

YÜZ TANIMA UYGULAMALARINDA ÖZYÜZLER VE YAPAY SİNİR AĞLARININ KARŞILAŞTIRILMASI

COMPARISON OF EIGEN FACES AND ARTIFICIAL NEURAL NETWORKS IN FACE RECOGNITION

Hakan KEKÜL*
Hüdaverdi BİRCAN**
Halil ARSLAN***

Öz

Bu çalışma ile yüz tanınmanın iki temel metodu olan görünüm ve öznitelik tabanlı yöntemlerin modellenerek karşılaştırılması ve iki metodun yüz tanıma sistemlerinde farklı alternatifler oluşturacak şekilde modellenmesi amaçlanmıştır. Bu amaçla görünüm tabanlı yöntem için özyüzler ve öznitelik tabanlı yöntem için ise yapay sinir ağları kullanılmıştır. Özyüzler ve yapay sinir ağları için farklı veri tabanları kullanılarak sistemler eğitilmiş ve test verileri ile yöntemlerin sonuçları karşılaştırılmıştır. Farklı durumlardaki tanıma performansları ve yüz tanıma probleminin zorlukları karşısındaki başarımları değerlendirilmiştir. İki sistemin farklı durumlar için birbirinin alternatifi olabileceği belirlenmiştir.

Anahtar Kelimeler: *Yüz Tanıma, Özyüzler, Yapay Sinir Ağları*

Abstract

In this study, two basic methods of face recognition and comparison with the operation of the feature-based methods and modeled in face recognition systems two methods are intended to be designed so as to generate different alternatives. For this purpose, eigenfaces for the view-based method and artificial neural Networks for the feature-based method are used. The systems were trained using different data bases for eigenfaces and artificial neural networks, and the results of the test data and Networks were compared. The recognition performances in different situations and their performance against the difficulties of the face recognition problem have been evaluated. It has been determined that the two systems may be alternatives for different situations.

Keywords: *Face Recognition, Eigenfaces, Artificial Neural Networks*

* Cumhuriyet Üniversitesi, Sosyal Bilimler Enstitüsü, hakankekul@gmail.com

** Doç. Dr., Cumhuriyet Üniversitesi, İşletme Bölümü, hbircan@gmail.com

*** Dr.Öğr. Üyesi, Cumhuriyet Üniversitesi, Bilgisayar Mühendisliği Bölümü, harslan@cumhuriyet.edu.tr

1. GİRİŞ

Bilişim teknolojilerinde yaşanan gelişmelerle birlikte hayatımıza giren pek çok yenilik olmuştur. Bunlardan bir tanesi ise biyometrik kimlik tespit teknolojisi. Bu teknolojiler hızla gelişmekte ve kendisine kullanım alanı bulmaktadır. Bir sektör haline de gelen global biyometrik sanayi, yayınlanan bir pazar araştırması çalışmasına göre, 2017 yılında 16.47 milyar doları aşan bir pazar büyüklüğüne kavuşacağı öngörülmüştür (New report predicts Global Biometrics Market, 2011). Bu teknolojinin alt dallarından biri ise yüz tanıma sistemleridir. Yüz tanıma sistemleri, insanların dijital imgeler halinde kaydedilmiş yüzleri ile eğitilen bir sisteme, insanların eğitim aşamasında kullanılmayan yeni bir dijital yüz imgesi verildiğinde kimlik tespitinin yapıldığı uygulamalardır.

Yüz tanıma, yüksek güvenlik ihtiyacındaki artış, internette çok fazla miktarlarda (sosyal medya hesapları vb.) dijital yüz imgelerinin bulunması ve görüntü yakalama araçlarındaki hızlı gelişmeler sonucunda giderek daha önemli bir hale gelmiştir (Jain ve Li, 2011). Herhangi bir fiziksel temasa ve mevcut görüntüleme cihazları ile gelişmiş bir donanıma ihtiyaç duymadan elde edilen görüntülerle çalışabilmesi yüz tanıma sistemlerinin en büyük avantajıdır (Jain ve Li, 2011). İdeal olmayan şartlarda yüz tanıma sistemlerinin başarı sağlamakta zorlanmasına karşın, görüntülerin elde edilmesinde kullanıcılara müdahale edilmemesi nedeniyle sağlanan yüksek kullanıcı kabulü kontrollü ortamlarda kabul edilebilir düzeylerde tanıma performansı sağlamaktadır (Pike, 2007). Yüz tanıma sistemlerinin temel amacı insan beyninin gerçekleştirdiği gibi bir tanıma işlemi makineler aracılığı ile gerçekleştirmektir. İnsan beyninin yüzleri nasıl tanıdığı tam olarak bilinmemesine rağmen beynimizin yüz tanıma işleminde oldukça başarılı olduğu açıktır. Yüz tanıma probleminin çözümünde farklı pek çok metod önerilmiş olsa da araştırmacıların yapmış oldukları çalışmalar, insan beyninin belirli yüz özelliklerini tanıma amacıyla kullandığını ortaya koymuştur (Goldstein vd., 1971; Haig, 1985; Rhodes, 2013). Yüz tanıma problemi bilim insanlarının üzerinde yoğun olarak çalıştıkları güncel, önemli ve zor problemlerden biridir. Günümüzde artan güvenlik gereksinimleri diğer biyometrik yöntemlere olduğu gibi yüz tanıma olan ihtiyacın ve ilginin artmasına neden olmuştur. Bu konuda uzun zamandır çok sayıda bilimsel çalışma yapılmasına karşın, gerçek yaşamda karşılaşılan sorunları çözmeye yetecek başarıya sahip yüz tanıma sistemleri hala geliştirilmeye devam etmektedir. Yüz tanıma probleminin zorlukları arasında; pozdaki değişimler, ışık kaynağının yeri ve şiddetindeki değişimler, yüz ifadesindeki değişimler, ölçek sorunu, zamanla veya yaşlanmayla oluşan değişimler, tanınacak kişilerin çokluğu ve işlem zamanı yer almaktadır (Gökmen vd., 2007).

