

Müzik Türlerinin Co-MRMR ile Sınıflandırılması

Audio Genre Classification with Co-MRMR

Yusuf Yaslan, Zehra Çataltepe

Bilgisayar Mühendisliği Bölümü
İstanbul Teknik Üniversitesi, Maslak İstanbul
{yyaslan, cataltepe}@itu.edu.tr

Özetçe

Çok sayıda öznelik vektörü ve etiketsiz verinin bulunduğu sınıflandırma problemlerinde, Birlikte Öğrenme algoritması (Co-training) kullanılarak iki sınıflandırıcı eğitilip, etiketsiz veriler özyineli olarak etiketlendirilebilir ve sonuç sınıflandırıcılar birleştirilebilir. Birlikte Öğrenme algoritması özellikle veri etiketlemenin pahalı, zor olduğu ve az etiketli verilerin bulunduğu durumlarda sınıflandırma başarımını arttırabilir. Bu çalışmada, bütün özneliklerden seçilen değişik altkümeleri kullanan sınıflandırıcıların eğitilmesi ve daha sonra birlikte öğrenmesine dayanan Co-MRMR algoritması müzik türlerinin sınıflandırılması için kullanılmıştır. Öznelik vektörleri, MRMR (Minimum Redundancy Maximum Relevance, En Küçük Artıklık En Büyük İlgililik) öznelik seçme algoritması kullanılarak seçilmektedir. Marsyas ve Music Miner yazılımları ile elde edilmiş iki öznelik kümesi Birlikte Öğrenme algoritması için kullanılmıştır. Co-MRMR algoritması daha önce Wang v.d. tarafından 2008'de önerilmiş olan rasgele altküme algoritması RASCO'dan ve geleneksel Birlikte Öğrenme algoritmasından daha iyi sonuç vermiştir.

Abstract

In a classification problem, when there are multiple feature views and unlabeled examples, Co-training can be used to train two separate classifiers, label the unlabeled data points iteratively and then combine the resulting classifiers. Especially when the number of labeled examples is small due to expense or difficulty of obtaining labels, Co-training can improve classifier performance. In this paper, Co-MRMR algorithm which uses classifiers trained on different feature subsets for Co-training is used for audio music genre classification. The features are selected with MRMR (minimum redundancy maximum relevance) feature selection algorithm. Two different feature sets, obtained from Marsyas and Music Miner software are evaluated for Co-training. Experimental results show that Co-MRMR gives better results than the random subspace method for Co-training (RASCO) which was suggested by Wang et al. in 2008 and traditional Co-training algorithm.

1. Giriş

Günümüzde birçok örüntü tanıma probleminde, etiketli veri ile birlikte çok sayıda etiketsiz veri de bulunmaktadır. Etiketli veriler özellikle, veriye erişimin kolay fakat bunları etiketlemenin zor olduğu gerçek problemlerde karşımıza çıkmaktadır [1]. Örneğin web sayfalarını içeren birçok sunucudan web dokümanları ya da resimleri elde edilebilmektedir. Fakat bunların sınıflandırılması zaman gerektiren güç bir işdir. Benzer olarak biyoinformatikte protein bilgilerini içeren birçok veri tabanı bulunmakta fakat bunların fonksiyonlarının belirlenmesinde problem yaşanmaktadır. Diğer bir problem ise müzik türlerinin sınıflandırılmasıdır. İnternet ve çoğul ortam sistemlerinin artması müzik verisine erişimi kolaylaştırmış olmasına rağmen türlerin sınıflandırılması işlemi zor, uzun zaman gerektiren işlemlerdir. Geleneksel müzik sınıflandırma sistemleri eğitici sistemler olup çok sayıda etiketli veriye ihtiyaç duymaktadırlar. Bazen verinin %90'ı eğitim için kullanılabilir [2]. Bu tür durumlarda yarı eğitici algoritmalarından yararlanılabilmektedir.

Literatürde müzik türlerinin sınıflandırılması için verilmiş birçok algoritma bulunmaktadır [3, 4, 5]. Benzer olarak bu algoritmaların kullandığı sıfır geçişleri, işaret bant genişliği, Mel Frekans kepsrum katsayıları, bant enerji oranları, izgesel merkez, gibi birçok öznelik vektörleri tanımlanmıştır [5]. Genel olarak birden fazla farklı şekilde elde edilmiş öznelik uzaylarının olduğu durumlarda tek bir öznelik uzayı oluşturmak üzere tüm öznelik vektörleri birleştirilebilir. Fakat bu, bazen sınıflandırma başarımı açısından problemler doğurabilmektedir [2]. Örneğin birleştirilen öznelik vektör uzayları fiziksel anlamlarını kaybedebilmekte veya öznelik fazlalığı oluşabilmektedir.

