

Seyrek İşaret İşlemede Sınıflandırma Uygulamaları ve Çekirdek Tabanlı Yaklaşımlar

Classification Applications of Sparse Signal Processing and Kernel Based Methods

Abdurrahman Yeşiloğlu¹ ve Ender M. Ekşioğlu¹

¹Elektronik ve Haberleşme Mühendisliği Bölümü, İstanbul Teknik Üniversitesi, İstanbul, Türkiye
{yesiloglua, ekxioglua}@itu.edu.tr

Özetçe—Seyreklik tabanlı işaret işleme araştırmacılar tarafından oldukça fazla ilgi çeken ve örüntü tanıma, görüntü işleme ve bilgisayarlı görü gibi alanlarda sıklıkla kullanılan görece yeni bir araştırma alanıdır. Bu çalışmada seyreklik tabanlı işaret işleme ve çekirdek yaklaşımlarının beraberce sınıflandırmada kullanılmasını konu almaktayız. Seyreklik tabanlı sınıflandırıcılar son dönemde çeşitli sınıflandırma uygulamalarında oldukça verimli şekilde kullanılmışlardır. Bu yeni seyrek sınıflandırıcıların, çekirdek yaklaşımı vasıtasıyla daha etkin versiyonlarının oluşturulması ise görece az ilgi çekmiştir. Burada sözlük öğrenme içermeyen seyrek sınıflandırıcılarda, çekirdek yaklaşımının kullanımı incelenecektir. Yüz ve rakam veri setleri üzerinde gerçekleştirilen sınıflandırma benzetimleri, seyrekliği ve çekirdek yaklaşımını beraberce kullanan sınıflandırıcıların oldukça rekabetçi sonuçlar verdiğini göstermektedir.

Anahtar Kelimeler —Sıkıştırılmış algılama; seyreklik; görüntü işleme; sınıflandırma, yüz tanıma.

Abstract—Sparsity based signal processing is a relatively new research area which has attracted tremendous interest from researchers. Application areas for sparse signal processing include but are not limited to image processing, pattern recognition and computer vision. This work considers the joint application of sparsity and kernel methods to classification problems. Novel sparsity based classifiers have been effectively utilized in classification. Variants of sparse classifiers utilizing kernel functions on the other hand have garnered limited interest. Here we will examine the combination of non-dictionary learning sparse classifiers with kernel based methods. Simulations in face and digit recognition applications demonstrate competitive performance for classifiers utilizing sparsity and kernel methods concurrently.

Keywords — compressive sensing; sparsity; image processing; classification, face recognition.

I. GİRİŞ

Seyreklik, son yıllarda ortaya çıkmış ve birçok bilimsel alanda başarılı çözümlere temel oluşturmuş önemli bir araştırma alanıdır. Seyreklik, özellikle işaret işleme, yapay öğrenme ve görüntü işleme gibi alanlarda oldukça etkin bir uygulama sahasına sahiptir. Görüntü işleme problemlerinden, gürültü giderme, görüntü restorasyonu, çözünürlük değiştirme, görsel izleme, görüntü sınıflandırma vb. uygulamalar için literatürde oldukça fazla çalışma bulmak mümkündür. Yeni bir veri toplama paradigması olarak sunulan sıkıştırılmış algılama, popülerite kazanan seyreklik tabanlı yaklaşımların en bilinen ve göz önünde olan uygulaması olmuştur [1].