Yüz tanıma sistemlerinin iki temel metodu vardır. Birinci yaklaşıma göre tüm yüz görüntüsünden elde edilen bilgi bir yüzü en iyi şekilde tanımlayan bilgidir. Bu yaklaşıma görünüm tabanlı (appearance-based) yüz tanıma yöntemi denir. İkinci yaklaşım ise bir yüzün ağız, burun, çene ve gözler gibi kısımlarından elde edilecek değerlerle oluşturulan öz nitelikleri tanıma amacıyla kullanılmasıdır (Terzopoulos ve Waters, 1990). Bir yüzün bilgisi ister tüm yüzden isterse yüzün belirli kısımlarının öz niteliklerinden elde edilmiş olsun makineler aracılığıyla kimlik tespitinin yapılabilmesi için bir modele ihtiyaç vardır. Bu çalışmamızda iki yöntemde modellenmiştir.

Çalışma şu şekilde organize edilmiştir. İkinci ve üçüncü bölümde, çalışmada kullanılan metodoloji ve yöntemlerden özyüzler ve yapay sinir ağları yöntemleri sunulmuştur. Dördüncü bölümde, iki yöntemin kullanıldığı uygulama ve sonuçları ortaya konulmuş ve son bölümde elde edilen sonuçlar değerlendirilmiştir.

2. ÖZYÜZLER

Sirovich ve Kirby (1987) yüzü efektif bir formda göstermek için ilk defa kullandıkları bu yöntem öz yüzler (Eigenfaces, Principal Component Analysis, PCA) olarak bilinmektedir. Bu

yöntem Temel Bileşen Analizi olarak da bilinmektedir. Yüz resimlerinden oluşan uzayın dağılımını temsil eden temel bileşenlerin bulunması amaçlanmaktadır. Temel bileşen analizi; değişkenlerden oluşan bir veri kümesinin varyans – kovaryans yapısını, bu değişkenlerin doğrusal birleşimleri yardımıyla açıklayarak, boyut indirgemesi ve yorumlamasını sağlayan birçok değişkenli istatistiksel yöntemdir (Kaufman ve Breeding, 1976). Özyüzler yönteminde amaç yüz uzayındaki resimleri Temel Bileşenler Analizi kullanarak daha az boyutlu bir alt uzayda ifade etmektir. Özyüzler yöntemi yüz uzayının temel bileşenlerini ve yüz vektörlerinin temel bileşenler üzerine izdüşümünü kullanır. Bu yöntem boyut indirgeme yöntemidir ve yüz uzayının boyutunu azalttığı için tanıma ve öğrenme işlemleri hızlıdır. Yüz uzayında bulunan resimlerin değerleri arasındaki varyanslardan yararlanır. Örneğin bir x değeri y ile bağlantılı ise ve x'in değerini bilmek y'nin değerini ifade etmede yeterli ise (x,y) iki boyutlu uzayı yerine tek boyutlu x değerlerini tutmak yeterli olacaktır.

2.1. Öz Yüzlerin Hesaplaması

I(x,y) yüz görüntüsü, 8 bit yoğunluk değerlerine (gri seviye resim) sahip $N \times N$ boyutlu bir matristir. $N \times N$ 'lik bir matris N^2 boyutunda bir vektör olarak düşünülebilir. Yani 128×128 boyutundaki tipik bir görüntü 16,384 boyutunda bir vektör veya eşit şekilde 16,384 boyutlu uzayda bir nokta olur.

Aynı olan yüz görüntüleri, bu büyük uzayda rastgele bir şekilde dağılmayacaktır ve bu nedenle nispeten düşük boyutlu alt uzayda tarif edilebilir. Temel bileşen analizinin ana fikri, tüm görüntü uzayında yüz görüntülerinin dağıtılmasını en iyi açıklayan vektörleri bulmaktır.

