

## EMPIRICAL GRAPHICS DATA CONVERSION TO LEARNING SETS IN APPLE-TREE PESTS NEURAL IDENTIFICATION PROCESS

### Summary

*The mischievous of insects is mostly about their preying on the cultivated plants. In order to identify a pest correctly, one has to have the ability to identify its key characteristics. These are placed all over the insects corpse. A pest can be described by hundreds or even thousands of 'keys' – depending on the kind or species – what proves how difficult and time-consuming the identification is. ANN (Artificial Neural Networks) can learn, are less sensible to incomplete incoming information, they are processing entered signals and give results in actual time. The above properties and the analysis during the research allow to make a conclusion that ANN may do the identification task similarly to a human being. Thanks to such identification process automation it could be possible to eliminate the objectivism factor.*

## KONWERSJA GRAFICZNYCH DANYCH EMPIRYCZNYCH DO POSTACI ZBIORÓW UCZĄCYCH W PROCESIE NEURONOWEJ IDENTYFIKACJI SZKODNIKÓW JABŁONI

### Streszczenie

*Szkodliwość oddziaływania owadów na rośliny uprawne polega przede wszystkim na ich żerowaniu. Fakt ten powoduje daleko posunięte zmiany w morfologii i fizjologii roślin, co w efekcie końcowym prowadzi do ich zamierania. Żeby prawidłowo oznaczyć szkodnika, trzeba mieć możliwość identyfikacji cech kluczowych. Cechy te umiejscowione są na rozmaitych częściach ciała. Wymaga to jednak sporej wiedzy i dobrego rozeznania w grupach. Dotychczasowe metody identyfikacji owadów opierają się na rozpoznawaniu za pomocą kluczy. Klucze używane przez badaczy są ściśle dopasowane do danego osobnika. W zależności od rodzaju czy gatunku szkodnik może być opisany za pomocą setek a nawet tysięcy kluczy, co świadczy o trudności i czasochłonności w ich oznaczaniu. Sztuczne sieci neuronowe ze względów technicznych są uproszczonym symulatorem pracy ludzkiego mózgu posiadając jego cechy. Potrafią się uczyć, są mało wrażliwe na niekompletną informację wejściową, przetwarzają wprowadzone sygnały i podają na wyjściu wyniki w czasie rzeczywistym [2]. Wskazane właściwości oraz analizy podczas badań pozwalają przypuszczać, że SNN mogą wykonać zadanie identyfikacji podobnie jak człowiek. Dzięki takiemu zautomatyzowaniu procesu identyfikacji udałoby się wyeliminować współczynnik obiektywizmu.*

### Wprowadzenie

Intensywny rozwój technik multimedialnych w inżynierii rolniczej wymusza położenie większego nacisku na przetwarzanie i analizę obrazów. Badania obejmują zagadnienia związane z szeroko rozumianym wnioskowaniem z danych obrazowych na podstawie danych empirycznych przygotowanych za pomocą wytworzonego systemu informatycznego, ze szczególnym naciskiem na:

- analizę ilościową, - wybór cech reprezentatywnych,
- techniki konwersji graficznych danych do postaci zbiorów uczących,
- trening sztucznych sieci neuronowych na podstawie danych empirycznych zawartych w przygotowanych zbiorach uczących.

Pomimo, że sztuczna sieć neuronowa stanowi uniwersalny układ aproksymacyjny, odwzorowujący wielowymiarowe zbiory danych, bezpośrednio jej użycie jest nieefektywne bądź nawet niemożliwe, co może być spowodowane chociażby niejednorodną reprezentacją wielkości w układzie, czy rozmiarem wektora tych wielkości.

W takim przypadku wskazane jest użycie bloku przetwarzania wstępnego. Na rynku znajduje się wiele systemów do przetwarzania obrazów graficznych, jednak nie spełniły one wymagań, takich jak wybór cech reprezentatywnych oraz odpowiednich technik konwersji zaznaczonych obiektów na obrazach do postaci zbiorów uczących [3]. W tym celu został zaprojektowany i wytworzony sys-

tem „Konwerter” do przetwarzania i formowania obrazów do postaci akceptowalnej przez sztuczną sieć neuronową.

### Projekt naukowo-badawczy


Rzeczywiste obiekty są opisywane dużą liczbą cech, dlatego też ze względu na złożoność obliczeniową założono, że jedynie niektóre z nich, odpowiednio wybrane, będą ujęte w zbiorze uczącym.

W wyniku przeprowadzonych badań okazało się, że nie można w sposób dokładny sprecyzować kroków procesu przetwarzania danych dla wszystkich przypadków, stąd też na proces ten składa się sekwencja następujących etapów [1].

- Wstępne przetwarzanie danych:
  - zebranie i przechowywanie danych pierwotnych,
  - wstępne przetwarzanie danych pierwotnych,
  - ekstrakcja cech z danych pierwotnych.
- Konwersja zbiorów obrazów:
  - ekstrakcja i kodowanie obrazów dla zdefiniowanych obiektów,
  - generowanie zbiorów danych treningowych w formie tabelarycznej.- Przetwarzanie zbiorów obrazów:- wstępne przetwarzanie cech ze zbiorów danych treningowych,
  - selekcja cech reprezentatywnych ze zbiorów danych treningowych.

