





Yeni bir otomatik yüz tanıma sistemi A novel automatic face recognition system

Engin Cemal Mengüç^{1,*} , Nurettin Acır² 

¹ Kayseri Üniversitesi, Mühendislik, Mimarlık ve Tasarım Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 38280, Kayseri, Türkiye
² Milli Savunma Üniversitesi, Hava Harp Okulu, Elektronik Mühendisliği Bölümü, 34149, İstanbul, Türkiye

Öz

Bu çalışmada, yakın zamanda geliştirilen Lyapunov kararlılık teorisi (LKT) tabanlı yapay sinir ağı (YSA) algoritması kullanılarak yeni bir otomatik yüz tanıma sistemi önerilmiştir. Bu amaç doğrultusunda, ilk olarak en bilgilendirici öznelikleri çıkarmak ve hesap karmaşıklığını azaltmak için temel bileşen analizi (TBA) metodu kullanılmıştır. Ardından, çıkarılan öznelikler ile LKT tabanlı YSA yapısı bir sınıflandırıcı olarak beslenmiştir. Önerilen yüz tanıma sisteminin başarımı, diğer sistemlerle karşılaştırmalı olarak ORL yüz veri kümesi üzerinde değerlendirilmiştir. Deneysel sonuçlar, önerilen yüz tanıma sisteminin, adaptif adaptasyon kazanç oranı parametresi yardımıyla, daha yüksek eğitim hızının yanı sıra daha yüksek eğitim ve test tanıma oranları sağladığını kanıtlamıştır.

Anahtar kelimeler: Yüz tanıma, Yapay sinir ağı, Lyapunov kararlılık teorisi

1 Giriş

Otomatik yüz tanıma sistemleri, insan-bilgisayar arayüzleri, biyomedikal görüntüleme, güvenlik, kontrol teknolojisi gibi birçok mühendislik uygulamasında odak noktası haline gelmiştir [1-16]. Yüz tanıma yaklaşımları genelde, öznelik-tabanlı yaklaşım [1-4] ve bütünsel yaklaşım [5, 6] olarak iki guruba ayrılır [9]. Öznelik-tabanlı yaklaşımlar mekânsal yüz tanıma için lokal öznelikler (örneğin; burun, ağız, göz vb.) çıkarırken, bütünsel yaklaşımlar, tanıma görevlerini yerine getirmek için tüm yüzlerle eşleştirme gerçekleştirir [7].

Yapay sinir ağları (YSA) diğer kural tabanlı sistemlere göre önemli başarımları sağlamak için istatistiksel ve yapısal bilgiyi kullandıklarından [15], hala yüz tanıma problemlerinde tercih edilen ilk sistem bileşenleri arasındadır [8-14]. YSA genellikle gradyan iniş algoritmaları ile eğitilir [16] fakat bu algoritmalar yavaş yakınsama probleminden dolayı YSA'nın eğitim süresini artırmaktadır. Hatta bu tür algoritmalar, hata başarımlarında yerel minimum noktalara takılabilmektedir [9]. Geleneksel gradyan tabanlı eğitim algoritmalarının yakınsama oranını hızlandırmak amacıyla literatürde; momentum terimi, standart eniyileme teknikleri ve adaptif öğrenme oranları (yinelemeli en küçük kare, eşlenik gradyan, yarı-Newton, Levenberg-Marquardt gibi) dahil olmak üzere çeşitli yöntemler önerilmiştir [17-20]. Bu yöntemler, geleneksel

Abstract

In this study, a new automatic face recognition system is proposed using the recently developed Lyapunov stability theory (LST) based artificial neural network (ANN) algorithm. For this purpose, the principal component analysis (PCA) method is first used to extract the most informative features and reduce computational complexity. Then, LST based ANN structure as a classifier is fed by the extracted features. The performance of the proposed face recognition system is evaluated on the ORL face dataset in comparison with other systems. Experimental results prove that the proposed face recognition system provides higher training and test recognition rates as well as higher training speed with the help of the adaptive adaptation gain rate parameter.