Bu vektörler, orijinal yüz görüntülerine karşılık gelen kovaryans matrisinin öz vektörleri olduğundan ve görünüm olarak yüze benzediklerinden bunlara “özyüzler – eigenfaces ” adı verilir. Aşağıda özyüzler yönteminin uygulama adımları sunulmuştur.

1. Eğitim için kullanılacak veri setinde M adet yüz resmi var ise ve bunları S kümesinde gösterecek olursak yüz uzayı eşitlik 1'deki gibi gösterilebilir. Γ_i yüz uzayındaki bir resmi ifade etmektedir. Γ_i değerleri $N \times N$ 'lik bir resmin N^2 boyutlu vektörüdür.

$$S = \{\Gamma_1, \Gamma_2, \Gamma_3, \dots, \Gamma_M\} \quad N \times M \quad (1)$$

2. Yüz uzayındaki yüz resimlerinin ortalaması alınarak ortalama (averaj) yüz bulunur. Ψ , eğitim setinin ortalama matrisi eşitlik 2'teki gibi hesaplanır.

$$\Psi = \frac{1}{M} \sum_{n=1}^M \Gamma_n = \begin{bmatrix} \Psi_1 \\ \Psi_2 \\ \vdots \\ \Psi_N \end{bmatrix} \quad (2)$$

3. Yüz uzayındaki her yüz vektör değerinden ortalama yüz değeri çıkarılarak yüz uzayının ortalama yüzleri bulunur (normalizasyon). Buradaki amaç ortalama değeri sıfır olan bir veri kümesi elde etmektir. Ortalaması hesaplanmış verilerin vektörleri Φ_i ve bu vektörlerden oluşan matris A şeklinde gösterilirse ortalaması çıkarılmış vektörler ve matris eşitlik 3 ve 4'teki gibi hesaplanır.

$$\Phi_i = \Gamma_i - \Psi \quad (3)$$

$$A = \begin{bmatrix} \Phi_1^1 - \Psi_1 & \Phi_1^2 - \Psi_1 & \dots & \Phi_1^M - \Psi_1 \\ \Phi_2^1 - \Psi_2 & \Phi_2^2 - \Psi_2 & \dots & \Phi_2^M - \Psi_2 \\ \vdots & \vdots & \ddots & \vdots \\ \Phi_N^1 - \Psi_N & \Phi_N^2 - \Psi_N & \dots & \Phi_N^M - \Psi_N \end{bmatrix} \quad (4)$$

4. Sıfır ortalamalı A matrisinin kovaryans matrisi C eşitlik 5'deki gibi hesaplanır.

$$C = \frac{1}{M} \sum_{n=1}^M \Phi_n \Phi_n^T = AA^T \quad (5)$$

Burada köşegen üzerinde bulunan değerler varyans, diğerleri ise kovaryans değerleridir. Varyans diğer boyutlardan bağımsız olarak yalnızca bir boyuttaki verinin ortalama etrafındaki dağılımı hakkında bilgi vermektedir. Kovaryans ise bir değişkenin diğer değişkenlerle birlikte nasıl bir değişim gösterdiği hakkında bilgi verir ve daima iki değişken arasında hesaplanır (Pentland vd., 1994). C kovaryans matrisi simetrik bir matristir ve öz değerleri (eigenvalue) ve öz vektörleri (eigenvector) hesaplanabilir.

5. Kovaryans matrisine ait öz değer ve öz vektörlerin hesaplanmasında eşitlik 7 kullanılır. C , $N \times N$ boyutlu bir matris, λ herhangi bir skaler ve v sıfırdan farklı bir sütun vektör olmak üzere aşağıdaki eşitliği sağlayan λ sayısı C matrisinin öz değeri ve v de λ ile ilişkili öz vektördür.

$$Cv = \lambda v \quad (6)$$

λ öz değerlerinin hesaplanmasında I_n birim matris olmak üzere,

$$(\lambda I_n - C)v = 0 \quad (7)$$

Şeklinde yazılabilir. $(\lambda I_n - C)v = 0$ ifadesi $(C - \lambda I_n)v = 0$ şeklinde de yazılabilir ve ilk ifade için verilebilecek tanımlar ikinci ifade içinde doğrudur (Pentland ve ark., 1994).