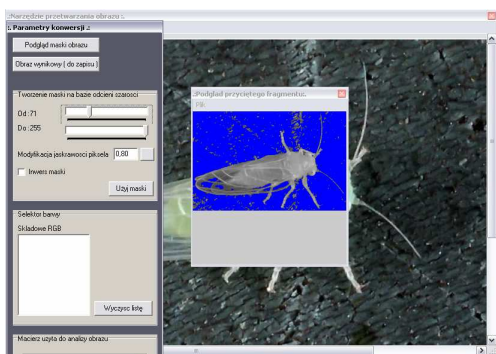
Działanie systemu „Konwerter”:

**ETAP I** – wczytanie obrazu i zaznaczenie interesującego obiektu




Rys. 1. Zaznaczenie obiektu  
Fig. 1. Marked object

- z wykorzystaniem detekcji krawędzi:



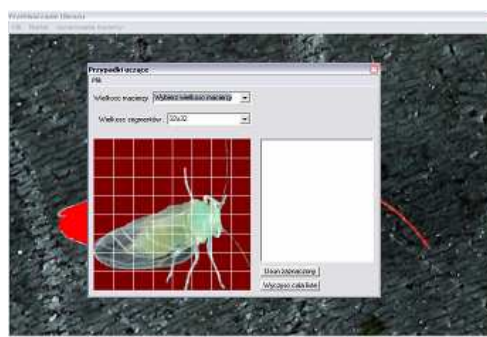
Rys. 2. Zastosowanie detekcji krawędzi  
Fig. 2. Detection of edge

- poprzez ręczne zaznaczenie (za pomocą markera) o różnych dostępnych rozdzielczościach:



Rys. 3. Ręczne zaznaczenie obiektu  
Fig. 3. Manual marked object

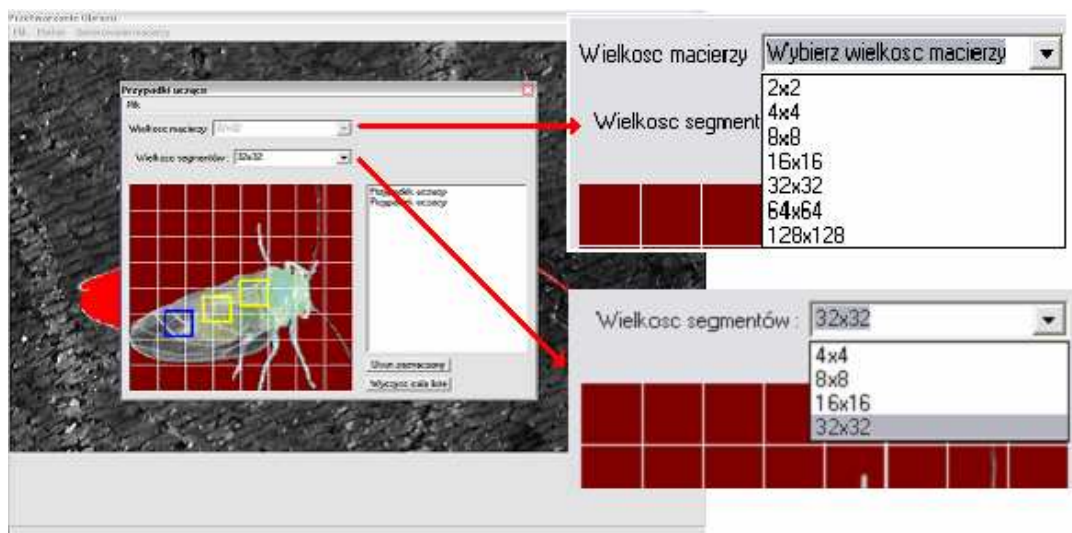
**ETAP II** – konwersja obrazu z zaznaczonym obiektem do rozdzielczości 256x256 pikseli



Rys. 4. Obiekt po konwersji  
Fig. 4. Object after conversion

**ETAP III** – wybór cech do opisu obiektu


- barwa - w formacie RGB oraz LAB (metoda próbkowania i fragmentacji obiektu):



Rys. 5. Próbkowanie i fragmentacja obiektu  
Fig. 5. Sampling and fragmentation of object