Keywords: Face recognition, artificial neural network, Lyapunov stability theory

gradyan tabanlı algoritmalarından daha hızlı bir yakınsama oranı sergilemelerine rağmen, yüksek depolama, yüksek bellek gereksinimleri, yüksek hesaplama karmaşıklığı, sezgisel bilgi gereksinimi gibi ciddi problemler içerir [21, 22].

Son zamanlarda, bu tür problemlerin üstesinden gelmek için LKT tabanlı algoritmalar [8, 9, 23-29] popüler hale gelmiştir. Gradyan tabanlı eğitim algoritmalarının aksine, bu algoritmalar, ağırlık katsayılarını güncelleyerek hata başarımlarını yüzeyi boyunca küresel minimum noktayı bulmayı amaçlar ve bu durumu gerçekleştirirken her zaman Lyapunov anlamında kararlılığı sağlarlar. Bu algoritmaların anahtar parametresi, yakınsama hızı üzerinde önemli bir etkiye sahip olan adaptasyon kazanç oranı parametresidir. [8, 9, 23]'de yer alan çalışmalarda LKT tabanlı algoritmalar tasarlanırken, aday Lyapunov fonksiyonu olarak hata sinyali tabanlı fonksiyonlar yaygın olarak kullanılmış ve bu algoritmaların adaptasyon kazanç oranı parametresi sabit bir değer olarak seçilmiştir. Bu yaklaşımlarda [8, 9, 23], en iyi adaptasyon kazanç oranı parametresini belirlemek için çok sayıda deneme yapılmasına ihtiyaç vardır.

Bu amaçla, [24]'te yer alan çalışmada, adaptasyon kazanç oranının kendisini adaptif olarak güncellediği LKT tabanlı YSA algoritması geliştirilmiştir. Bu çalışmada [24], ilk olarak $a_i > 1$ durumu için aday Lyapunov fonksiyonu,

$V_t(k) = a_t^k e_t^2(k)$ seçilmiştir, burada a_t , adaptasyon kazanç oranıdır. Ardından ise LKT'nin [30] kesin negatiflik koşulunun kısıt olarak yer aldığı bir kısıtlı eniyileme problemi tanımlanmıştır. Tanımlanan bu problemin çözümünün sonucunda ise [24]'de yer alan LKT tabanlı YSA algoritması türetilmiştir. Önerilen algoritma Lyapunov anlamında kararlılığı her zaman sağlayarak YSA'nın ağırlık katsayılarını etkin bir şekilde güncellemiştir. Buna ek olarak, [24]'te önerilen algoritmanın diğer dikkat çekici özelliklerini şu şekilde özetleyebiliriz:

- Önerilen algoritma, giriş bozukluğunun etkilerini ortadan kaldırarak YSA'nın eğitim hatasını asimptotik olarak sifira yaklaştırmaktadır [24].
- Gradyan tabanlı tekniklerden farklı olarak, önerilen algoritma hata başarımlı yüzeyi boyunca küresel minimum noktayı bulmayı amaçlamaktadır [24].
- Adaptasyon kazanç oranı parametresi YSA'nın öğrenme kabiliyetini önemli ölçüde geliştirmektedir [24].

Bu çalışmada, LKT tabanlı YSA algoritması [24] kullanılarak yeni otomatik bir yüz tanıma sistemi önerilmiştir. Bu amaç doğrultusunda, ilk olarak en bilgilendirici öznelikler çıkarmak ve hesap karmaşıklığını ortadan kaldırmak için temel bileşen analizi (TBA) metodu [10, 11] kullanılmıştır. Ardından, çıkarılan öznelikler ile LKT tabanlı YSA bir sınıflandırıcı olarak beslenmiştir. Önerilen yüz tanıma sisteminin başarımı, diğer sistemlerle karşılaştırılabilir olarak ORL veri kümesi [31] üzerinde test edilmiştir. Deneysel sonuçlar, önerilen yüz tanıma sisteminin diğer sistemlere kıyasla daha hızlı bir eğitim hızı ve daha yüksek bir tanıma oranı sağladığını açık bir şekilde göstermiştir.

2 Materyal ve metot

Bu bölümde, sırasıyla TBA yöntemi ile öznelik çıkarımı ve LKT tabanlı YSA algoritmasının [24] tasarımı sunulacaktır.