II. BENZER ÇALIŞMALAR

Seyreklik tabanlı işaret işlemenin kullanıldığı ilk önemli sınıflandırma çalışması, Wright ve diğerleri tarafından geliştirilmiştir [2]. Önerilen bu sınıflandırıcı parametrik olmayan ve sözlük öğrenme gerektirmeyen bir yapıda tasarlanmıştır. Gelen test resminin doğrudan sözlük verisi üzerinde seyrek temsili gerçekleştirilerek sınıflandırma yapılmaktadır. Bu öncü çalışma ile birlikte seyrek sınıflandırma üzerine yapılan çalışmalar büyük bir artış göstermiştir. Örneğin Zhang ve diğerleri [3], ℓ_2 normunu kullanarak iyi bir başarımla elde eden seyrek sınıflandırıcı sistemini önermiştir. Yine Deng ve diğerleri [4], seyreklik tabanlı sınıflandırıcının değişik yüz görüntüsü özellikleri (kamuflej, yüz ifadeleri, ışık seviyeleri gibi) için daha iyi performans gösteren, iyileştirilmiş bir versiyonunu önermiştir.

Seyreklik tabanlı sınıflandırmada çekirdek yaklaşımları ise görece az ilgi çekmiştir. Çekirdek yaklaşımları ve seyrekliği birleştiren sınıflandırma çalışmalarından en önemli iki tanesi, ℓ_1 normlu SVM (Support Vector Machine) [5] ve çekirdek tabanlı seyrek temsil (Kernel Sparse Representation - KSR) [6] çalışmalarıdır. Her iki yaklaşımda da, nesnelere yüksek boyutlu öznelik uzayına dönüştüren çekirdek yaklaşımı ve seyreklik beraberce kullanılarak yeni sınıflandırıcılar geliştirilmiştir.

III. SEYREKLİK TABANLI SINIFLANDIRMA

A. Seyreklik Tabanlı Sınıflandırmanın Temelleri

Gözetimli sınıflandırmada temel problem sınıfı bilinmeyen test nesnesini, k farklı bilinen sınıf seti içinden doğru sınıfa atamaktır. Bu sınıflandırmayı seyreklik tabanlı olarak yapmak istediğimizde, öncelikle nesne ve sözlük arasındaki ilişkiyi ifade eden seyrek gösterilim vektörünü elde etmemiz gereklidir. Bir test nesnesine ait seyrek gösterilim vektörü, onun geri çatımında kullanılan sözlük atomlarının belirli bir kısmında yoğunlaşır. Bu durum, test nesnesinin sözlükte yoğunlaştığı atomların doğrusal birleşimi ile elde edildiğini ve bu durumu benzerliklerinin bir ölçüsü olarak kabul edebileceğimizi gösterir. Buradan hareketle k farklı sınıfın her biri için belirli sayıda atom içeren bir sözlük kümesinin verildiğini düşündüğümüzde, test resmini k farklı bilinen sınıfa ait bu sözlük atomları cinsinden seyrek olarak ifade edebiliriz.

Sınıflandırmada kullanılacak tüm nesnelere \mathbb{R}^s boyutunda birer vektör olduğunu varsayalım. Her bir sınıfa ait sözlükteki atom sayısı n_i olmak üzere, k tane farklı sınıfa ait toplam $n = n_1 + n_2 + \dots + n_k$ adet atom kullanılarak büyük D sözlük matrisi oluşturulabilir. İlk olarak, i . sınıfa ait sözlük (1)'deki gibi ifade edilebilir.

$$D_i = [d_{i,1}, d_{i,2}, \dots, d_{i,n_i}] \in \mathbb{R}^{s \times n_i} \quad (1)$$

Burada, $d_{i,j}$, i . sınıfa ait sözlüğün j . atomunu ifade etmek üzere, k adet sınıfa ait sözlüklerin birleşimi ile oluşan D sözlüğü (2)'deki gibi ifade edilir.

$$D = [D_1, D_2, \dots, D_k] \quad (2)$$

Sözlükteki atom sayısının nesne vektörü boyutundan büyük olduğu, yani özellikle $n \gg s$ durumu için, seyrek işaret işleminin gücü ortaya çıkmaktadır. $x \in \mathbb{R}^s$ test nesnesi önceden belirlenmiş D sözlüğünün atomları cinsinden doğrusal bir bileşim olarak (3)'teki gibi ifade edilebilir.

