adamski M., Kowalik I., Zbytek Z.** 2003. Bioreaktor do badań procesów rozkładu materiałów organicznych. *Journal of Research and Applications in Agricultural Engineering*, vol. 48. Nr 4. s. 74-77.
- Dach J., Zbytek Z.** 2007. Zasady prawidłowego i ekonomicznie racjonalnego kompostowania obornika w gospodarstwach rolnych. *Zagadnienia Doradztwa Rolniczego*. Nr 3. s. 73-91.
- Dach J., Zbytek Z.** 2006. Badania nad biologicznymi aspektami różnych metod zagospodarowania obornika. *Nawozy i nawożenie – Fertilizers and Fertilization*. Nr 4. s. 46-60.
- Duer I., Fotyma M., Madej A.** 2002. *Kodeks Dobrej Praktyki Rolniczej*. Ministerstwo Rolnictwa i Rozwoju Wsi. Ministerstwo Środowiska. Warszawa.
- Jędrzcak A.** 2007. *Biologiczne przetwarzanie odpadów*. Wydawnictwo Naukowe PWN S.A. Warszawa. s. 199.
- Zbytek Z., Dach J.** 2006. Maszyny do kompostowania materiałów organicznych. *Nawozy i nawożenie – Fertilizers and Fertilization*. IUNG Puławy. Nr 4. s. 80-90.

## RESEARCH METHODOLOGY AND PREPARATION OF LEARNING DATASETS FOR NEURAL NETWORKS IDENTIFYING COMPOST QUALITY

**Abstract.** There is no cheap and quick method for determining the degree of compost maturity, which could be carried out by a person having no experience in this field. Therefore, there has been an attempt made to estimate it using artificial neural networks as a tool. Described methodology presents subsequent stages of research works carried out in order to acquire representative data for training intelligent classifying systems.

**Key words:** compost, image analysis, neural networks, artificial intelligence

### Adres do korespondencji:

Artur Jakubek; e-mail: artjak@up.poznan.pl  
Instytut Inżynierii Rolniczej  
Uniwersytet Przyrodniczy w Poznaniu  
ul. Wojska Polskiego 48  
60-637 Poznań