2.1 Öznelik çıkarımı için TBA metodu

Önerilen sistemde her hangi bir yüz görüntüsüne ait öznelikler çıkarmak için TBA metodu [10, 11] kullanılmıştır. Bilindi üzere, $q \times q$ yoğunluk değerleri dizisine sahip bir yüz görüntüsü, 2 boyutlu bir matris formundan oluşmaktadır. Yüz tanıma sisteminde sınıflandırıcı olarak kullanılacak olan bir YSA yapısının eğitim süreci göz önüne alındığında, yüz görüntüsü önce q^2 boyutuna sahip bir vektör formuna dönüştürülmelidir. Böylece, p adet yüz görüntüsüne ait eğitim kümesi $\mathbf{Z} = \mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_p \subset \mathbb{R}^{q^2 \times p}$ olarak tanımlanmış olur, burada her bir vektör yüz tanıma sistemi tarafından sınıflandırılacak bir sınıfı temsil etmektedir.

Bu durumlar sağladıktan sonra, TBA metodunu kullanmak için önce kovaryans matrisinin aşağıdaki gibi tanımlanması gerekir:

$$\mathbf{C} = \frac{1}{p} \sum_{i=1}^p \mathbf{z}_i \mathbf{z}_i^T - \bar{\mathbf{z}} \bar{\mathbf{z}}^T \quad (1)$$

burada $\bar{\mathbf{z}} = (1/p) \sum_{i=1}^p \mathbf{z}_i$ ortalama görüntü vektörüdür.

Ardından ise kovaryans matrisi \mathbf{C} 'nin özdeğerleri ve özvektörleri hesaplanarak, r adet en büyük özdeğerlerle ilişkili r adet özvektörden oluşan $\mathbf{U} = \mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_r \subset \mathbb{R}^{q^2 \times r}$ ($r < p$) matrisi tanımlanır.

Eğitim sürecinde kullanılacak olan orijinal $\mathbf{Z} \subset \mathbb{R}^{q^2 \times p}$ yüz görüntülerinin $\mathbf{X} \subset \mathbb{R}^{r \times p}$ özyüz-tabanlı öznelikleri, kendine karşılık gelen özyüz uzayı \mathbf{Z} 'ye yansıtılarak aşağıdaki gibi elde edilir:

$$\mathbf{X} = \mathbf{U}^T \mathbf{Z} \quad (2)$$

Eğer yeni bir yüz görüntü olan \mathbf{z}_{new} ile sistem test edilmek istenirse, bu yeni görüntü özyüz uzayına aşağıda verilen ifade kullanılarak yansıtılır:

$$\mathbf{X}_{new} = \mathbf{U}^T (\mathbf{z}_{new} - \bar{\mathbf{z}}) \quad (3)$$

burada \mathbf{X}_{new} ifadesi sisteme test için uygulanan yeni görüntünün özyüz temelli özneliğini temsil etmektedir. Burada TBA metodu ile ilgili daha fazla bilgi için [10, 11]'deki çalışmalar incelenebilir.

2.1.1 LKT tabanlı YSA algoritmasının tasarımı

Burada, LKT tabanlı YSA algoritmasının [24] tasarımından kısaca bahsedilecektir. Tasarımda kullanılan YSA yapısı, \mathbb{R}^n 'den \mathbb{R}^m 'e olan giriş-çıkış ilişkisi dikkate alınarak modellenmiştir, burada n ve m sırasıyla giriş ve çıkış sayısını temsil etmektedir. YSA yapısının ağırlık katsayılarını içeren M -boyutlu ağırlık vektörü $\mathbf{w}_t(k)$ ise aşağıdaki gibi tanımlanmaktadır:

$$\mathbf{w}_t(k) = \begin{bmatrix} \mathbf{w}_t^{(2,1)}(k) \\ \mathbf{w}_1^{(1,0)}(k) \\ \vdots \\ \mathbf{w}_u^{(1,0)}(k) \end{bmatrix} \quad (4)$$

burada u gizli katmandaki nöron sayısını temsil ederken, $M = u(n+1) + (u+1)$ ve $t = 1, 2, \dots, m$ 'dir.