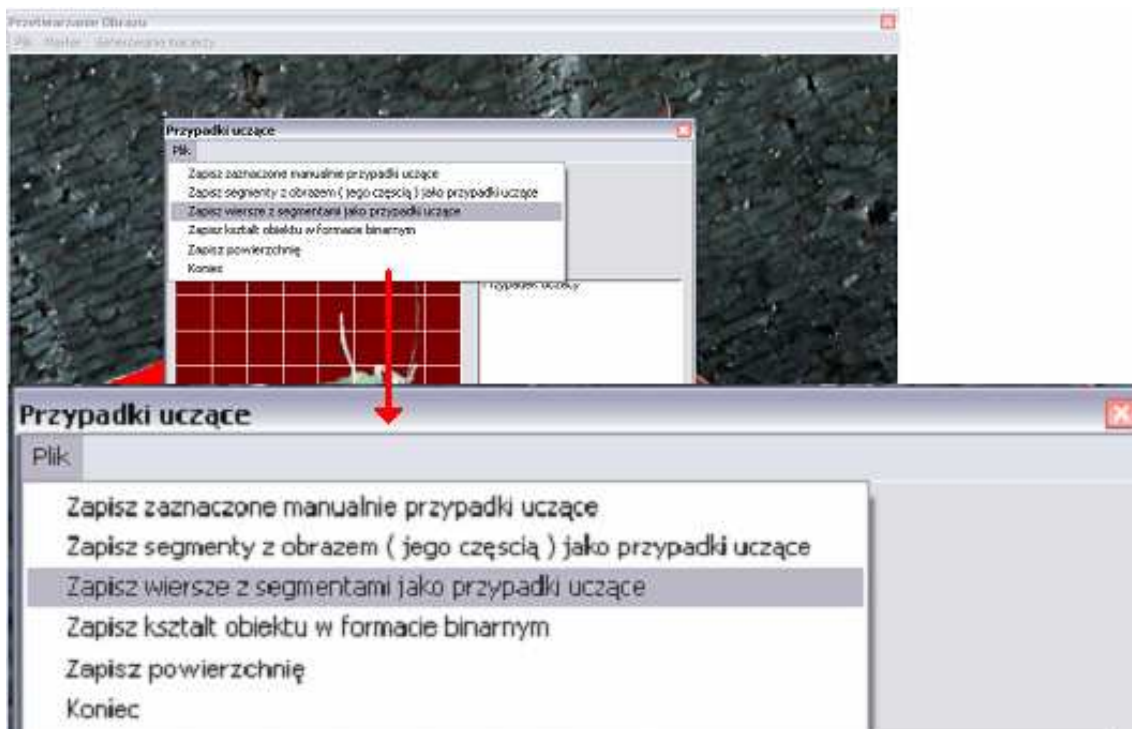
Każdy fragment to jeden przypadek uczący (1 wiersz), a każdy piksel to 1 zmienna [5].

- kształt - zapis w formacie binarnym oraz za pomocą współczynnika kształtu:



Rys. 6. Binarystacja obiektu  
Fig. 6. Binary conversion of object

**ETAP IV** – zapis przetworzonych obrazów do zbiorów uczących



Rys. 7. Sposoby zapisu  
Fig. 7. Saving methods to learning data

Celem była konwersja graficznych danych empirycznych do postaci zbiorów uczących w oparciu o system informatyczny, wytworzony na potrzeby edukacji sztucznych sieci neuronowych, uwzględniając trzy reprezentatywne cechy: barwę szkodnika (format RGB, LAB), jego kształt (format binarny, współczynniki kształtu) oraz wielkość (powierzchnię; ilość pikseli przypadających na obiekt). Wszystkie cechy zapisywane są do pliku o rozszerzeniu \*.csv – format zapisu akceptowany przez arkusz kalkulacyjny i pakiet Statistica v.6.0. Tak przygotowane dane służą jako zbiory treningowe w procesie uczenia sztucznych sieci neuronowych.

### Wnioski

1. Zastosowanie wytworzonego systemu informatycznego „Konwerter” pozwoliło na konwersję danych pierwotnych prezentowanych w postaci zdjęć fotograficznych owadów jabłoni do takiej postaci, która jest odpowiednia dla wykorzystania w procesie uczenia sieci neuronowej.
2. Analiza wpływu fragmentacji przez podział obrazu w oparciu o różne matryce pozwoliła na wybranie rozdzielczość 256x256 pikseli.
3. Celem przetwarzania wstępnego była ekstrakcja cech takich jak kolor, wymiar i pole powierzchni, zrealizo-

wana na zbiorze zdjęć oraz uzyskanie reprezentatywnego zbioru informacji zapisanego w możliwie najmniejszym wymiarze.

4. Wprowadzenie fragmentacji obrazu pozwoliło rozwiązać problem nierównej liczby zmiennych w poszczególnych wektorach uczących.

### Literatura

- [1] Marciniak A., Korbicz J. (1999): Diagnostowanie dynamicznych obiektów nieliniowych z wykorzystaniem statycznych sieci neuronowych. – Mat. XIII Krajowej Konferencji Automatyki.
- [2] Tadeusiewicz R., Flasiński M. (1991): Rozpoznawanie obrazów – Warszawa PWN.
- [3] Malina W., Smiatcz M.(2005): Metody cyfrowego przetwarzania obrazów – Wydawnictwo ELIT.
- [4] Ryszard S. Choraś (2005): Komputerowa wizja. Metody interpretacji i identyfikacji obiektów - Wydawnictwo EXIT.
- [5] Boniecki P., Piekarska\_Boniecka H. (2004): Neuronowa identyfikacja wybranych szkodników drzew owocowych w oparciu o analizę obrazu - Journal of Research and Applications in Agricultural Engineering, Vol. 49(3), str. 25 - 30.