$\lambda I_n - C$ ifadesi matris formda,

$$\lambda I_n - C = \begin{bmatrix} \lambda - c_2^1 & -c_1^1 & \dots & -c_1^n \\ -c_1^2 & \lambda - c_2^2 & \dots & -c_1^n \\ \dots & \dots & \dots & \dots \\ -c_1^n & c_2^n & \dots & \lambda - c_n^n \end{bmatrix} \quad (8)$$

şeklinde gösterilebilir. Bu matrisin determinantına C matrisinin karakteristik polinomu denir. $v \neq 0$ çözümü için,

$$p(\lambda) = \det(\lambda I_n - C) = 0 \quad (9)$$

olmalıdır. Buna C matrisinin karakteristik denklemi denir. Bu denklemin kökleri C matrisinin öz değerlerini verir. Bu öz değerler Eşitlik 7'de yerine yazılırsa bu öz değerlere karşı gelen öz vektörler elde edilir. Elde edilen öz değer matrisindeki en büyük değere sahip olan bileşen temel bileşendir. Yani veri kümesi içindeki en önemli ilişkidir. Öz değerler küçükten büyüğe doğru sıralanacak biçimde dizildiğinde, en önemli olandan en az önemli olan bileşene doğru sıralanmış olur. Bu dizilime göre istenirse sifıra yakın veya ihmal edilebilecek daha az önemli olan bileşenler elenerek boyut azaltılmış olur. Bu şekilde seçilmiş öz vektörlerden oluşan matrise öz nitelik matrisi denir.

6. Öz değer ve öz vektörler hesaplandıktan sonra u öz yüzlerin hesaplanmasına geçilir. Öz yüzler Φ ortalama değerlerinin öz vektörlerin oluşturduğu matrisle çarpılarak Eşitlik 10'deki gibi hesaplanabilir.

$$u_i = \sum_{k=1}^M v_{lk} \Phi_k \quad l = 1, 2, \dots, M \quad (10)$$

7. Tanıma işlemine geçilmeden öz yüzler matrisi A veri kümesine iz düşürülerek temel bileşenler analizi ile boyut azaltma işlemi gerçekleştirilmiş olur. u , yüksek öz değere gelen öz yüzler matrisinin transpozu ve A veri matrisi çarpılarak Ω matrisi eşitlik 11'teki gibi oluşturulur.

$$\Omega = u^T x A \quad (11)$$

v ve Ω matrisi belirlenerek eğitim aşaması tamamlanmış olur.

8. Tanıma işlemi için ilk olarak test resmi ile ortalama resim arasındaki fark bulunur ve bu fark her öz vektör değeri ile Eşitlik 12'teki gibi hesaplanır. Bu çarpım sonucu elde edilen veriler ile Ω^T matrisi oluşturulur.

$$\omega_k = u_k^T (\Gamma - \Psi) \quad k = 1, 2, \dots, M \quad (12)$$

$$\Omega^T = [\omega_1, \omega_2, \dots, \omega_M] \quad (13)$$

Hangi yüz sınıfının test resmi için en uygun tanımlama olduğunu bulunur. Bu işlem öklid uzaklığının minimize edilmesi ile gerçekleşir.

$$\varepsilon_k = \|\Omega^T - \Omega\|^2 \quad (14)$$

ε_k değerinin minimum olduğu değere ait yüz resmi tanıma sonucu olarak bulunmuş olur.

3. YAPAY SİNİR AĞLARI

Yapay sinir ağları (YSA), insan beyninin öğrenme yolu ile yeni bilgiler üretme ve keşfedebilme gibi becerilerini otomatik olarak gerçekleştirebilmek amacı ile geliştirilen bilgisayar sistemleridir (Basheer ve Hajmeer, 2000). Yapay Sinir Ağları, eğitim verileri ile eğitilerek öğrenebilme ve genelleme yapabilme özellikleri sayesinde çok esnek ve güçlü araçlar olma özelliğine sahiptirler. Bu sebeple Yapay Zekâ biliminin altında araştırmacıların çok yoğun ilgi gösterdikleri bir araştırma alanıdır (Benvenuto ve Marani, 2000). Yapay sinir ağları insan beyninin öğrenme, ilişkilendirme, sınıflandırma, genelleme, tahmin, özellik belirleme ve optimizasyon gibi fonksiyonel özelliklerini başarılı bir şekilde uygulamaktadır. Bu özellikleri sayesinde arıza analizi ve tespiti, tıp, haberleşme, savunma, üretim ve otomasyon gibi çok farklı alanlarda kullanıldığından günümüzde kullanım alanlarını belirli gruplara ayırmak zorlaşmıştır.

3.1. Biyolojik Sinir (Nöron) Hücresinin Yapısı

Sinir hücreleri sinir sistemini oluşturan temel elemanlardır. Nöron olarak isimlendirilen bu hücrelerin birbirleri ile oluşturdukları bağlantılara ağ (network) denir. Birbiriyle bağlantılı iki nöronun axon, dentrite, synapse ve soma olmak üzere dört önemli bölümü bulunmaktadır. Bu yapının bütünü sinir sistemini oluşturur. İnsan beyninde 10 milyar sinir hücresi (nöron) ve hücreler arası 60 trilyon synapse olduğu tahmin edilmektedir (Boznar vd., 1993).

