

Rakam Tanıma için KNN ve LDA Algoritmalarının Karşılaştırılması

Halit Çetiner¹, Ömer Kuşcu²

^{1,2}Süleyman Demirel Üniversitesi, Araştırma ve Uygulama Hastanesi, Bilgi İşlem Merkezi, Isparta
halitcetiner@sdu.edu.tr, omerkucucu@sdu.edu.tr

Özet: Görüntü sınıflandırma, yapay zekânın en önemli araştırma alanlarından biridir. Görüntü sınıflandırma uygulamaları, optik karakter tanıma karakter tanınmanın gelişmesi yönünde ilerlediği görülmektedir. Karakter tanıma son yüzyılda geniş bir şekilde uygulama alanı bulmuştur. Uygulama alanları posta kodlarının okunması, araç plakası tanıma, barkod okuma, banka çeklerinin otomatik okunması, büro otomasyonu, reklam, afiş, market panolarının okunması, yol işaretlerinin okunarak araçların yönlendirilmesi, çeşitli bankalara ait kart numaralarının tanınması gibi farklı alanlardaki karakter tanıma çalışmalarından oluşmaktadır. Bu gibi farklı uygulama alanlarında artan isteği karşılayabilmek için daha gelişmiş yöntemlere gereksinim duyulmaktadır. Bu makalede, kimlik kartlarından elde edilmiş rakamlar üzerinde doğrusal ayırt edici analiz (LDA) ile en yakın k komşu algoritması (KNN) sınıflandırıcılarının karakteristikleri tartışılmıştır. İki farklı sınıflandırıcı, moment değişmezleri ile elde edilen özniteliklerinin sınıflandırma doğruluğu, eğitim/test süreleri incelenerek karşılaştırılmıştır. Eğitim/test sürelerinin yaklaşık olarak aynı olmasına karşın sınıflandırma doğruluğu açısından KNN sınıflandırıcı LDA sınıflandırıcıdan daha yüksek başarı vermektedir.

Anahtar Sözcükler: KNN, LDA, Karakter Tanıma, Değişmez Momentler

Comparison of KNN and LDA Algorithm for Digit Recognition

Abstract: Image classification is one of the most important research areas of artificial intelligence. Image classification applications are viewed to advancing in the direction of the development of character recognition in optical character recognition. Character recognition has found a wide range of applications in last century. Application areas consist of character recognition studies in different fields such as recognition of card numbers belonging to various banks, directing of vehicles by reading road signs, advertising, banner, reading of market boards, office automation, automatic reading of bank checks, barcode reading, license plate recognition, reading of postal codes. More sophisticated methods are needed in order to meet the increasing request in this is a different application area. In this article, characteristics of the linear discriminant analysis (LDA) and k-nearest neighbor (KNN) classifiers on the figures which are obtained identity cards is discussed. Two different classifiers are compared by examining training/test periods, classification accuracy of features which are obtained with Hu moment invariants. Although training/test periods are approximately the same, in terms of classification accuracy LDA classifier give higher success than LDA classifier.

Keywords: KNN, LDA, Character Recognition, Invariant Moments

1. Giriş

İlk karakter tanıma çalışması, körler için Rus bilim adamı Tyurin tarafından 1900 yılında yapılmıştır. 1950'li yıllarda donanım olarak tasarlanan OKT makineleri, farklı fontlardaki rakamları tanıyabilmekteydi. 1970'lerde ise farklı fontlardaki metinler yazılımla tasarlanan otomatik metin okuyucuları ile okunabilmekteydi. O ana kadar okuma algoritmaları ana yapılarla ve mini bilgisayarlarla yapılmaktaydı. 1980'lere gelindiğinde ise okuma makineleri iyice yaygınlaşmıştı ve aynı sayfada yer alan farklı fontlardaki metinler bile tanınmaktaydı. Ancak asıl gelişme, kişisel bilgisayarların marketlerde yer alması ve yaygın olarak kullanılmasıyla başladı. Bazı ticari firmalar, farklı tarzlardaki yazı şekillerini,

hatta el yazısını, farklı dillerin alfabelerini yüksek oranlarda çevrimdışı olarak tanımayı başardılar ([1]; [2]) Günümüzde ise karakter tanıma alanındaki çalışmalar büyük uygulama alanı bulmuş ve kendine görüntü tanıma içinde ayrı bir yer edinmiştir. Uygulama alanları olarak posta kodlarının okunması, araba plakası okuma, barkod okuma, banka çeklerinin otomatik okunması, büro otomasyonu, reklam, afiş, market panolarının okunması sayılabilmektedir [3]. Karakter tanıma alanının geniş uygulama alanı göz önünde bulundurularak yapılan çalışmada rakamların görüntülerini içeren görüntü kümeleri (RIGK)'den elde edilen rakamlar kullanılarak bir veri tabanı oluşturulmuştur. Değişmez momentleri yöntemi kullanılarak bu veri tabanında bulunan rakamlardan öznitelikler çıkarılmıştır. Bu öznitelikler RIGK

