

*Jacek Goszczyński*  
*Instytut Inżynierii Rolniczej*  
*Akademia Rolnicza w Poznaniu*

## **KLASYFIKACJA TEKSTUR ZA POMOCĄ SVM – MASZYNY WEKTORÓW WSPIERAJĄCYCH**

### **Streszczenie**

Motywacją do badań był pomysł wytworzenia robota-kosiarki wyposażonego w system komputerowego widzenia. Rozpoznawanie obrazu może zostać zrealizowane za pomocą klasyfikacji tekstur obiektów, które otaczają robota. Artykuł przedstawia przykład klasyfikacji tekstur za pomocą Maszyny wektorów wspierających SVM (ang. Support Vector Machine) Do badań wykorzystano oprogramowanie LIBSVM.

**Słowa kluczowe:** Maszyna wektorów wspierających, rozpoznawanie wzorców, rozpoznawanie obrazów, rolniczy robot mobilny

### **Wprowadzenie**


W naukach rolniczych często spotykane są problemy, dla których zależności są bardzo skomplikowane i może to wymagać rozwiązania problemu nieseparowalnego liniowo. Zbiorem takich przykładowych problemów, może być rozpoznawanie obiektów znajdujących się na obrazach przedstawiające naturalne środowisko. Wpływ warunków przyrodniczych na wygląd obiektów jest tak duży, że zastosowanie prostych metod rozpoznawanie obrazu na podstawie różnicy kolorów nie spełnia swojej roli. Jednym ze sposobów na powyższą sytuację jest rozpoznawanie złożonych cech jednoznacznie identyfikujące widziane obiekty. Jedną z takich cech może być tekstura. Przy cyfrowym zapisie obrazu teksturę można przedstawić za pomocą dwuwymiarowej tablicy pikseli. Natomiast rozpoznawanie tekstur może być zrealizowane za pomocą algorytmów rozwiązujących problemy klasyfikacji, do których należy min metoda maszyny wektorów wspierających (ang. Support Vector Machine ) SVM.

## Metoda SVM

Metoda SVM jest stosunkową młoda metodą służącą do rozwiązywania problemów regresji oraz klasyfikacji zaproponowaną przez Vladimira Vapnika [Vapnik 1995]. Klasyfikacja za pomocą metody SVM jest realizowana podobnie jak w przypadku sztucznych sieci neuronowych za pomocą zbioru uczącego. Jest to doskonała alternatywa dla sztucznych sieci neuronowych i często poprawność klasyfikacji jest lepsza dla SVM. Istotą metody SVM jest konstrukcja „*optymalnej hiperpłaszczyzny*”, której zadaniem jest rozdzielenie danych, należących do przeciwnych klas, z możliwie największym marginesem zaufania [Jankowski 2003].

$$\begin{aligned} \min_{\omega, b, \xi} \quad & \frac{1}{2} \omega^T \omega + C \sum_{i=1}^l \xi_i \\ & y_i (\omega^T \phi(x_i) + b) \geq 1 - \xi_i, \\ & \xi_i \geq 0. \end{aligned} \quad (1)$$

Na rys. 1 przedstawiona jest „*optymalna hiperpłaszczyzna*” dla dualnego problemu klasyfikacyjnego, w postaci prostej liniowej separującej obiekty należące do dwóch klas – kwadratów i kół. Rozpatrywanymi cechami obiektów są wartości zmiennych  $x$  i  $y$  określających położenie obiektu na płaszczyźnie a nie ich kształt.



Rys. 1. „*Optymalna hiperpłaszczyzna*” dla dualnego problemu klasyfikacyjnego  
 Fig. 1. „*Optimal hiperplane*” for doubleclassification problem

Dla problemów, w których nie można idealnie rozdzielić obiekty należące do przeciwnych klas, czyli nie istnieje idealnie separująca funkcja w przestrzeni cech, Cortes i Vapnik [Cortes 1995] zaproponowali metodę SVM, w postaci następującego zadania optymalizacyjnego:

Dany jest zbiór trenujący oznaczonych wzorców  $(x_i, y_i)$ ,  $i = 1 \dots l$ , gdzie  $x_i \in \mathbb{R}^n$  są cechami wzorców i  $y \in (-1, 1)^l$ , które są oznaczeniami wzorców, SVM wymaga rozwiązania następującego problemu optymalizacyjnego przedstawionego za pomocą równania nr 1:

gdzie:

- $\omega$  i  $b$  – współczynniki optymalnej hiperpłaszczyzny
- $\phi(\cdot)$  – funkcja jądrowa (bazowa),
- $C$  – parametr wysokości kary,
- $\xi_i$  – zmienna rozluźniająca,

Idea metody SVM jest konstrukcja optymalnej hiperpłaszczyzny w pewnej wysokowymiarowej przestrzeni cech  $Z$ , która jest nieliniowym produktem pewnych funkcji jądrowych  $\phi(\cdot)$  wybranych a priori. SVM znajduje liniową hiperpowierzchnię w wysokowymiarowej przestrzeni cech  $Z$  z możliwie największym marginesem rozdzielającym. W metodzie SVM optymalizacja marginesu realizowana jest poprzez wyszukanie możliwie najlepszego parametru kary  $C$  oraz parametrów funkcji jądrowych. W literaturze dotyczącej rozpoznawania wzorców za pomocą SVM stosowane są następujące funkcje jądrowe:

liniowa:  $K(x_i, x_j) = x_i^T x_j$ ,

wielomianowa:  $K(x_i, x_j) = (\gamma x_i^T x_j + r)^d$ ,  $\gamma > 0$ ,

radialna (RBF):  $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$ ,  $\gamma > 0$ ,

sigmoidalna:  $K(x_i, x_j) = \tanh(x_i^T x_j + r)$ .

gdzie  $\gamma$ ,  $r$ , oraz  $d$  są parametrami funkcji jądrowych.

Na stronach <http://www.kernel-machines.org/> znajduje się lista adresów internetowych do stron zawierających informacje dotyczące metody SVM. Wśród dostępnych pakietów informatycznych zawierających implementację metody SVM na wyróżnienie zasługują następujące:

LIBSVM – często aktualizowana bardzo prosta implementacja metody SVM,

Torch – <http://www.torch.ch/> - duży pakiet z zestawem metod maszynowego uczenia, min, MLP, RBF, Naiwny klasyfikator Bayesa, SVM i inne.

LightSVM – jedna z pierwszych implementacji metody SVM.

Dla przybliżenia zasady działania metody SVM posłużono się pakietem LIBSVM. Pakiet składa się on z trzech podstawowych programów uruchamianych bezpośrednio w oknie terminala systemu operacyjnego: *svmscale*, *svmtrain*, *svmpredict*.

Do pakietu dołączony jest zestaw skryptów napisanych w języku Python umożliwiających automatyzację poszukiwania parametrów związanych optymalną hiperpłaszczyzną []. Do uruchomienia skryptów niezbędna jest instalacja języka *Python* oraz pakietu do tworzenia wykresów *gnuplot*.

## Cel

Celem jest rozwiązywanego problemu klasyfikacji trzech tekstur reprezentujących obiekty występujących na obrazie zarejestrowanych kamerą zamontowaną na zdalnie sterowanej kosiarce firmy Evatech Inc. RLMC2006C. Motywacją do rozwiązania rozpatrywanego problemu jest wizja wytworzenia robota-kosiarki samodzielnie poruszającego się po trawniku sąsiadującego z różnymi przeszkodami jak kwietnik oraz małe drzewa iglaste.

## Metodyka


Do przeprowadzonych badań wytworzono program komputerowy SNNtoSVM konwertującym pliki programu Statistica Neural Network 4.0 o rozszerzeniu .sta, do plików tekstowych wymaganych przez pakiet LIBSVM.

W celu wygenerowania zbiorów uczących oraz testowych posłużono się oprogramowaniem ARBOO, który umożliwia:

- definiowanie nazw tekstur;
- zaznaczanie obszarów wzorcowych z teksturami na zdjęciach skatalogowanych w bazie danych;
- generowanie plików uczących lub testowych dla pakietu STATISTICA Neural Network 4.0;
- testowanie nauczonych sztucznych sieci neuronowych pod kontem poprawności klasyfikacji tekstur na zaznaczonych obszarach wzorcowych.