Birlikte öğrenme algoritması [6] farklı iki öznelik uzayının bulunduğu durumlarda, iki sınıflandırıcı eğiterek etiketsiz verileri özyineli olarak etiketlendirmektedir. [2]'de Xu ve arkadaşları Birlikte Öğrenme algoritmasını kullanarak klasik, pop ve metal türlerinin sınıflandırmasını gerçekleştirmişlerdir. Bu çalışmada Co-MRMR algoritması klasik, jaz, pop, hiphop ve rege müzik türlerinin sınıflandırılması için kullanılmış ve diğer algoritmalarla kıyaslanmıştır. Co-MRMR algoritması farklı sınıflandırıcıları MRMR öznelik seçme yöntemi ile elde edilen öznelik vektörleriyle birlikte eğitmektedir. Test sonuçları Co-MRMR algoritmasının RASCO ve Birlikte

Öğrenme algoritmasından daha iyi başarımlarını göstermektedir.

2. Birlikte Öğrenme ve RASCO

Birlikte Öğrenme algoritması farklı öznelik uzayında iki sınıflandırıcı eğiterek etiketsiz verileri özyineli olarak etiketlendirmeyi ve her bir sınıflandırıcının başarımını arttırmayı hedefleyen bir algoritmadır. Birlikte Öğrenme algoritması Algoritma 1'de verilmiştir:

Algoritma 1'de F_1 ve F_2 farklı iki öznelik uzayını, U etiketsiz verileri, L etiketli verileri, C_1 (C_2) etiketli veri kümesinin F_1 (F_2) öznelik uzayı üzerinde eğitilmiş sınıflandırıcıyı göstermektedir. u etiketsiz veriden seçilecek örnek sayısını, n yineleme sayısını göstermektedir. U^l olarak, U 'nun tamamı da seçilebilir. Birlikte öğrenme sırasında her bir sınıflandırıcı her bir sınıf için en emin olduğu bir etiketsiz örneği etiketlemek ve bunu etiketli veri kümesi içerisine atmaktadır. [6]'da iki sınıflı sınıflandırma problemi için, p pozitif sınıfları n negatif sınıfları göstermek üzere, her bir sınıflandırıcı $p+n$ adet etiketsiz veriyi etiketlemektedir. Çalışmamızda daha her bir sınıflandırıcı her sınıf için sınıf başına en emin olduğu bir adet etiketsiz veriyi etiketli veri kümesine katmaktadır.

Algoritma 1: Birlikte Öğrenme Algoritması

```

U1 = Select u random examples from U
for i = 1 to n do
  for j = 1 to 2 do
    Train  $C_j$  on  $F_j$ 
    Classify  $U^1$  by  $C_j$ 
    Select most surely classified example on  $U^1$ 
    Remove this example from  $U^1$  and add to  $L$ 
  end for
end for

```

Genel olarak öznelik vektörleri birbirleri arasında uyumlu (*compatible*) ve koşullu bağımsız (*conditionally independent*) ise Birlikte Öğrenme algoritması sınıflandırma başarımını arttırmaktadır [6]. Fakat bu iki özelliği sağlamak genellikle zordur. Bu problemi ortadan kaldırmak üzere, rasgele altküme yönteminin Birlikte Öğrenme algoritması ile birleşimi (RASCO) önerilmiştir [7]. RASCO farklı iki öznelik vektörü uzayı üzerinde sınıflandırıcı eğitmek yerine, önce bütün öznelikler bir araya getirip $F=F_1 \cup F_2$ kümesini oluşturur. Daha sonra farklı K adet, C_k ($k=1, \dots, K$) sınıflandırıcısını, F 'den seçilmiş L_k öznelik alt uzayında eğitmektedir. RASCO algoritması, F_1 ve F_2 uzayların bulunmadığı, F uzayının yeteri kadar büyük olduğu tek bir uzay üzerinde de çalışabilmektedir. RASCO algoritması Algoritma 2'de verilmiştir. Algoritmada VP pozitif sınıflar için, VN ise negatif sınıflar için seçilmiş etiketsiz verilerin kümesini temsil etmektedir.