YSA yapısına ait durum ve istenen çıkış denklemleri ise aşağıdaki gibi tanımlanmaktadır [8, 24, 32]:

$$\mathbf{w}_t(k) = \mathbf{w}_t(k-1) + \mathbf{v}_t(k) \quad (5)$$

$$d_t(k) = f(\mathbf{w}_t(k-1), \mathbf{x}(k)) + c_t(k) \quad (6)$$

burada $\mathbf{w}_t(k)$ ve $\mathbf{x}(k) = \{x_t(k)\} \in \mathfrak{X}^n$ ifadeleri sırasıyla YSA yapısının k anındaki durum ve giriş vektörlerini temsil ederken, $f(\cdot): \mathfrak{X}^n \rightarrow \mathfrak{X}^m$ ifadesi YSA yapısının doğrusal olmayan fonksiyonunu temsil etmektedir. Ayrıca, (5) ve (6)'da yer alan $\mathbf{v}_t(k)$ ve $c_t(k)$ ifadeleri sıfır ortalamaya sahip rastgele Gauss süreçler olarak tanımlanmaktadır.

Bu tanımlamaların ardından, [8, 24]'de yer alan yöntem kullanılarak, YSA yapısı doğrusallaştırma işlemine tabi tutulur. Böylece doğrusallaştırılmış YSA çıkışı $\tilde{y}_t(k)$ aşağıdaki gibi elde edilmiş olur:

$$\tilde{y}_t(k) = \mathbf{h}_t^T(k) \mathbf{w}_t(k) \quad (7)$$

burada $\mathbf{h}_t(k)$ ifadesi doğrusallaştırma sürecinde elde edilen Jacobian matrisinin t 'inci sütun vektörünü temsil etmekte olup aşağıda tanımlanmıştır:

$$\mathbf{h}_t(k) = \begin{bmatrix} \frac{\partial y_t(k)}{\partial \mathbf{w}_t^{(2,1)}(k)} \\ \frac{\partial y_t(k)}{\partial \mathbf{w}_1^{(1,0)}(k)} \\ \vdots \\ \frac{\partial y_t(k)}{\partial \mathbf{w}_u^{(1,0)}(k)} \end{bmatrix} = \begin{bmatrix} G'(z_t^{(2,1)}(k)) \mathbf{s}^{(2,1)}(k) \\ G'(z_t^{(2,1)}(k)) w_{t,1}^{(2,1)}(k) F_1'(z_1^{(1,0)}(k)) \mathbf{s}^{(1,0)}(k) \\ \vdots \\ G'(z_t^{(2,1)}(k)) w_{t,u}^{(2,1)}(k) F_u'(z_u^{(1,0)}(k)) \mathbf{s}^{(1,0)}(k) \end{bmatrix} \quad (8)$$

burada $G'(z_t^{(2,1)}(k)) = 1 - (z_t^{(2,1)}(k))^2$ ve $F'(z_u^{(1,0)}(k)) = 1 - (z_u^{(1,0)}(k))^2$ 'dir, $\mathbf{s}^{(1,0)}(k)$ giriş katmanından gizli katmana olan giriş vektörünü, $\mathbf{s}^{(2,1)}(k)$ gizli katmandan çıkış katmanına olan giriş vektörünü, $z_t^{(1,0)}(k)$ ve $z_u^{(1,0)}(k)$ fonksiyonları her bir nöronun toplanmış çıkışlarını, $F(\cdot) = G(\cdot) = (1 - e^{-\beta(\cdot)}) / (1 + e^{-\beta(\cdot)})$ fonksiyonları tanjant sigmoid fonksiyonlarını, $F'(\cdot)$ ve $G'(\cdot)$ ise sırasıyla $F(\cdot)$ ve $G(\cdot)$ 'nin türevlerini temsil etmektedir.