Duyu organlarından alınan uyarılar sinirlerin girdi bilgileri olarak kullanılırlar. Her bir sinir hücresi aldıkları sinyalleri işleyerek bir sonraki hücreye aktarır ve sinyalin merkezi sinir sistemine kadar ulaşması sağlanır. Sinir hücrelerinden gelen uyarılar (elektiriksel sinyaller) sinapslar üzerinden dentritlerine alınır. Gelen sinyaller güçlendirilir ya da zayıflatılır ve hücre gövdesine iletilir. Kuvvetlendirme ve zayıflatma etkilerine göre gelen sinyaller hücre gövdesinde işlenir. Gelen sinyaller etkileşim sonucunda yeteri bir eşik değerini aşacak şekilde kuvvetlenirlerse, aksone sinyal gönderilir ve sinir aktif hale getirilir. Aksi takdirde, sinyal gönderilmez ve sinir pasif durumda kalır (Cheng ve Titterington, 1994).


3.2. Yapay Sinir Ağlarının Yapısı

Yapay sinir ağları ile aslında biyolojik sinir ağlarının bir benzeri modellenmeye çalışılmaktadır. Sinir hücreleri bir birleri ile bağlantılı olarak işlem yaptıklarından dolayı ağ olarak isimlendirilirler. Bir sinir ağları grubunda binlerce nöron bulunabilir. Yapay sinir hücrelerinin birbirleri ile bağlantı kurarak oluşturdukları bu yapıya yapay sinir ağları denilmektedir (Comrie, 1997).

Yapay sinir hücrelerinin bir araya gelmeleriyle yapay sinir ağlarının katmanları oluşmaktadır. Yapay sinir ağları 3 katmandan oluşur. Giriş katmanı, ara (gizli) katmanlar ve çıkış katmanı.

3.3. Yapay Sinir Hücrelerinin Yapısı

Biyolojik sinir hücreleri taklit edilerek tasarlandığı için yapay sinir hücreleri yapı olarak biyolojik sinir hücrelerine benzemektedirler. Yapay sinir hücresi yapay sinir ağlarını oluşturan ve çalışmasını sağlayan temel bilgi işleme birimidir. Yapay sinir ağını oluşturan tüm hücreler bir veya daha fazla girdi alabilmesine rağmen sadece bir tane çıktı üretebilirler. Hücrelerin ürettiği çıktılar çıktı değerleri sonuç olarak üretilen çıktılar olabileceği gibi komşu hücrelerine girdi olarak da kullanılabilirler. Biyolojik sinir hücresi nöronlarda olduğu gibi yapay sinir hücrelerinde de girdi sinyallerini aldıkları, toplanıp işlendiği ve çıktı olarak verildiği bölümleri vardır. Bir yapay sinir hücresi girdiler, ağırlıklar, toplama (birleştirme) fonksiyonları, aktivasyon (transfer) fonksiyonu ve çıktılar olmak üzere beş bölümden oluşmaktadır (Benvenuto ve Marani, 2000).



Şekil 1. Temel Yapay Sinir Ağı Hücresi (Yüksek, 2007)

4. UYGULAMA

Çalışmanın ilk aşamasında özyüzler modeli anlatılarak sistemin çalışması ve işlem basamakları açıklanmıştır. Özyüzler yaklaşımı görüntü tabanlı bir yaklaşımdır. Yani yüz görüntüsü hakkındaki bilginin tüm yüz görüntüsü ile elde edilebileceği varsayılarak oluşturulmuştur. Bu sebeple kullanılan veri tabanındaki resimler her hangi bir ön işleme tutulmadan modelin eğitimi için kullanılmıştır. Uygulamada 40 kişinin toplam 400 adet yüz görüntüsü kullanılmıştır (The Database of Faces, 2017). Bu veri setindeki 400 görüntünün 320 tanesi eğitim için, 80 tanesi ise test için ayrılmıştır. Test seti ideal haliyle kullanıldıktan ve sonuçlar elde edildikten sonra test setindeki resimlerin belirli bölgeleri değiştirilerek test işlemi tekrarlanmıştır. Değiştirilen bölgeler sırayla göz, burun ve ağız-çene bölgeleridir. Ayrıca test verileri üzerinde belirli bir gürültü oluşturularak da testler yenilenmiştir. Tüm testler kayıt altına alınmış ve sonuçlar Tablo 1.'de sunulmuştur.