W oprogramowaniu ARBOO zostały zdefiniowane trzy tekstury odpowiednio reprezentujące odpowiednie zbiory roślin: TRAWA, DRZEWKO IGLASTE, KWIETNIK. Zaznaczono 31 obszarów wzorcowych o łącznej powierzchni 450008 pikseli. Przykładowe wskazania obszarów wzorcowych przedstawione są na rys .2.

Do przeprowadzenia badań wygenerowano dwa pliki: uczący oraz testowy, zawierające 3000 przykładowych tekstur o powierzchni 10x10 pikseli. Wybór tekstur z zaznaczonych obszarów wzorcowych odbywał się przy użyciu funkcji losowej systemu operacyjnego. W każdym ze zbiorów znajdowało się po 1000 przykładów z każdej tekstury. W plikach było 300 zmiennych wejściowych, które odpowiadały intensywności kolorów RGB każdego piksela tekstury. Trzy zmienne wejściowe reprezentowały przynależności do klasy.



Rys. 2. Na lewym rysunku zaznaczony prostokątny obszar wzorcowy przedstawiający teksturę trawy, na prawym obszar przedstawiający teksturę identyfikującą kwietnik

Fig. 2. Two pictures with selected rectangles of textures. On left picture is selected rectangle of grass texture and on the right is flowerbed

## Wyniki badań i ich analiza

*Klasyfikacja tekstur za pomocą sztucznych sieci neuronowych.*

Zbiór uczący *tekstury\_uczacy.sta* wczytano do programu Statistica Neural Network i wyszukano najlepszą sztuczną sieć neuronową typu RBF (ang. Radial Function Basis) za pomocą funkcji automatycznego projektanta. Utworzoną sieć wczytano w oprogramowaniu ARBOO i wyliczono poprawność klasyfikacji dla wyznaczonych tekstur. Poprawność była liczona dla 10 zbiorów zawierających po 3000 przykładowych tekstur i mieściła się zakresach przedstawionych w tabeli 1.

*Tabela 1. Zakresy poprawności klasyfikacji zdefiniowanych tekstur przez nauczoną sztuczną sieć neuronową typu RBF*

*Table 1. Classification accuracy ranges for RBF neural network*

Tekstura	Poprawność klasyfikacji
DRZEWKO IGLASTE	96,8 – 97,2
KWIETNIK	79,1 – 82,7
TRAWA	87,0 – 88,2

*Klasyfikacja tekstur za pomocą LIBSVM*

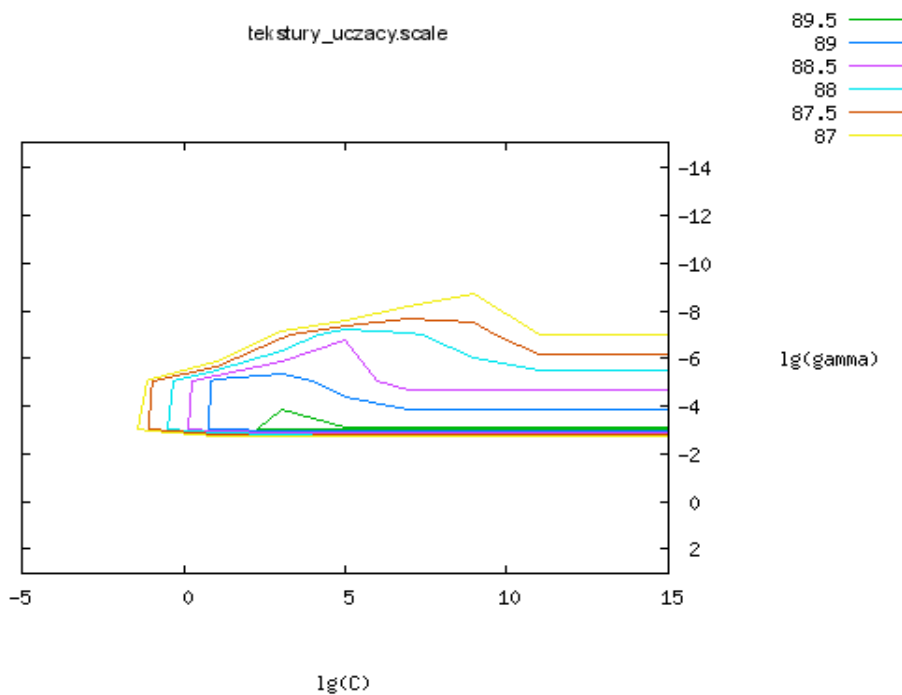
Pliki wygenerowane przez oprogramowanie ARBOO zostały przekonwertowane za pomocą programu SNNtoSVM. Za pomocą programu *svmscale* zmienne