$$x = Da \in \mathbb{R}^s \quad (3)$$

$a \in \mathbb{R}^n$ seyrek katsayı vektörü olmak üzere $x = Da$ eksik belirtilmiş doğrusal denkleminin tek değil pek çok çözümü mevcuttur. Bu denklemin tek bir çözüme sahip olması ancak ilave bir kısıt altında mümkün olmaktadır. Kısıt olarak en az sayıda atomun kullanımı alınır, bu ℓ_0 normu altında bir optimizasyon problemini getirmektedir. Seyrek gösterilim problemi olarak niteleyebileceğimiz bu problem (4)'teki gibi verilebilir. Bu optimizasyon problemi eşleştirmeli takip (Matching Pursuit-MP) veya dikey eşleştirmeli takip (Orthogonal Matching Pursuit-OMP) algoritmaları ile yaklaşık olarak çözülebilmektedir.

$$a = \underset{a}{\operatorname{argmin}} \|a\|_0, \quad (4)$$

$$\|Da - x\|_2 \leq \varepsilon \text{ koşulu altında}$$

x test nesnesinin, (4)'teki optimizasyon probleminin çözümüyle elde edilen a seyrek vektörünün sıfır olmayan elemanlarının yoğunlaştığı sınıfa ait olduğuna karar verilebilmektedir. Buradan hareketle a seyrek vektöründeki her bir sınıfa ait katsayıları seçen fonksiyonu $\delta_i : \mathbb{R}^n \rightarrow \mathbb{R}^n$ olarak tanımlarsak, $r_i(x)$ i . sınıfa ait artığı göstermek üzere sınıflandırma yapılacak sınıf bu artığı minimum yapacak sınıftır. Bu durumda sınıflandırma algoritması (5)'deki karar kuralına göre ilgili sınıfa atama yapacaktır.

$$\underset{i}{\operatorname{min}} r_i(x) = \|x - D\delta_i(a)\|_2 \quad (5)$$

Nihai olarak seyreklik tabanlı sınıflandırma (Sparse Representation Classification - SRC) algoritmasına ait sözde kod Algoritma 1'deki gibidir [2].

Algoritma 1: Seyreklik Tabanlı Sınıflandırma Algoritması (SRC) [2]

1. Giriş: D sözlüğü oluşturulur ve x test nesnesi belirlenir.
2. D sözlüğüne ait tüm atomlar birim ℓ_2 normuna göre normalize edilir.
3. ℓ_0 minimizasyon problemi çözülür:

$$a = \underset{a}{\operatorname{argmin}} \|a\|_0,$$

$$\|Da - x\|_2 \leq \varepsilon \text{ koşulu altında}$$
4. Her bir sınıf için artık hesabı yapılır:

$$\underset{i}{\operatorname{min}} r_i(x) = \|x - D\delta_i(a)\|_2$$
5. Karar verilir:

$$\operatorname{Sınıflandır}(x) = \underset{i}{\operatorname{argmin}} r_i(x)$$

B. Çekirdek Yaklaşımı

Çekirdek yaklaşımı literatürde sınıflandırmada sıkça kullanılan bir yaklaşımdır ve temelde doğrusal olmayan karar sınırları ile sınıflandırma yapabilmek amacıyla kullanılır. Doğrusal olmayan karar sınırları ile sınıflandırma yapabilmek için giriş uzayında doğrusal olarak sınıflandırılmayan veri kümesi, daha yüksek boyutlu bir uzayda temsil edilerek, bu uzayda doğrusal sınıflandırılır. Fakat bu doğrusal olmayan yüksek boyutlu öznelik uzayına geçiş ve orada işlem yapmak oldukça fazla işlem yükü getirebilmektedir.