Yapılan bu doğrusallaştırma işleminin ardından, LKT dikkate alınarak, YSA'nın t 'inci çıkışı için öncelikle aday Lyapunov fonksiyonu olarak $V_t(k) = a_t^k e_t^2(k)$ ($a_t > 1$ için) fonksiyonu seçilir. Ardından, LKT'nin kesin negatiflik şartının [30] kısıt fonksiyonu olarak kullanıldığı bir kısıtlı eniyileme problemi aşağıdaki gibi oluşturulur:

$$\begin{aligned} & \text{Argmin} \left(\frac{1}{2} \delta \mathbf{w}_t^T \delta \mathbf{w}_t \right) \\ & \text{subject to} \\ & (a_t^k e_t^2(k) - a_t^{k-1} e_t^2(k-1)) < 0, \forall k \end{aligned} \quad (9)$$

burada $\delta \mathbf{w}_t = \mathbf{w}_t(k) - \mathbf{w}_t(k-1)$ 'dir ve $e_t(k) = d_t(k) - \mathbf{h}_t^T(k) \mathbf{w}_t(k)$ ifadesi YSA'nın hata sinylidir. Denklem (9)'da yer alan kısıt fonksiyonu sayesinde, eniyileme işleminin Lyapunov anlamında kararlılığı her zaman garanti edilecektir. Denklem (9), Lagrange çarpanlar teoremi kullanılarak çözülecek olur ise YSA için aşağıdaki ağırlık vektörü güncelleme kuralı [24] elde edilmiş olur:

$$\begin{aligned} \mathbf{w}_t(k) &= \mathbf{w}_t(k-1) \\ &+ \frac{\mathbf{h}_t(k)}{\|\mathbf{h}_t(k)\|^2} \left(1 - \frac{|e_t(k-1)|}{(a_t(k-1))^{k/2} |\alpha_t(k)|} \right) \alpha_t(k) \end{aligned} \quad (10)$$

burada $\alpha_t(k) = d_t(k) - \mathbf{h}_t^T(k) \mathbf{w}_t(k-1)$ ve $a_t(k) = 1 + e_t^2(k-1) / e_t^2(k)$ sırasıyla ön kestirim hatası ve adaptasyon kazanç oranıdır. Adaptasyon kazanç oranı $a_t(k)$ 'nın, ardışık eğitim hata oranlarına bağlı olarak güncellendiği ve dolayısıyla eğitim sürecini önemli ölçüde iyileştirdiği unutulmamalıdır [24]. Ayrıca bu parametre başlangıçta $a_t(0) > 1$ [24] olarak ayarlanmıştır. Bununla birlikte temel sebebi Lyapunov anlamında eğitim hatası $e_t(k)$ 'nin asimptotik yakınsamasının her zaman sağlanması içindir.

Ayrıca, Denklem (10)'un payda kısımlarında oluşabilecek tekillik problemleri, başarıyı etkilemeyecek kadar küçük bir λ pozitif değişkeni ile aşağıdaki gibi ortadan kaldırılabılır.

$$\begin{aligned} \mathbf{w}_t(k) &= \mathbf{w}_t(k-1) + \frac{\mathbf{h}_t(k)}{\lambda + \|\mathbf{h}_t(k)\|^2} \\ &\times \left(1 - \frac{|e_t(k-1)|}{\lambda + (a_t(k-1))^{k/2} |\alpha_t(k)|} \right) \alpha_t(k) \end{aligned} \quad (11)$$

Sonuç olarak, LKT tabanlı YSA algoritması bu bölümde kısaca sunulmuştur. Bu algoritma hakkında daha fazla bilgi için [24]'te yer alan çalışma incelenebilir.