wejściowe w plikach `tekstury_uczacy.svm` oraz `tekstury_test.svm` zostały przeskalowane z zakresu  $[0, 255]$  do zakresu  $[0, 1]$ .

```
$svmtrain -l 0 -u 1 tekstury_uczacy.svm tekstury_uczacy.scale
$svmtrain -l 0 -u 1 tekstury_test.svm tekstury_test.scale
```

Za pomocą skryptu `grid.py` przeprowadzono szukanie optymalnych parametrów  $C$  i  $\gamma$ . W ramach skryptu `grid.py` poszukiwana jest hiperpłaszczyzna w wytworzona z radialnych funkcji jądrowych. W trakcie szukania podstawiane są kolejno wartości  $C$  z zakresu  $C=2^{-5}, 2^{-3}, \dots, 2^{15}$  oraz  $\gamma=2^{-15}, 2^{-13}, \dots, 2^3$ . Podczas wyszukiwania otrzymano wykres rys. 3 ilustrujący zakres optymalny wartości dla parametrów  $C$  i  $\gamma$ .

```
$python grid.py tekstury_uczacy.scale
```



Rys. 3. Wykres ilustrujący poziom poprawności klasyfikacji dla różnych wartości parametrów  $C$  oraz  $\gamma$

Fig. 3. Chart with level of classification correctness for ranges of SVM parameter  $C$  and  $\gamma$

Dla wartości  $C = 8$  i  $\gamma = 0.125$  utworzono model klasyfikatora tekstur za pomocą programu `svmtrain`.

```
$svmtrain -c 8 -g 0.125 tekstury_uczacy.scale tekstury.model
```

Następnie przeprowadzono testowanie utworzonego modelu.

```
$svmpredict tekstury_test.scale tekstury.model tekstury.odp  
Accuracy = 91.1667% (2735/3000) (classification)
```

Otrzymano wynik 91,2% poprawności klasyfikacji.

### **Wnioski**

1. Model umożliwiający klasyfikację tekstur utworzony za pomocą metody SVM był nieznacznie lepszy od najlepszej wyszukanej sztucznej sieci neuronowych. W poszukiwaniu jeszcze lepszych modeli można przeprowadzić badania przy użyciu innych funkcji jądrowych.
2. Poprawność klasyfikacji tekstur dla wyszukanej sztucznej sieci neuronowej typu RBF nie przekraczała 90%.
3. Poprawność klasyfikacji tekstur dla zbioru testowego wyliczona dla modelu klasyfikacyjnego utworzonego za pomocą metody SVM i radialnej funkcji bazowej wyniosła 91.1%.

### **Bibliografia**

Hsu Ch., Chang Ch., Lin Ch. 2005. A Practical Guide to Support Vector Classification, Department of Computer Science and Information Engineering, National Taiwan University.

Cortes, C. and V. Vapnik 1995. Support-vector network. Machine learning 20, 273–297.

Jankowski N. 2003. Ontogeniczne sieci neuronowe. O sieciach zmieniających swoją strukturę, Akademicka Oficyna Wydawnicza EXIT, Warszawa.

Vapnik, V. 1995. The Nature of Statistical Learning Theory. New York, NY: Springer-Verlag.

## TEXTURE CLASSIFICATION USING SUPPORT VECTOR MACHINE

### Summary

Motivation for research was idea to create mower robot with computer vision system. Image recognition can be done by textures classification of objects that robot is surrounded. This article has reviewed example of texture classification by SVM Support vector machine. For research was used LIBSVM software.

**Key words:** support Vector Machine, pattern recognition, image recognition, agriculture mobile robot