Algoritma 2: RASCO

```

Randomly choose m dimensional subspaces for K times
for j = 0 to J do
  Project  $L$  to each of the subspace to get  $L_k$  ( $1 \leq k \leq K$ )
  Use each  $L_k$  to train  $C_k$ 
  Use each  $C_k$  to predict the labels of unlabeled data
  Let  $C(q) = (1/K) \sum C(q)_k$ , and q be an example to be classified
  if  $C(q) \geq 0$  then
    put q into  $VP$ 
  else

```

```

    put q into  $VN$ 
  end if
  for  $VP$  and  $VN$  select  $q^1$ ,  $q^1 = \text{argmax}(lC(q^1))$ 
  put  $q^1$  into  $L_j$ 
  Update  $L \leftarrow L \cup L_j$ ,  $L_j \leftarrow \emptyset$ ;
end for

```

RASCO algoritması Birlikte Öğrenme ve Üçlü Öğrenme (Tri-training) [8] algoritmaları ile karşılaştırılmış ve RASCO algoritmasının daha iyi sonuç verdiği gösterilmiştir [7].

Öte yandan birçok gerçek veri kümesinde öznelik vektörleri arasında ilinti bulunabilmektedir. RASCO öznelik vektörlerini rasgele seçtiğinden, birbiri ile ilintili öznelikler aynı alt kümede bulunabilmekte ve dolayısıyla her bir sınıflandırıcının başarımı azalabilmektedir. Öznelik vektörleri arasında ilişkinin bulunduğu durumlarda, birçok çalışmada öznelik seçme algoritmaları kullanılabilir. Genellikle öznelik seçme algoritmaları [9] daha küçük uzayda ve daha fazla ayırt edici özelliklere sahip öznelikleri bulmayı amaçlamaktadır. Bu çalışmada, birçok veri tabanında başarılı ve hızlı sonuçlar verdiği gözlemlenen MRMR öznelik seçme algoritması RASCO algoritması ile tümelştirilmiş ve yeni algoritma, Co-MRMR, kullanılarak müzik türleri sınıflandırılmıştır.

3. Co-MRMR Algoritması

Bu bölümde öncelikli olarak MRMR öznelik seçme algoritması açıklanacak daha sonra Co-MRMR algoritması tanıtılacaktır.

3.1. MRMR Öznelik Seçme Algoritması

Birçok sınıflandırma probleminde, birbirleriyle ilintili öznelik uzayından iyi öznelik altkümesi seçmek önemli bir işlemdir. Öznelik seçme işleminin öznelik uzayını azaltma ve bu sayede işlem zamanını düşürme, gürültüyü azaltma ve daha iyi ve ayırt edici öznelikleri belirleme gibi faydaları vardır. Genel olarak öznelikler filtreleme (filtering methods) veya sınıflandırıcı başarımları (wrapper methods) dikkate alınarak seçilmektedir [9]. Sınıflandırıcı başarımına göre gerçekleştirilen öznelik seçme algoritmaları iyi sonuç vermekle birlikte eğitim kümesi için çok sayıda örnek ve zamana ihtiyaç duymaktadırlar. MRMR öznelik seçme algoritması önce öznelikleri sınıf etiketlerine olan ilgilerine (relevance) göre sıralar. MRMR aynı zamanda seçilmiş öznelik kümesi ile en az ilintili olan öznelik vektörünü seçmeyi amaçlar. MRMR öznelik-öznelik ve öznelik-etiketler arası benzerlik miktarını hesaplamak için karşılıklı bilgi miktarını (mutual information) kullanmaktadır. Daha detaylı bilgiye [10]'dan ulaşılabilir.

3.2. Co-MRMR

Co-MRMR algoritması her bir öznelik vektörü için MRMR öznelik seçme algoritmasını kullanarak öznelik altkümelerini elde etmektedir [11]. Co-MRMR algoritması öncelikli olarak etiketli eğitim kümesi içerisindeki öznelik vektörlerini ayırır. Sonraki aşamada d adet öznelik