üzerinde tespit edilen ve bölütlenen rakamların sınıflandırılmasında ve tanınmasında kullanılmıştır. Sınıflandırılma işleminde en yakın komşu algoritması (KNN) ve doğrusal ayırt edici analiz (LDA) algoritmaları kullanılmış ve bu algoritmaların bu görüntüler üzerindeki doğruluk oranları, eğitim ve test süreleri karşılaştırılmıştır. Çalışmanın ilerleyen bölümlerinde görüntünün dosyadan işlenebilir halde okunması, okunan görüntü üzerinde kırpma, parlaklık ayarı gibi ön işlemler yapılmıştır. Ön işlemde geçen görüntü gri seviye formatına dönüştürülmüş ve görüntüye özgü belirlenen eşik değeri yardımıyla görüntü ikili formata dönüştürülmüştür. Bu aşamadan sonra bağlantı bileşen analizi ile görüntü üzerindeki gürültüler belirlenerek temizlenmiştir. Gürültüden temizlenen görüntü üzerinden alınan yatay histogram ile RIGK üzerinde rakam olabilecek alanların tespiti yapılarak, bu alanlar belirlenmiştir. Belirlenen alanlar üzerinden dikey histogramlar ile RIGK üzerindeki rakamların olabileceği bölgeler belirlenmiştir. RIGK üzerindeki rakamların tespiti için histogram sonucunda ardışık olarak ayırık nesnenin bulunduğu bölgeler rakam bölgesi olabileceği araştırmak üzere işaretlenmiştir. İşaretlenen bölgeler üzerinde bölütler arasında dikey histograma göre nesnelere arası boşlukların hesaplanarak rakam bölgeleri belirlenmiştir. RIGK rakamlarının olduğu bölge tespit edildikten sonra rakam olabilecek bölgeler bölütlenerek kenar boşluklarının silinmesi ve ölçekleme gibi ön işlemlerden geçirilerek öznelik çıkarma algoritmasına parametre verilerek bu bölgelerin öznelikleri değişmez momentler ile çıkartılmıştır. Görüntüden çıkartılan bu öznelikler sırasıyla KNN ve LDA algoritmaları ile sınıflandırılıp tanıma başarı oranları kıyaslanmıştır. Bu noktada yetersiz özneliklerine rağmen doğru tanıma oranları kıyas edildiğinde KNN algoritmasının daha başarılı olduğu tespit edilmiştir.

2. İlgili Çalışmalar

Bu alanda son yıllarda yapılan çalışmalardan 3 tanesi kısaca incelenmiştir. İncelenen makalelerden bir tanesinde Osmanlı karakter tanıma sistemi için yeni bir LDA öne sürmüşlerdir. LDA, orijinal veri setleri içerisindeki çeşitlilikleri mümkün olduğu ölçüde temsil ederken verilerin boyutlarını azaltmaktadır. Öne sürülen sistemde, her Osmanlı dili alfabetine ait karakterden 33 sınıf içeren bir eğitim sınıfı oluşturulmuştur. İlk olarak eğitim seti görüntüleri, aydınlatma ve boyuttaki çeşitlilikleri azaltabilmek için normalleştirilmiştir. Sonrasında, ayırt edici olan öznelikleri LDA ile çıkartılmıştır. LDA'yı

uygulayabilmek için eğitim setindeki örnek sayısı her bir örneğin öznelik sayısından fazla olmalıdır. Bunu başarabilmek için, ön aşama olarak temel bileşen analizi kullanılmıştır. Tanımlanan süreçler aynı zamanda eğitilmemiş test görüntülerine uygulanmıştır. Sınıflandırma için en yakın k komşu algoritması kullanılmıştır [4].