Bu nedenle x verisinin $\Phi(x)$ öznelik uzayındaki temsilini, giriş uzayında hesap edebilecek bir yaklaşım uygulamak çok faydalı olmaktadır. Bu dönüşüm Mercer çekirdek teoreminden faydalanılarak yapılmaktadır [7]. Bir Mercer çekirdeği olan $k(x, y)$ fonksiyonunun Mercer şartlarını sağladığı düşünüldüğünde, $k(x, y)$ fonksiyonu Hilbert öznelik uzayındaki Φ dönüşümünü ifade eden bir fonksiyon olarak tanımlanabilmektedir ve $k(x, y) =$

$\langle \Phi(\mathbf{x}), \Phi(\mathbf{y}) \rangle$ iç çarpımlar cinsinden ifade edilebilmektedir [8, 9].

\mathbf{x} ve \mathbf{y} vektör olmak üzere, $k(\mathbf{x}, \mathbf{y}) = (1 + \mathbf{x}^T \mathbf{y})^d$ polinom çekirdek fonksiyonunu ve $k(\mathbf{x}, \mathbf{y}) = e^{(-\|\mathbf{x}-\mathbf{y}\|^2/t)}$ Gaussian çekirdek fonksiyonunu ifade eder. Her bir uygulama için en iyi sonucu veren d ve t parametreleri deneysel sonuçlar ışığında elde edilir.

C. Seyreklik Tabanlı Sınıflandırmada Çekirdek Yaklaşımı

SRC yönteminden farklı olarak çekirdek tabanlı yaklaşımdaki hedef, bu Φ doğrusal olmayan öznitelik uzayına dönüştürülmüş test nesnesini, yine Φ öznitelik uzayına dönüştürülmüş sözlük elemanları ile seyrek olarak temsil edebilmektir.

Bu durumda \mathbf{x} test nesnesi öznitelik uzayında $\Phi(\mathbf{x})$ olarak temsil edilir. Benzer şekilde sözlük (6)'daki gibi ifade edilir.

$$\Phi(\mathbf{D}) = [\Phi(\mathbf{D}_1), \Phi(\mathbf{D}_2), \dots, \Phi(\mathbf{D}_k)] \in \mathbb{R}^{s \times n} \quad (6)$$

Nihai olarak (4)'teki optimizasyon problemi (7)'deki optimizasyon problemine dönüşür.

$$\begin{aligned} \mathbf{a} &= \operatorname{argmin}_{\mathbf{a}} \|\mathbf{a}\|_0, \\ \|\Phi(\mathbf{D})\mathbf{a} - \Phi(\mathbf{x})\|_2 &\leq \varepsilon \text{ koşulu altında} \end{aligned} \quad (7)$$

(7) iç çarpımlar cinsinden ifade edilirse, $\Phi(\mathbf{D})^T \Phi(\mathbf{x}) = \langle \Phi(\mathbf{D}), \Phi(\mathbf{x}) \rangle = k(\mathbf{D}, \mathbf{x}) \in \mathbb{R}^{1 \times n}$ olmak üzere bir vektör ve $\mathbf{S} = \Phi(\mathbf{D})^T \Phi(\mathbf{D}) = \langle \Phi(\mathbf{D}), \Phi(\mathbf{D}) \rangle = k(\mathbf{D}, \mathbf{D}) \in \mathbb{R}^{n \times n}$ olmak üzere simetrik ve pozitif tanımlı gram matristir. Bu durumda çekirdek fonksiyonları ile ifade edilmiş optimizasyon problemi (8)'deki gibidir.

$$\begin{aligned} \mathbf{a} &= \operatorname{argmin}_{\mathbf{a}} \|\mathbf{a}\|_0, \\ \|\mathbf{S}\mathbf{a} - k(\mathbf{D}, \mathbf{x})\|_2 &\leq \varepsilon \text{ koşulu altında} \end{aligned} \quad (8)$$

Nihai olarak, bu çalışmada önerilen Çekirdek-Seyreklik tabanlı sınıflandırma (Kernel Sparse Representation Classification – K-SRC) algoritmasına ait sözde kod Algoritma 2'deki gibidir. Bu algoritma Nguyen ve diğerlerinin önerdiği sözlük öğrenmeli sınıflandırıcının [10] sözlük öğrenme kullanmayan daha basit bir versiyonu olarak düşünülebilir.