vektörü için ilgililik (relevance) değerlerinden elde edilen Q değerleri, toplamları 1 olacak şekilde normalize edilir ve öznitelik vektörleri için olasılık dağılım fonksiyonu oluşturulur. Her bir alt küme için öncelikli olarak turnuva seçme yöntemi kullanılarak m adet öznitelik vektörü seçilir ve D_i kümesi oluşturulur. S_i öznitelik altkümesi MRMR algoritmasının D_i kümesi üzerinde bulunduğu en iyi m adet öznitelik vektörünün seçilmesi ile oluşturulur. RASCO algoritmasında olduğu gibi sınıflandırıcılar S_1, \dots, S_K altkümeleri üzerinde eğitilir. Sonuç sınıflandırıcı oluşturulmuş sınıflandırıcıların çoğunluk değerine (majority vote) göre belirlenir. Algoritma belirli bir yineleme süresince etiketsiz veri kümesindeki verileri etiketleyerek, etiketli veri kümesini genişletir. Co-MRMR algoritması Algoritma 3'te verilmiştir.

Algoritma 3: Co-MRMR

Discretize(L)

$Q = \text{Relevance}(L)$

$Q = \text{Normalize}(Q)$

for $j = 1$ to K do

$D_i \leftarrow \text{TournamentSelection}(Q, m^1)$

$S_j \leftarrow \text{MRMR}(D_i, m)$

end for

for $i = 1$ to I do

for $j = 1$ to K do

Train classifier C_j using S_j

end for

Label examples on U by using $C = (1/K) \sum C_k$

Select one most surely classified example from U for each class and add them to L .

end for

Şekil 1'de l etiket bilgisini göstermek üzere Co-MRMR, RASCO ve Birlikte Öğrenme algoritmaları, kullandıkları öznitelik uzayları ile birlikte gösterilmiştir.

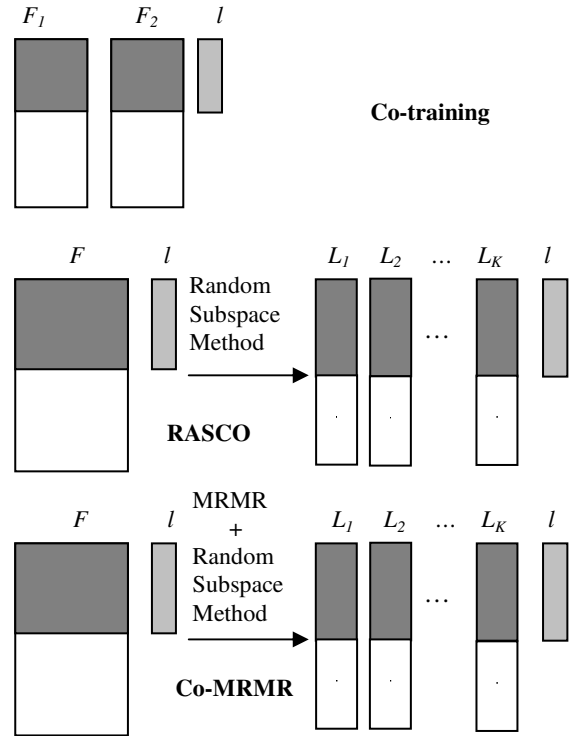
4. Veri Kümesi ve Test Sonuçları

Veri kümesi olarak [5]'de verilmiş birbirleri ile en az karışık klasik, jaz, pop, hiphop ve rege müzik türleri kullanılmıştır. Veri tabanında her müzik türü için toplam 100 adet müzik dosyası bulunmaktadır. Benzer bir çalışma daha önce Birlikte Öğrenme algoritması kullanılarak klasik, pop ve metal sınıfları için gerçekleştirilmiştir [2]. Xu ve arkadaşları sınıflandırıcı olarak K En yakın Komşuluk (KNN) algoritmasını kullanmışlardır. Bu çalışmada test sonuçları PRTools' daki KNN(optimum) algoritması kullanılarak elde edilmiştir [11].

4.1. Öznitelik Vektörleri

Bu çalışmada sınıflandırıcıların kullanması için farklı 2 tür öznitelik vektörü elde edilmiştir. Öncelikli olarak [5]'te belirtilen 30 boyutlu öznitelik vektörleri MARSYAS yazılımı kullanılarak çıkarılmıştır. Bu öznitelikler 6 boyutlu Beat, 9 boyutlu STFT, 10 boyutlu MFCC ve 5 boyutlu MPITCH öznitelikleridir. Bu öznitelik vektörleri ile ilgili detaylı bilgi [5]'te bulunabilir. MARSYAS öznitelik vektörlerinin tamamı Birlikte Öğrenme algoritması için F_1 öznitelik uzayı olarak seçilmiştir. Benzer olarak [12]'de verilmiş Databionic Music Miner yazılımı kullanılarak 20 adet en iyi başarımları gösteren öznitelik vektörü elde edilmiştir. Bu öznitelik vektörleri düşük ve yüksek seviyeli (low and high level) birçok öznitelik vektöründen çıkarılmıştır. Daha detaylı bilgi [12]'den elde