Tablo 1. Özyüzler Performans Değerleri

	Test Verisi Sayısı	Doğru Sayısı	Hata Sayısı	Başarı Yüzdesi
İdeal Görüntü	80	77	3	96,25
Göz Kısmı Kapalı Görüntü	80	11	69	13,75
Ağız-Çene Kapalı Görüntü	80	6	74	7,5
Burun kapalı görüntü	80	25	55	31,25
Gürültü Oluşturulmuş görüntü	80	75	5	93,75

Sonuçlar incelendiğinde ideal şartlarda ön profilden alınan görüntülerin tanınmasında özyüzlerin tanıma performansının %96,25 gibi çok üst düzeyde olduğu görülmüştür. Ancak yüz görüntülerinin belirli bölgelerinde yapılan değişikliklerde tanıma performansı oldukça düşmektedir. Özellikle göz ve ağız-çene bölgeleri değiştirilmiş görüntülerde sırayla elde edilen %13,75 ve %7,5'lik tanıma başarısı oldukça düşük çıkmıştır. Burun bölgesinin tanıma performansı ise diğer bölgelerin tanıma oranları dikkate alındığında nispeten % 31,25 gibi bir oranla daha yüksek çıkmaktadır. Ancak test aşamasında kabul edilebilir bir gürültü ile veriler işlendiğinde, tanıma performansının çok etkilenmediği görülmüştür.

Çalışmanın ikinci aşamasında ise Yapay Sinir Ağları ile oluşturulan model ve bu modelin eğitiminde kullanılan veri tabanının hazırlanması sağlanmıştır. Yüz tanıma sistemlerinin temel yöntemlerinden olan bir yüzün öznelik değerleri ile tanınabileceği varsayımı denenmiştir. Yüz veri setindeki görüntülerin öznelikleri kullanılarak bir Yapay Sinir Ağı eğitilmiş ve test edilmiştir.

Yapay sinir ağının eğitimi için yüz resimlerinin belirli özellik noktalarından; göz, burun, ağız, çene vb. değerler çıkarılarak yüz geometrisi bilgilerinden sonuçlar üretilmiştir. Kullanılan veri tabanı içerisinde bulunan veri setindeki yüz resimlerinin 22 ayrı bilgi noktası bulunmaktadır (Martinez, 1998). Bu noktaların koordinat bilgileri arasında uzaklıkları ve açıları hesaplanarak yüz resmini ifade eden yeterli bir veri seti oluşturulmuştur. Bu koordinatlar kullanılarak yüz tanıma için gerekli özellikler belirlenmiştir. Öz niteliklerin belirlenmesinde çene, ağız, burun ve sol-sağ göz açı değerleri derece cinsinden hesaplanmıştır. Bu yöntemle tüm veri setinde bulunan koordinat noktalarından çene bölgesi için 3 açı değeri, ağız bölgesi için 6 açı değeri, burun bölgesi için 3 açı değeri, sol göz bölgesi için 3 açı değeri, sağ göz bölgesi için 3 açı değeri olmak üzere toplamda bir yüzü ifade etmek için yüzün temel kısımlarından elde edilen 18 farklı açı değeri ile veri seti oluşturulmuş ve Yapay Sinir Ağı eğitilmiştir. Model test edilirken öncelikle tüm açı değerleri kullanılarak sonuçlar karşılaştırılmıştır. Daha sonra özyüzler yönteminde olduğu gibi belirli bölgelerin açı değerleri test setinden silinerek testler tekrarlanmış ve sistemin eksik değerlerle olan genelleme yeteneği açısından sonuçlar üretilmiştir. Eksik verilerin testinde öncelikle göz bölgesinin 6 açı değeri silinmiş ve sisteme yüz görüntüsüne ait 12 açı değeri verilmiştir. Daha sonra burun bölgesinin 3 açı değeri silinerek sistem 15 açı değeri ile test edilmiştir. Son olarak ağız-çene bölgelerinin 9 açı değeri silinerek kalan 9 açı değeri ile sistem test edilmiş ve tüm test sonuçları Tablo 2.'de sunulmuştur.

Tablo 2. Yapay Sinir Ağları Performans Değerleri

	Test Verisi Sayısı	Kullanılan Açı Sayısı	Başarı Yüzdesi
Tüm Yüz Açıkları Kullanılan Test	101	18	98,7
Burun Bölgesi Açı Değerleri Eksik Test	101	15	82,4
Ağız-Çene Bölgesi Açı Değerleri Eksik Test	101	9	98,2
Göz Bölgesi Açı Değerleri Eksik Test	101	12	0,6

Uygulama sonuçları incelendiğinde yapay sinir ağlarının yüz tanıma uygulamalarında öz nitelik değerleri kullanılarak %98,7 gibi bir yüksek başarıya sahip olduğu görülmektedir. Yapay sinir ağlarının genel özelliklerinden biri olan eksik verilerde genelleme yapabilme yeteneği sayesinde özellikle burun ve ağız-çene bölgesi verileri eksik iken de %82,4 - %98,2'lık test sonuçları dikkate alındığında başarılı olduğu görülmektedir. Ancak göz bölgesine ait değerler veri setinden çıkarılarak yapılan testlerde sonuçların çok düşük bir tanıma yüzdesine sahip olduğu görülmektedir. İki model üzerinden elde edilen test performansları karşılaştırmalı olarak Tablo 3.'te sunulmuştur.