IV. DENEYSEL BENZETİM SONUÇLARI

Deneysel benzetim sonuçlarında gerçek hayatta geniş bir kullanım alanına sahip yüz tanıma ve rakam tanıma sistemleri için seyrek sınıflandırma algoritmalarının karşılaştırmalı performans testleri ele alınacaktır. SRC ve K-SRC algoritmaları için deneysel benzetim sonuçları MATLAB ortamında, en yakın komşuluk (Nearest Neighbour - NN) ve Doğrusal SVM algoritmaları ile karşılaştırılacaktır.

Algoritma 2: Çekirdek-Seyreklik Tabanlı Sınıflandırma Algoritması (K-SRC)

1. Giriş: \mathbf{D} sözlüğü oluşturulur, $k(i, j)$ çekirdek fonksiyonu seçimi yapılır ve \mathbf{x} test nesnesi belirlenir.
2. $\Phi(\mathbf{D})$ ve $\Phi(\mathbf{x})$ 'e ait tüm atomlar birim ℓ_2 normuna göre normalize edilir.
3. ℓ_0 minimizasyon problemi çözülür:

$$\begin{aligned} \mathbf{a} &= \operatorname{argmin}_{\mathbf{a}} \|\mathbf{a}\|_0, \\ \|\Phi(\mathbf{D})\mathbf{a} - \Phi(\mathbf{x})\|_2 &\leq \varepsilon \text{ koşulu altında} \\ \text{veya} \end{aligned}$$

$$\|\mathbf{S}\mathbf{a} - k(\mathbf{D}, \mathbf{x})\|_2 \leq \varepsilon \text{ koşulu altında}$$

4. Her bir sınıf için artık hesabı yapılır:

$$\min_i r_i(\mathbf{x}) = \|\Phi(\mathbf{x}) - \Phi(\mathbf{D})\delta_i(\mathbf{a})\|_2$$
 veya

$$\min_i r_i(\mathbf{x}) = \|k(\mathbf{D}, \mathbf{x}) - \mathbf{S}\delta_i(\mathbf{a})\|_2$$
5. Karar verilir:

$$\text{Sınıflandır}(\mathbf{x}) = \operatorname{argmin}_i r_i(\mathbf{x})$$

A. Yüz Tanıma

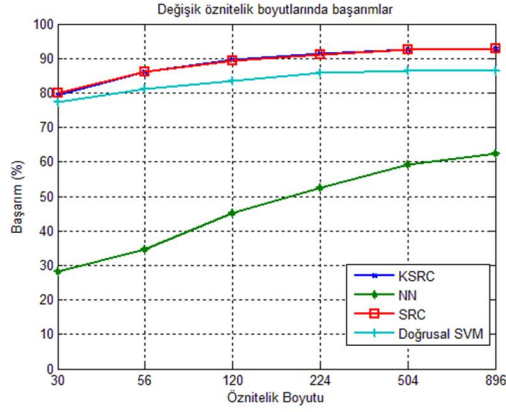
Bu bölümde yüz tanıma sistemine ait gerçekleştirilen deneysel benzetim sonuçları ele alınacaktır. Veri seti olarak Genişletilmiş (Extended) Yale B yüz veri seti kullanılmıştır. Bu veri seti 38 bireye ait toplam 2432 yüz resmi içermektedir. Her bir yüz için değişik laboratuvar ışıklandırma seviyelerinde ve değişik yüz duruşlarında toplam 64 resim bulunmaktadır.