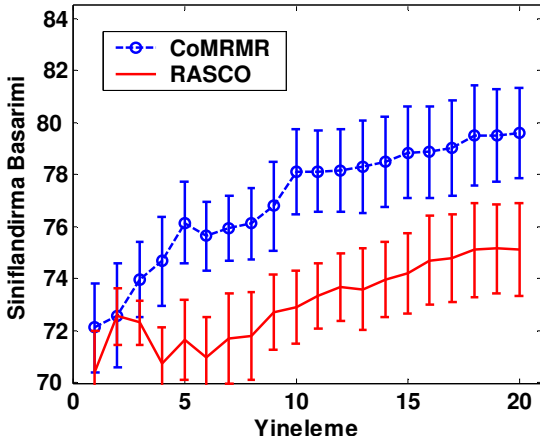
edilebilir. Music Miner ile elde edilmiş öznitelik vektörlerinin tamamı Birlikte Öğrenme algoritması için F_2 öznitelik uzayı olarak seçilmiştir. RASCO ve Co-MRMR her iki öznitelik uzayının birleşimi ile elde edilen F üzerinde çalıştırılmıştır.



Şekil 1: Birlikte Öğrenme, RASCO ve co-MRMR algoritmalarının kullandıkları öznitelik uzayları.

4.2. Test Sonuçları

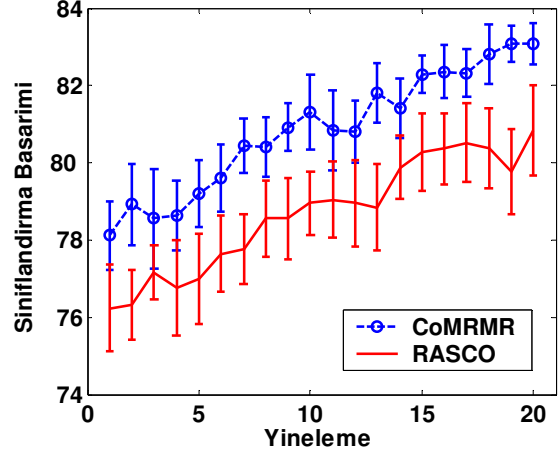
Test sonuçları için öncelikli olarak tüm veri kümesi test ve eğitim kümeleri olmak üzere eşit iki bölüme ayrılmıştır. Eğitim kümesi de etiketli ve etiketsiz eğitim kümesi olmak üzere iki parçaya bölünmüştür. Öncelikli olarak her bir sınıf için 10 adet etiketli veri ile sınıflandırıcılar eğitilmiş ve yinelemeli olarak etiketsiz veriler etiketlenerek etiketli eğitim kümesine eklenmiştir. 20 yineleme için elde edilmiş sonuçlar Şekil 1’de gösterilmiştir. Sonuçlar 10 adet rasgele yürütme ile elde edilmiş ve her bir yöntem için ortalamanın standart başarımları verilmiştir. Co-MRMR ve RASCO algoritması için seçilen öznelik vektörü boyutu $m = 25$ ve sınıflandırıcı sayısı $K = 5$ olarak alınmıştır. Co-MRMR’da m^l 25 olarak alınmıştır. Birlikte Öğrenme algoritması yinelemelerde farklı sayıda etiketsiz veriyi etiketli veri kümesine eklediği için 10 yineleme ile sonuçlandırılmıştır. Birlikte Öğrenme algoritmasının başlangıç başarımı 67.60 ± 1.51 ve 10 yineleme sonucundaki başarımı 74 ± 1.08 olarak elde edilmiştir. Co-MRMR ve RASCO algoritmaları ilk birkaç yinelemede birbirlerine yakın sonuçlar vermekle birlikte Co-MRMR algoritması RASCO’dan daha iyi başarımlar göstermektedir. Eklenen veri sayısı arttıkça her iki algoritmanın başarımı da artmaktadır ve CoMRMR algoritması yinelemeler sonunda %80’e yakın başarımlara ulaşmışlardır. İki algoritma da Birlikte Öğrenme algoritmasından çok daha yüksek başarımlar göstermektedir.