İncelenen bir diğer makalede ise araç plaka karakterlerinin tanınması ve bu tanınan karakterlerinin şifreleme ve şifre çözme teknikleri kullanarak güvenlik ağ kanalları ile iletilmesi ile uğraşmıştır. Bu makale, plaka tespiti, uygun karakterlerinin bölütlenmesi süreci, normalizasyon ve tanıma adımlarını açıklamaktadır. Otomatik plaka tanıma sistemi gerçek zamanlı çalışan gömülü sistemler ile otomatik olarak plakaları tanıyabilmektedir. Bu makalede, değişik algoritmalar ile gerçekleştirilen plakalardan karakterlerin tanınmasından sonra, karakterler güvenli kanal ile iletilmektedir. Plaka rakamları gibi tanınmış karakterlerin güvenli iletilmesi için, Steganografi teknikleri kullanılmıştır. İlk olarak tanımlanmış karakterler görüntüye gömülmüştür ve bu veri son gönderenin özel anahtarı kullanılarak şifrelenmiştir. Son alıcıda, veri şifre çözme teknikleri kullanarak görüntüden çıkartılmıştır [5].

Üçüncü ve son olarak incelenen makalede ise Hindistan gibi çok dilli ülkelerde, bir doküman birden fazla dilde metin sözcükleri içerebilmesi göz önünde bulundurularak yapılan bir çalışma incelenmiştir. Bu makalede farklı sektörlerdeki, daha geniş bir kitleye ulaşabilmek için farklı dillerde kelimeler içeren belgenin dijital ortamda tanınması sağlanmaya çalışılmıştır. Öncelikle olarak optik karakter tanıma işleminden önce kelimelerin hangi dilde yazıldığı tespit edilmesi gerekmektedir. Çok sayıdaki dili tanımlayabilen tek bir tanımlayıcı tasarlamak imkânsızdır. Bu yüzden, optik karakter tanıma sisteminin belgenin dil bölgesinin tanımlanması gerekmektedir. Tanımlama, elektronik kitaplar, magazinler, haber gazeteleri, makaleler gibi dijital ortamda basılmış belgelere ait bilgileri çıkartabilmeyi amaçlamaktadır. Buda birçok dil desteği olan tanıma sisteminin tasarlanmasına yol açmaktadır. Bu makalenin amacı, belgenin farklı metin bölümlerini tanımlayabilmek için yöntem tabanlı görsel ipuçları geliştirilmiştir. Bu çalışmada, tepe maksimum satır, alt maksimum satır, tepe yatay satırlar, yatay satırlar, alt bileşenleri, tik bileşenleri, tepe delikleri ve alt delikleri dili tanımlayabilmek için kullanılmıştır. Telegu, Hintçe ve İngilizce dillerinde yazılmış kelimeleri içeren belgeleri tanımlayabilmek için sezgisel tabanlı ve KNN tabanlı bir yöntem öne sürülmüştür.

Deneylerden anlaşılan şudur ki tanımlama oranı %95'tir [6].

3. Rakamları İşleme Algoritması

Rakam içeren görüntüler önceden yapmış olduğum [12] çalışmasından elde edilmiştir. İçerisinde rakam içeren görüntülerin bulunduğu sistemde, görüntülerin okunması, yapılan ön işlemler, rakamların elde edilmesi ve diğer öznelik çıkarma, sınıflandırma ve tanıma adımlarının temel algoritma işleyişi aşağıda belirtilen adımlardan oluşmaktadır:

- a. Dosyadan görüntü okuma işlemi
- b. Kimliği kısaltma (Crop ile [200,30,genişlik, yükseklik] değerlerinde kesme işlemi gerçekleştirilir [12])
- c. Parlaklık hesabı yapma.
 - 1.. Eğer parlaklık değeri <50 ise ayrı bir algoritma uygula
 - 2.. Eğer parlaklık değeri >=50 ise ayrı bir algoritma uygula
- d. Gri seviyeye görüntüyü dönüştürme
- e. Görüntü parlaklık ayarı (3.maddedeki parametreye göre)
- f. Eşik değeri belirleme
- g. İkili görüntüye çevirme
- h. Bağlantı bileşen analizi ile görüntülerin temizlenmesi
- i. Yatay histogram ile RIGK olabilecek alanların tespiti ve bölütlenmesi [12]
- j. Yatayda bölütlenen RIGK olabilecek bölütlerin dikey histogramının alınması [12]
- k. Ardışık nesne sayısına göre bölütlerin tespiti [12]
- l. Bölütler arasında dikey histograma göre nesnelere arası boşlukların hesaplanarak rakamsal bölgelerin olup olmadığı kontrolü yapılıyor. [12]
- m. L adımından geçen bölütler dikey histograma göre parçalanır (rakam olabilecek bölge tespiti) [12]
- n. Rakamların 4 bölgesindeki padding değerleri temizlenir. Rakamlar 80x52 olarak boyutlandırılır.
- o. Her bir rakam bölgesinin öz nitelikleri değişmez momentleri yardımıyla çıkartılmaktadır.
- p. Çıkartılan öznelikleri LDA algoritması ile sınıflandırma ve tanıma işlemi yapılmaktadır.
- q. Çıkartılan öznelikleri KNN ile sınıflandırma ve tanıma işlemi yapılmaktadır.