Deneysel sonuçlar için veri seti sözlük ve test olarak ikiye ayrılmıştır. Bunun için veri seti içindeki her bir bireye ait 64 resmin yarısı rastgele test için (32 resim), diğer yarısı (32 resim) ise sözlük için ayrılmıştır. Nihai olarak $N_{\text{sözlük}}=1216$ ve $N_{\text{test}}=1216$ adet resimden oluşmuştur. Seyrek sınıflandırma algoritmaları için Van Nguyen ve diğerleri iki farklı sınıflandırma yaklaşımı önermiştir [10]. Birinci yaklaşım (İşbirlikçi) test nesnesini tüm sözlüğün doğrusal birleşimi ile seyrek ifade etmektir. İkinci yaklaşım (Dağıtık) ise test nesnesini her bir sınıfın sözlüğü ile ayrı ayrı seyrek ifade etmektir.

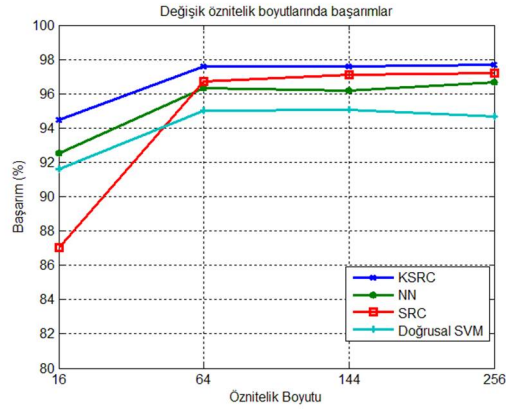
Yapılan deneysel sonuçlarda ikinci yaklaşımın daha yüksek performans gösterdiği belirlenmiş ve bu yöntem kullanılmıştır. Yüz tanıma deneyi için en yüksek başarıyı gösteren çekirdek fonksiyonu deneysel sonuçlarla $k(\mathbf{x}, \mathbf{y}) = (1 + \mathbf{x}^T \mathbf{y})^{0.6}$ olarak bulunmuştur.

SRC ve K-SRC algoritmaları için seyreklik seviyesi $T_0 = 5$, Abbas ve diğerlerinin [11] çalışması dikkate alınarak NN algoritması için en yüksek başarıyı veren k değeri 3 olarak alınmıştır. Ayrıca tüm algoritmalar 10 farklı sözlük ve test seti üzerinde 10 sefer oluşturulmuş ve başarımlar ortalamarı dikkate alınmıştır.

Şekil 1' den görülebileceği gibi tüm öznitelik boyutlarında en yüksek başarımları K-SRC ve SRC göstermiştir. SRC,



Şekil 1: Yüz tanıma için değişik sınıflandırıcılara ait başarımlar yüzdeleri.



Şekil 2: Rakam tanıma için değişik sınıflandırıcılara ait başarımlar yüzdeleri.

K-SRC'ye oldukça yakın başarımlar göstermiş ve fark sadece %0.2 seviyelerinde kalmıştır.

B. Rakam Tanıma

Bu bölümde çevrimdışı ve elle yazılmış rakam tanıma sistemine ait gerçekleştirilen deneysel benzetim sonuçları ele alınmıştır. Veri seti olarak USPS el yazması rakam veri seti kullanılmıştır [12]. Veri setindeki resimler, rakamlara odaklı olarak boyutları eşitlenmiş 16×16 gri seviyeli resimlerdir.

Deneysel sonuçlar için veri seti ikiye ayrılmıştır. Bunun için veri seti içerisindeki her bir rakama ait rastgele 350 resim test ve rastgele 350 resim sözlük için ayrılmıştır. Nihai olarak 10 farklı rakam için toplam test resmi sayısı $N_{test} = 3500$ ve sözlük resmi sayısı $N_{sözlük} = 3500$ olmuştur. SRC ve K-SRC algoritması için $T_0 = 10$ alınmış ve sınıflandırmalar dağıtık yaklaşımla yapılmıştır [10]. Yine bu çalışma dikkate alınarak USPS veri seti için K-SRC algoritmasında en yüksek başarımları veren çekirdek fonksiyonu, 4. derece polinom olarak seçilmiştir. Babu ve diğerlerinin [13] yaptığı çalışma dikkate alınarak NN algoritması için en yüksek başarımları veren k değeri 1 olarak alınmıştır.