Şekil 2: Co-MRMR ve RASCO algoritmalarının yineleme sayısına bağlı sınıflandırma başarımı. Her bir sınıf için başlangıçtaki etiketli veri sayısı = 5.

Eğitim kümesindeki etiketli veri sayısı her bir sınıf için 10’a çıkarılmış ve benzer sonuçlar aynı parametreler için şekil 3’de gösterilmiştir. Birlikte Öğrenme algoritmasının başlangıç başarımı 71.28 ± 1.43 ve 10 yineleme sonucundaki başarımı 76.16 ± 1.64 . Co-MRMR algoritması yinelemelerin tamamında RASCO’dan daha iyi başarımlar göstermekte ve 20 yineleme sonunda %83.08 sınıflandırma başarımına ulaşmaktadır.

Etiketli verinin artması her üç algoritmada da başarımların artmasına neden olmaktadır. Co-MRMR algoritması, özellikle sınıflandırma için değerli öznelikleri seçtiği için, eklenen etiketli verilerin sınıflandırma başarımındaki faydasını RASCO’dan daha fazla görmektedir.



Şekil 3: Co-MRMR ve RASCO algoritmalarının yineleme sayısına bağlı sınıflandırma başarımı. Her bir sınıf için başlangıçtaki etiketli veri sayısı = 10.

5. Sonuçlar

Bu bildiri Co-MRMR algoritması müzik türlerinin sınıflandırılması için kullanılmış ve başarımı RASCO ve Birlikte Öğrenme algoritmaları ile kıyaslanmıştır. Co-MRMR algoritması iki algoritmadan da çok daha iyi başarımlar göstermektedir. İleriki çalışmalarda sınıf sayısının artırılması ve sınıflandırıcı olarak Karar Destek Makinelerinin kullanılması planlanmaktadır. Benzer olarak yüksek boyutlu öznelik uzaylarında önerilen algoritmanın başarımı incelenecektir.

6. Kaynakça

- [1] Yaslan Y. and Cataltepe Z. “Co-training with adaptive bayesian classifier combination” *In International Symposium on Computer and Information Sciences (ISCIS2008)*, Istanbul Turkey, 27-29 October 2008.
- [2] Y. Xu, C. Zhang and J. Yang, “Semi-Supervised Classification of Musical Genre Using Multi-View Features”, *International Computer Music Conference (ICMC 2005)*, 5-9 September 2005.
- [3] Cataltepe Z., Yaslan Y., and Sonmez, A. “Music Genre Classification Using MIDI and Audio Features”, *EURASIP Journal on Advances in Signal Processing*, 2007.
- [4] Yaslan Y. and Cataltepe Z. “Audio Music Genre Classification Using Different Classifiers and Feature Selection”, *18th International Conference on Pattern Recognition (ICPR 2006)*, Hong Kong, 2008.
- [5] Tzanetakis, G. and Cook, P., “Musical Genre Classification of Audio Signals”, *IEEE Transactions on Speech and Audio Processing*, vol.10 no.5, pp. 293-302, 2002.
- [6] Blum A. and Mitchell T. “Combining Labeled and Unlabeled Data with Co-training” *Proc. of the 11th Annual Conference on Computational Learning Theory (COLT '98)* (pp. 92-100), 1998.
- [7] Wang J. Luo S.W. and Zeng X.H “A random subspace method for co-training” *In International Joint*

- Conference on Neural Networks(IJCNN 2008)*, pp 195–200, 2008.
- [8] Zhou Z. H. and Li M., “Tri-Training: Exploiting Unlabeled Data Using Three Classifiers”, *IEEE Transactions on Knowledge and Data Engineering*, vol.17, no.11, pp. 1529-1541, 2005.
 - [9] Guyon I. and Elisseeff, “An Introduction to Variable and Feature Selection”, *Journal of Machine Learning Research*, vol.3, pp. 1157-1182, 2003.
 - [10] Ding C. and Peng H. “Minimum redundancy feature selection from microarray gene expression data” *In Computational Systems Bioinformatics(CSB 2003)*, pp 523–528, 2003.
 - [11] R.P.W. Duin. PRTOOLS A Matlab Toolbox for Pattern Recognition. 2004
 - [12] Mierswa I. and Morik K. “Automatic Feature Extraction for Classifying Audio Data”, *Machine Learning*, vol. 58, pp. 127-149,2005.