4. Öznelik Çıkarma

Aynı karakterin farklı durumlarını tanımlayabilmek için karakterlerin farklı dönüşümlerinde, varyasyonlarında karakter özneliklerinin sabit,

değişmez olması gerekmektedir. Orijinal resmin döndürülmüş, ölçeklendirilmiş, gerilmiş, eğimli, eğimsiz, simetriği alınmış her durumda özneliklerin sabit kalması gerekmektedir. Bu noktada farklı frekans ve ölçeklerdeki görüntüyü en iyi temsil edecek Hu [7]'nin değişmez momentleri yöntemi tercih edilmiştir.

4.1 Değişmez Momentleri Yöntemi

Örüntü analizi alanında en temel konu, boyut, konum ve yönelimine bakılmaksızın karakterlerin ve nesnelerin tanınmasıdır. Hu [7], cebirsel değişmezleri kullanılarak küme değişmezlerini türettiğinde şekil tanımda momentlerin kullanım fikriyle büyük bir ün kazanmıştır. Sayısal ortamda M x M boyutundaki görüntünün iki boyutlu momentleri gri fonksiyona sahiptir [8].

$$f(x, y), (x, y = 0, \dots, M - 1)$$

gri fonksiyonu;

$$m_{pq} = \sum_{x=0}^{M-1} \sum_{y=0}^{M-1} (x)^p (y)^q f(x, y) \quad (1)$$

$$p, q = 0, 1, 2, 3 \dots$$

$f(x, y)$ momentleri (a, b) toplamına dönüştürülmüştür, Eş. 2'deki gibi tanımlanmıştır.

$$\mu_{pq} = \sum_x \sum_y (x + a)^p \cdot (y + b)^q f(x, y), \quad (2)$$

Böylece m'_{pq} veya μ_{pq} merkezi momentleri $a = -\bar{x}$ ve $b = -\bar{y}$ yerine koyularak Eş. 2'den hesaplanabilmektedir;

$$\bar{x} = \frac{m_{10}}{m_{00}} \text{ ve } \bar{y} = \frac{m_{01}}{m_{00}},$$

$$\mu_{pq} = \sum_{x=0}^{M-1} \sum_{y=0}^{M-1} (x - \bar{x})^p (y - \bar{y})^q f(x, y) \quad (3)$$

Ölçeklenmiş normalleştirme merkezi moment değişikliklerine uygulandığında,

$$\eta_{pq} = \frac{\mu_{pq}}{\mu_{00}^{\gamma}}, \quad \gamma = [(p + q)/2] + 1 \quad (4)$$

Özellikle, Hu [7], ölçekleme, pozisyon ve yönelime ölçeklenmiş sıralı 3 aracılığıyla normalleştirilmiş merkezi momentleriyle hesaplanan 7 değeri tanımlamıştır [8]. Merkezi momentleri bakımından, 7 momentler aşağıdaki Eş. 5'de verilmiştir:

$$M_1 = (\eta_{20} + \eta_{21}),$$

$$M_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2,$$

$$M_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2,$$

$$\begin{aligned}
 M_4 &= (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2, \\
 M_5 &= (\eta_{30} - 3\eta_{12})^2 (\eta_{30} + \eta_{12}) [(\eta_{30} + \eta_{12})^2 - \\
 & \quad \eta_{21} + \eta_{03}] + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03}) [\\
 & \quad 3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2], \\
 M_6 &= (\eta_{20} - \eta_{02}) [(\eta_{30} + \eta_{12})^2 - \\
 & \quad (\eta_{21} + \eta_{03})^2] \\
 & \quad + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \\
 M_7 &= (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12}) [(\eta_{30} + \eta_{12})^2 - \\
 & \quad 3(\eta_{21} + \eta_{03})^2] - (\eta_{30} + 3\eta_{12})(\eta_{21} + \eta_{03}) [3 \\
 & \quad (\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]
 \end{aligned} \quad 3($$