Tablo 3. Modellerin Performanslarının Karşılaştırılması

	Öz yüzler	Yapay Sinir Ağları
Tüm Yüz – Tüm Veri	96,25	98,7
Göz Verisi Eksik	13,75	0,6
Ağız – Çene Verisi Eksik	7,5	98,2
Burun Verisi Eksik	31,25	82,4

5. SONUÇ

Yapılan çalışmada öncelikle yüz tanıma sistemleri için görünüm (tüm yüz verisinin kullanıldığı) ve öz nitelik tabanlı yaklaşımların literatür çalışmaları ele alınmıştır. Yapılan değerlendirmeler mevcut çalışmalarda belirli bir yöntemin yüz tanıma için tek başına ideal koşullar dışında yeterli sonuçlar üretmediği ve eş zamanlı çalışan gerçek uygulamalarda yeterli başarı sağlanamadığı belirtilmektedir. Literatürde sıklıkla kullanılan insan yüzü tanıma yöntemlerinin genellikle görünüm tabanlı (appearance-based) yöntemler olduğu belirtilmektedir. Bu yöntemler her insan için, farklı çevre koşullarını içerecek şekilde eğitim verisine ihtiyaç duymaktadır. Fakat gerçek uygulamalarda sınırlı sayıda eğitim verisine sahip olduğu için insan yüzüne ait tüm değişimleri bu sistemler yakalayamamaktadır.

Belirtilen yöntemlerden Temel Bileşen Analizi temelli “Özyüzler” yöntemi en yaygın görünüm tabanlı yöntem olup, özyüzlere dayalı yöntemler hala kullanılmakta ve başarılı sonuçlar elde edilmektedir. Bu yaklaşımın önemli sorunları arasında aydınlanma ve poz değişimlerine duyarlı olması yer almaktadır. Ayrıca, bu algoritmalarda tanıma başarısının yüksek çıkması için, algoritmaya giriş olarak sunulan insan yüzlerinin önden çekilmiş (frontal) ve iyi aydınlatılmış olmasına ihtiyaç duyulmaktadır. Özyüzler modeli hazırlanırken model iyi eğitilmiş olmalıdır. İdeal şartlarda alınan görüntüler üzerinden tanıma değerleri %96,25 gibi oldukça yüksek bir değerdir. Ancak yüz tanıma probleminin zorluklarından pozdaki değişimler, ışık kaynağının yeri ve şiddetindeki değişimler, yüz ifadesindeki değişimler, ölçek sorunu, zamanla veya yaşlanmayla oluşan değişimler vb. gibi durumlarda tanıma performansı %31,25, %13,5 ve %7,5 gibi oldukça düşük değerlere sahiptir. Özniteliklerin kullanıldığı modellerin görünüm tabanlı modellere göre en büyük dezavantajının bu nitelikleri elde etmekten kaynaklandığı söylenebilir. Çünkü birçok alanda görüntü alan basit bir kamere ile yüz görüntüsü elde edilebilirken öz niteliklerin elde edilmesi için görüntü üzerinde birçok işleme ihtiyaç vardır. Ancak görüntülerden öznitelikler gerekli hassasiyetle elde edilebilirse yapay sinir ağlarının yüz tanıma performansının %98,7 gibi oldukça yüksel olduğu görülmektedir. Ayrıca görüntünün belli bölgeleri eksik ise yapay sinir ağlarıyla yapılan öznitelik tabanlı modelin başarısının özyüzlere göre oldukça yüksek olduğu da anlaşılmaktadır. Ancak eksik verilerle çok yüksek tanıma performansı gösteren yapay sinir ağlarının başarısı yapılan tüm testler için geçerli olmamıştır. Yapay sinir ağlarıyla yapılan testlerde göz bölgesi eksik verilerin test sonucunun %0,6 gibi oldukça düşük bir değerde kaldığı görülmektedir. Ayrıca burun bölgesi eksik verinin ağız-çene bölgesi eksik olan veriden tanıma performansının yaklaşık %13 düşük olması bize öznitelik tabanlı uygulamalarda yüzün üst bölgesinin tanıma performansına alt bölgesinden daha fazla etki ettiğini göstermektedir.