Şekil 2' den görülebileceği gibi tüm öznitelik boyutlarında en yüksek başarımları K-SRC göstermiştir. SRC düşük öznitelik boyutunda en düşük performansı gösterirken diğer öznitelik boyutlarında K-SRC' den sonra en iyi performansı gösteren algoritma olmuştur.

V. SONUÇ

Bu bildiriye seyreklik tabanlı sınıflandırıcıların sözlük öğrenmesiz öncül bir versiyonu olan SRC'nin ve bunun çekirdek yaklaşımı ile çeşitlendirilmiş versiyonu olan K-SRC'nin seyrek sınıflandırmaya uygulanması ele alınmıştır. Seyreklik tabanlı SRC algoritması, çekirdek fonksiyonları vasıtası ile çok yüksek boyutlu öznitelik uzaylarında seyrek gösterilimi kullanan K-SRC algoritmasına dönüştürülmüştür. Bu algoritmalar ile gerçekleştirilen yüz tanıma ve rakam tanıma deneylerine bakıldığında, SRC ve K-SRC algoritmaları oldukça rekabetçi sonuçlar vermiş ve geleneksel sınıflandırıcılara önemli rakipler olabileceklerini göstermişlerdir.

KAYNAKÇA

- [1] Elad, M., Figueiredo, M. A. T. ve Ma, Y., "On the role of sparse and redundant representations in image processing", *Proc. IEEE*, 98(6):972-982, 2010.
- [2] Wright, J., Yang A. Y., Ganesh A., Sastry S. S. ve Ma, Y., "Robust face recognition via sparse representation", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31(2): 210-227, 2009.
- [3] Zhang, L., Yang, M., ve Feng, X., "Sparse representation or collaborative representation: which helps face recognition", *IEEE Conference on Computer Vision*, 471-478, 2011.
- [4] Deng, W., Hu, J., ve Guo, J., "Extended SRC: Undersampled face recognition via intraclass variant dictionary", *IEEE Trans. Pattern Anal. Mach. Intell.*, 34(9):1864-1870, 2012.
- [5] Zhang, L. ve Zhou, W., "On the sparseness of 1-norm support vector machines", *Neural Networks*, 23(3):373-385, 2009.
- [6] Gao, S., Tsang, I.W.-H. ve Chia, L.-T., "Kernel sparse representation for image classification and face recognition", *11th Eur. Conf. Comput. Vis.*, 6314, 1-14, 2010.
- [7] Vapnik, V., *The nature of statistical learning theory*. Springer-Verlag, New York, 1995.
- [8] Cortes, C. ve Vapnik V., "Support-Vector Networks", *Machine Learning IEEE*, 20 (3):273-297, 1995.
- [9] Courant, R. ve Hilbert, D., *Methods of Mathematical Physics*. Interscience. New York, 1953.
- [10] Van Nguyen, H., Patel, V.M., Nasrabadi, N.M. ve Chellappa, R., "Design of Non-Linear Kernel Dictionaries for Object Recognition", *IEEE Transactions on Image Processing*, 22(12): 5123-5135, 2013.
- [11] Ebrahimpour H. ve Abbas K., "Face Recognition Using Bagging KNN", *International Conference on Signal Processing and Communication Systems*, 17-19, 2007.
- [12] Hull, J.J., "A database for handwritten text recognition research", *IEEE Trans. Pattern Anal. Mach. Intell.*, 16(5):550-554, 1994.
- [13] Babu, U. R., Venkateswarlu, Y. ve Chintla, A. K., "Handwritten Digit Recognition Using K-Nearest Neighbour Classifier", *in Computing and Communication Technologies (WCCCT)*, 60-65, 2014.