3 Önerilen otomatik yüz tanıma sistemi

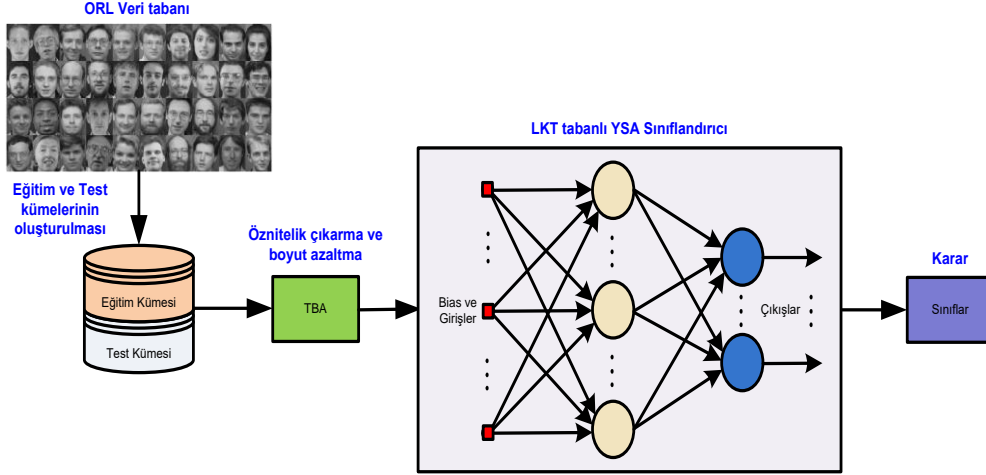
Bu bölümde, önerilen otomatik yüz tanıma sisteminin nasıl çalıştığından bahsedilmiştir. Şekil 1, önerilen otomatik tanıma sisteminin blok diyagramını göstermektedir. Şekil p önerilen yüz tanıma sisteminin adımları aşağıdaki gibidir.

- i. **Eğitim ve Test Kümesinin Oluşturulması:** Bu adımda, veri kümesi üzerinde istenilen oranlarda rastgele olmak kaydıyla eğitim ve test kümesi oluşturulmuştur.
- ii. **Öznitelik Çıkarımı ve Boyut Azaltma:** ORL yüz veri tabanı [31] görüntülerinin yüksek boyutluluğunu azaltmanın yanı sıra en bilgilendirici öznitelikleri çıkarmak için TBA metodu [10, 11] kullanılmıştır.
- iii. **LKT Tabanlı YSA Sınıflandırıcısı:** Bu adımda, bir önceki adımda çıkarılan öznitelikler ile LKT tabanlı

YSA sınıflandırıcısı [24] beslenerek eğitim süreci gerçekleştirilmiştir.

- iv. **Karar:** Bu adımda, eğitilmiş yüz görüntülerinin her biri kendi sınıfına ayrılmıştır.

Ayrıca eğitim sürecinin bitmesinin ardından ise yeni test görüntüsünün özyüz temelli özniteligi çıkarılıp eğitilmiş olan YSA'ya uygulanıp hangi sınıfa ait olduğu tespit edilmiştir.



Şekil 1. Önerilen yüz tanıma sistemi

Tablo 1. Uygulama 1 için algoritmaların test tanıma başarımı




Öznitelik Sayısı	Test Tanıma Oranı (%)			
	BP Tabanlı Yüz Tanıma Sistemi ($\eta = 0.95$, sabit)	BP Tabanlı Yüz Tanıma Sistemi ($\eta = 0.95$, adaptif)	LKT-YSA Tabanlı [8] Yüz Tanıma Sistemi ($a_i = 1.01$, sabit)	Önerilen LKT-YSA Tabanlı [24] Yüz Tanıma Sistemi ($a_i(0) = 1.01$, adaptif)
20	67.50	76.87	74.37	84.30
40	78.12	85.00	81.25	85.62
60	79.37	86.25	82.50	90.00
80	76.87	83.75	83.12	88.75
100	75.62	80.62	76.25	88.75
120	75.62	80.00	73.12	87.50
180	75.00	79.50	62.50	85.62
240	74.37	78.79	61.75	85.00

Tablo 2. Uygulama 2 için algoritmaların test tanıma başarımı

Öznitelik Sayısı	Test Tanıma Oranı (%)			
	BP Tabanlı Yüz Tanıma Sistemi ($\eta = 0.95$, sabit)	BP Tabanlı Yüz Tanıma Sistemi ($\eta = 0.95$, adaptif)	LKT-YSA Tabanlı [8] Yüz Tanıma Sistemi ($a_i = 1.01$, sabit)	Önerilen LKT-YSA Tabanlı [24] Yüz Tanıma Sistemi ($a_i(0) = 1.01$, adaptif)
20	70.5	73.75	74.0	84.0
40	77.0	79.50	80.0	84.5
60	78.5	83.00	81.5	89.0
80	76.5	82.00	80.0	88.5
100	74.5	81.00	77.0	88.5
150	72.5	76.5	74.5	88.0
200	72.0	75.0	70.0	87.0