Çalışma sonucunda ortaya çıkan yüz tanıma probleminin zorlukları yanında gözlük, şapka ve yüzü örten diğer unsurların bulunduğu durumlarda, yüzün belirli bölgesinin incelenmesi sonuçlar açısından önemlidir. Bu gibi zor şartlar altında elde edilmiş görüntülerde ve eksik verilerin fazla olduğu durumlarda görünüm tabanlı yöntemler yerine yapay sinir ağları ile oluşturulan modeller kullanılabilir. Yapay sinir ağlarının genelleme ve eksik veriler ile tahmin edebilme özellikleri kullanarak bu iki model farklı durumlar için birbirinin alternatifi olarak kullanılabilirler. Ayrıca görünüm tabanlı eş zamanlı çalışan modellerin geliştirilmesinde özyüzler yaklaşımı kullanılmak istenirse elde edilen test resimleri üzerinde görüntü işleme yöntemleri ile iyileştirmelerin yapılması tahmin performansını artırabilir. Bu yönde yapılacak çalışmalarda elde edilecek başarılar açısından önemli bir yenilik olacaktır. Özniteliklerin çıkarılmasında kullanılan tekniklerde meydana gelebilecek yenilikler, bu modellerin kullanılmasını artırıcı bir etki yapacaktır. Özellikle günümüzde görüntüleme cihazlarının yazılım ve teknolojilerindeki gelişmeler ile görüntülerden gerçek zamanlı olarak özniteliklerin elde edilebilmesi sağlanabilir ise bu modelin kullanılmasına büyük kolaylıklar katacaktır. Görüntüleme cihazlarındaki gelişmeler ve görüntü işleme alanında yapılan çalışmaların etkisi ile hem yüzün görüntüsü hem de öz nitelikleri aynı anda elde edilebilmesi kolaylaşmaktadır. Bu yüzden yüz tanıma sistemlerinde, tüm yüz görüntüsünü kullanan görünüm tabanlı model ve öznitelik tabanlı sistemlerinin birlikte çalışmasıyla oluşturulacak bir melez modelin gerçek zamanlı ve ideal olmayan koşullarda üreteceği çözümler daha başarılı sistemler olabilirler.

KAYNAKÇA

- Basheer, I. A., & Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application. *Journal of microbiological methods*, 43(1), 3-31.
- Benvenuto, F., & Marani, A. (2000). Neural networks for environmental problems: data quality control and air pollution nowcasting. *Global NEST: The International Journal*, 2(3), 281-292.

- Boznar, M., Lesjak, M., & Mlakar, P. (1993). A neural network-based method for short-term predictions of ambient SO₂ concentrations in highly polluted industrial areas of complex terrain. *Atmospheric Environment. Part B. Urban Atmosphere*, 27(2), 221-230.
- Cheng, B., & Titterton, D. M. (1994). Neural networks: A review from a statistical perspective. *Statistical science*, 2-30.
- Comrie, A. C. (1997). Comparing neural networks and regression models for ozone forecasting. *Journal of the Air & Waste Management Association*, 47(6), 653-663.
- Goldstein, A. J., Harmon, L. D., & Lesk, A. B. (1971). Identification of human faces. *Proceedings of the IEEE*, 59(5), 748-760.
- Gökmen, M., Kurt, B., Kahraman, F., & Çapar, A. (2007). Çok Amaçlı Gürbüz Yüz Tanıma. İstanbul Teknik Üniversitesi Bilgisayar Mühendisliği Bölümü, Tübitak Projesi, Proje, (104E121).
- Haig, N. D. (1985). How faces differ—A new comparative technique. *Perception*, 14(5), 601-615.
- Jain, A. K., & Kumar, A. (2010). Biometrics of Next Generation: An Overview. *proceedings Second Generation Biometrics' Springer*.
- Kaufman, G. J., & Breeding, K. J. (1976). The automatic recognition of human faces from profile silhouettes. *IEEE Transactions on systems, Man, and Cybernetics*, (2), 113-121.
- Jain, A. K., & Li, S. Z. (2011). *Handbook of face recognition*. New York: Springer.
- Martinez, A. M. (1998). The AR face database. CVC technical report.
- New report predicts Global Biometrics Market to reach US\$16.47 Billion, Erişim Tarihi: 20 Aralık 2011, <http://www.planetbiometrics.com/article-details/i/917/>.
- Pentland, A., Moghaddam, B., & Starner, T. (1994). View-based and modular eigenspaces for face recognition. In *CVPR (Vol. 94, pp. 84-91)*.
- Pike, J. (2007). Homeland Security: Biometrics. GlobalSecurity.org.
- Rhodes, G. (2013). Looking at faces: First-order and second-order features as determinants of facial appearance. *Perception*, 42(11), 1179-1199.
- Sirovich, L., & Kirby, M. (1987). Low-dimensional procedure for the characterization of human faces. *Josa a*, 4(3), 519-524.
- Terzopoulos, D., & Waters, K. (1990). Analysis of facial images using physical and anatomical models. In *Computer Vision, 1990. Proceedings, Third International Conference on (pp. 727-732)*. IEEE.
- The Database of Faces, Erişim Tarihi: 21 Haziran 2017, <http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html>.
- Turk, M., & Pentland, A. (1991). Eigenfaces for recognition. *Journal of cognitive neuroscience*, 3(1), 71-86.
- Yüksek, A. G. (2007). Hava Kirliliği Tahmininde Çoklu Regresyon Analizi ve Yapay Sinir Ağları Yönteminin Karşılaştırılması. Doktora Tezi, Sivas Cumhuriyet Üniversitesi, Sosyal Bilimler Enstitüsü