5. Sınıflandırma

Sınıflandırmada öğrenme ve test aşamalarını içeren yöntemler kullanılmıştır. Öğrenme aşamasında ön işlemlerden geçirilmiş her bir rakam için değişmez momentleri kullanılarak öznelikleri çıkarılmaktadır. İkinci adımda önceden belirlenen hedef değerlerine göre sınıflandırma işlemi yapılmaktadır. Öğrenme fazında, RIGK görüntülerinden elde edilmiş 116 tane görüntüden oluşmuş bir veri seti kullanılmaktadır [12]. Genel Öğrenme Algoritması:

Giriş: n kimlik kartının n rakamlı ön işlenmiş m x n'lik görüntü

Çıktı: her bir kimlik kartındaki her bir rakam için değişmez momentleriyle elde edilmiş 7 öznelikten oluşan öznelik vektörü

```

1.   for k=1 to m ( her bir rakam sınıfı için)
      for i=1 to rakam örneklerinin numarası
          Ön işlemlerden geçirme
          Hu momentleriyle 7 öznelik değerini
          hesapla
          end
      end
end

```

5.1 KNN Test/Sınıflandırma Yöntemi

Bu modelde, en yakın k komşu algoritması test örneklerini sınıflandırabilmek için kullanılmıştır. Hu momentleri kullanılarak her bir rakam görüntüsü için 7 tane öznelik elde edilmiştir. Öklid mesafesi, test örnekleri ve k komşusu arasında hesaplanmıştır. Öklid mesafesi formülü Eş. 6'da verilmiştir:

$$D(M) = \sqrt{\sum_{j=1}^N [f_j(x) - f_j(M)]^2} \quad (6)$$

öznelik vektöründe N öznelik sayısını göstermektedir. $f_j(x)$, X test örneğinin j^{th} özneliğini temsil etmektedir. $f_j(M)$, M^{th} sınıfının j^{th} özneliğini temsil etmektedir. Sonrasında test örneği X , en yakın komşu algoritması kullanılarak sınıflandırılmıştır. En yakın k komşu algoritmasında,

bir test örneği pozitif değere sahip bir k komşu değeriyle sınıflandırılmaktadır. Bu makalede yapılan deneysel çalışmalarda k=3 alınmıştır.

5.2 LDA Test/Sınıflandırma Yöntemi

LDA'nın temel fikri, dönüşüm sonrası en ayırt edilebilir öznelik kümeleri kullanılarak kümelerin doğrusal dönüşümlerini bulmayı amaçlamaktadır [11]. M sınıflı bir problem için, S_b ve S_w matrisleri arasında aşağıda Eş. 7 ve 8'deki gibi tanımlanmaktadır:

$$S_b = S_b = \sum_{i=1}^M P_r(C_i) (\mu_i - \mu)(\mu_i - \mu)^T = \Phi_b \Phi_b^T, \quad (7)$$

$$S_w = \sum_{i=1}^M \Pr(C_i) \Sigma_i = \Phi_w \Phi_w^T, \quad (8)$$

$\Pr(C_i)$, C_i sınıfının öncelikli olasılıklarıdır ve genellikle eşitlik önceliklerinin varsayımları ile $\frac{1}{M}$ atanır; μ ortalama vektörüdür; Σ_i ise μ_i ortalama vektörü temsil eden C_i farklı sınıflarının örnek vektörlerinin ortalama dağılımıdır:

$$\Sigma_i = E[(x - \mu_i)(x - \mu_i)^T | C = C_i], \quad (9)$$

Sınıf ayrımı belirli kriterler ile ölçülebilmektedir. Genel kullanımı, örneklerin sınıf dağılım matrisleri içerisinde ve örneklerin sınıf dağılım matrisleri arasındaki determinant oranıdır:

$$J(A) = \arg \max \frac{|A S_b A^T|}{|A S_w A^T|}, \quad (10)$$

Burada A , $m \times n$ boyutlarında bir matristir ($m \leq n$). Eş. (10)'daki optimizasyon probleminin çözümü genelleştirilmiş öz değer problemini çözmektedir [9]:

$$S_b A^* = \lambda S_w A^*, \quad (11)$$

$$D_i(X) = A^{*T} (X - \mu_i), \quad i = 1, 2, \dots, m, \quad (12)$$

Eş. (11), $S_w^{-1} S_b$ matrisi için öz değer problemini çözmekte ve S_w 'nin tersini hesaplamaktadır [9]. Fakat, bu yöntem sayısal olarak kararsızdır. Çünkü bu yüksek boyutlu matrislerin tersini içermektedir. Pratikte en sık kullanılan LDA algoritması paralel köşegenlemeyi temel almaktadır [10]. Bu algoritmanın temel fikri S_w ve S_b 'nin her ikisini paralel köşegenleştiren A matrisini bulmaktır [11].

Genel Test Algoritması:

Giriş: kimlik kartlarındaki rakamlardan elde edilmiş rakam görüntüleri


Çıktı: her bir rakamın sınıf tipi

1. Her bir rakam sınıfı için tekrarlar
2. Her bir rakam sınıfındaki rakam için tekrarlar
 - a.KNN sınıflandırıcı kullanılarak değişmez momentleri ile elde edilmiş özniteliklerinin sınıflandırılması
 - b.LDA sınıflandırıcı kullanılarak değişmez momentleri ile elde edilmiş özniteliklerinin sınıflandırılması
 - c.Doğruluk = (tanımlanmış rakamların sayısı / rakam kümelerindeki toplam rakam sayısı)* 100
 - d.Zaman ve doğruluk oranı açısından performans karşılaştırılması

6. Deneysel Çalışmalar

LDA ve KNN algoritmalarının, değişmez momentleriyle elde edilmiş rakam özniteliklerinin sınıflandırmasında başarı oranlarını analiz edebilmek için bir çalışma yapılmıştır. Bu çalışma, MATLAB 7.14 sürümünde gerçekleştirilmiştir. Deney sonuçları, 4GB RAM'li Intel Core i5 CPU (2.06 GHz) işlemciye sahip Windows 7 işletim sistemi üzerinde elde edilmiştir.

Her klasörde farklı bir rakam bulunmak üzere farklı kimliklerden bölütlenmiş ikili görüntüler bulunmaktadır. 10 klasör içerisinde, her klasörde 116 tane örnek olmak üzere toplam 1160 tane örnek vardır. Bu örneklerin her birinden 7 tane olmak üzere 1160x7 tane öznitelik elde edilmiştir.



Şekil 37. Eğitim kümesindeki ilk 20 örnek [12]

Şekil 1.'de örüntü kümesindeki örneklerin ilk 20 örneği gösterilmiştir. Geliştirilen uygulamada elde edilen öznitelikleri, 4. Bölümde anlatılan algoritmalarda testler yapılmıştır. Yapılan testler

sonucunda elde edilen test sonuçları aşağıdaki tablolarda gösterilmiştir.

Tablo 10 1160 tane rakam görüntüsünün eğitim işlemi sınıflandırma süreleri

Algoritma	Eğitim Zamanı (sn)
LDA	22.730
KNN	22.652

Tablo 11 1160 tane rakam görüntüsünün test işlemi tanıma süreleri

Algoritma	Test Zamanı (sn)
LDA	2.903
KNN	2.990

Doğruluk = (tanımlanmış rakamların sayısı / rakam kümelerindeki toplam rakam sayısı)* 100 ifadesine göre sınıflandırıcıların doğruluk oranları tespit edilmiştir.

for rakamKumesi=1:sonaKadar

[rakamSayisi]=bul(tahminiDegerler(rakamKumesi,:))=rakamKumesi);

Doğruluk=(uzunluk(rakamSayisi)/oruntuKumesindekiRakamSayisi)*100;

yazdır('%d rakamının tanıma oranı: %3f\n',rakamKumesi,doğruluk);

end

Tablo 12. 1160 tane görüntünün doğrulama işlemi süreleri

Algoritma	Doğrulama Zamanı (sn)
LDA	0.001
KNN	0.002

Tablo 13. Rakamların sınıflandırma tipine göre yüzdelik tanıma oranları

Rakam	LDA	KNN
0 (%)	100	100
1 (%)	97	100
2 (%)	97	100
3 (%)	98	100
4 (%)	95	100
5 (%)	100	100
6 (%)	63	100
7 (%)	100	100

8 (%)	91	100
9 (%)	60	100

Tablo 14. Eğitim, Test ve Doğrulama Toplam Zamanı (sn)

Algoritma	Toplam Zaman (sn)
LDA	26.431
KNN	26.635

Tablo 1-5 tablolarından da açıkça görülebileceği gibi deneysel çalışmaların başlangıcında belirtilen deney koşulları altında eğitim/test sürelerinin yaklaşık olarak aynı olmasına karşın sınıflandırma doğruluğu açısından KNN sınıflandırıcının LDA sınıflandırıcıdan daha başarılı olduğu gözlenmiştir.

4. Sonuç ve Öneriler

Görüntü sınıflandırma uygulamalarından, karakter tanıma alanında son yarım yüzyılda geniş bir şekilde uygulama alanı bulmuş olması göz önünde bulundurularak bir çalışma yapılmıştır. Bu makalede, kimlik kartlarından elde edilmiş rakamlar üzerinde LDA ile KNN sınıflandırıcılarının karakteristikleri tartışılmıştır. İki farklı sınıflandırıcı, değişmez momentleri ile elde edilen özniteliklerinin sınıflandırma doğruluğu, eğitim/test süreleri incelenerek karşılaştırılmıştır. Eğitim/test sürelerinin yaklaşık olarak aynı değildir. Ancak öznitelik seçim algoritması yetersiz bir algoritma olması olmasına karşın sınıflandırma doğruluğu açısından KNN sınıflandırıcının LDA sınıflandırıcıdan daha başarılı olduğu gözlenmiştir. İleride yapılacak çalışmalarda daha geniş veri setleri üzerinde iki boyutlu ayrık dalgacık yöntemler, gri seviye birleşim matrisi, gabor filtreler gibi farklı öznitelik seçim algoritmaları üzerinde denemeler yapılarak bu algoritmaların en iyi özelliklerini alan yeni bir öznitelik çıkarım algoritması öne sürülebilir. İkinci olarak belirtilen öznitelik çıkarım algoritmaları en ayırt edici öznitelikleri seçecek şekilde birden fazla klasik öznitelik çıkarım algoritmalarından melez bir yaklaşım öne sürülebilir. Son olarak da bu algoritmaların endüstride hatasız kullanılması gerektiğinden değerlendirme noktasında KNN, LDA ve yapay sinir ağları gibi başarılı sınıflandırma algoritmaları ile test edilebilir.

5. Kaynaklar

- [1] Alshebeili, S. A., Nabawib, A. A. F., Mahmoud, S. A., “Arabic character recognition using 1-D slices of the character spectrum”. *Signal Processing V. 56*, pp. 59-75, 1997.
- [2] Chim, Y. C., Kassim, A., Ibrahim, Y., “Character recognition using statistical moments”. *Image and Vision Computing V. 17*, pp. 299-307, Singapore, 1999.
- [3] Çetiner, H., “Görüntü işleme teknikleri kullanarak optik karakter tanımlama”, SDÜ, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 2012.
- [4] Kurt, Z., Turkmen, H., İ., Karşlıgil, M.E., “Linear Discriminant Analysis in Ottoman Alphabet Character Recognition”, *ECC 2007*,(2007).
- [5] Tatale, S., Khare, A., “Character recognition and transmission of characters using network security”, *International Journal of Advances in Engineering&Technology*, (2011).
- [6] Das, M. S., Rani, D. S., Reddy, C., Govardhan, A., “Script identification from multilingual Telugu, Hindi and English Text Documents”, *International Journal of Wisdom Based Computing*, Vol. 1(3), (2011).
- [7] Hu, M., “Visual pattern recognition by moment invariants”. *IRE Trans. Inf. Theor. IT-8*: 179–187, (1962).
- [8] Mercimek, M., Gülez, K., Mumcu, T. V., “Real object recognition using moment invariants”, *Sadhana Vol. 30*, pp. 765-775, (2005).
- [9] Wilks, S. S. “*Mathematical Statistics*”, New York: Wiley, (1962).
- [10] Fukunaga, K., “*Introduction to Statistical Pattern Recognition*”. New York: Academic Press, (1990).
- [11] Yang, J, Yu, H., Kunz, W., “An efficient LDA algorithm for face recognition”, (2000).
- [12] Çetiner, H., Cetişli, B., Çetiner, İ., “Gerçek zamanlı T.C. kimlik numarası tanıma”, *SAÜ., Fen Bilimleri Dergisi*, (2012).