Tablo 3. Uygulama 3 için algoritmaların test tanıma başarımları

Öznitelik Sayısı	Test Tanıma Oranı (%)			
	BP Tabanlı Yüz Tanıma Sistemi ($\eta = 0.95$, sabit)	BP Tabanlı Yüz Tanıma Sistemi ($\eta = 0.95$, adaptif)	LKT-YSA Tabanlı [8] Yüz Tanıma Sistemi ($a_i = 1.01$, sabit)	Önerilen LKT-YSA Tabanlı [24] Yüz Tanıma Sistemi ($a_i(0) = 1.01$, adaptif)
20	67.50	79.58	69.58	81.66
40	74.58	82.08	79.58	83.33
60	75.41	82.50	81.00	84.41
80	71.25	80.50	80.83	84.16
100	70.41	76.25	77.91	83.75
120	68.75	75.83	71.66	82.08
140	67.79	71.66	70.00	81.00
160	64.45	70.83	66.25	79.16



Şekil 2. 60 adet TBA özniteliği için algoritmaların eğitim MSE başarımları (a) uygulama 1 (b) uygulama 2 (c) uygulama 3

4 Veri kümesi, uygulamalar ve ön işleme süreci

4.1 Veri kümesi

Bu çalışmada sunulan uygulamalar, ORL yüz görüntüsü veri kümesi üzerinde yapılmıştır [31]. Bu veri kümesinde farklı cinsiyet, yaş ve etnik gruplara sahip 40 kişinin her biri için 10 farklı resim bulunmaktadır. Veri kümesinde farklı zamanlarda elde edilmiş ve farklı özelliklere sahip toplam 400 yüz görüntüsü bulunmaktadır. Tüm orijinal resimler 92x112 piksel çözünürlüğe sahiptir ve gri seviyededir. Bu çalışmada, 40 kişinin tüm görüntüleri kullanılmıştır.

4.2 Uygulamalar

Her uygulama için eğitim ve test kümesi şu şekilde oluşturulmuştur:

Uygulama 1: Eğitim süreci için kişi başına altı görüntü rastgele seçilirken, kalan dört görüntü eğitilmiş ağırları test etmek için uygulanmıştır (% 60 Eğitim ve % 40 Test).

Uygulama 2: Eğitim süreci için kişi başına beş görüntü rastgele seçilirken, kalan beş görüntü eğitilmiş ağırları test etmek için uygulanmıştır (% 50 Eğitim ve % 50 Test).

Uygulama 3: Eğitim süreci için kişi başına dört görüntü rastgele seçilirken, kalan altı görüntü eğitilmiş ağırları test etmek için uygulanmıştır (% 40 Eğitim ve % 60 Test).

Yukarıda verilen üç farklı uygulama ile veri kümesi üzerinde farklı oranlarda eğitim ve test kümelerinin değişimine göre algoritmaların davranışının daha açık bir şekilde gözlemlenebilmesi planlanmıştır.

4.3 Ön işleme

Bu çalışmada veriler, iki aşamadan oluşan bir ön işleme sürecinden geçirilmiştir. Bunlardan ilki, hem eşit bir yoğunluk dağılımı hem de yüz görüntülerinin kontrastını daha da iyileştirmek için yüz görüntülerine sırasıyla histogram eşitleme ile normalizasyon işleminin (1 ile -1 arasında) uygulanmasıdır. İkincisi ise, tüm uygulamalarda hem yüksek giriş boyutluluğunu azaltmak hem de öznelik çıkartmak için TBA'nın uygulanmasıdır. ORL veri kümesi dikkate alındığında, bir resim görüntüsünün boyutu 1x10304'dür. TBA sonrasında bu boyut, bu çalışmada 1x20 ile 1x240 arasında bir değere düşürülebilmektedir (Tablo 1, 2 ve 3'ten gözlemlendiği üzere).

5 Sonuçlar ve tartışma

Bu bölümde sunulan yüz tanıma sistemlerinde sınıflandırıcı olarak farklı öğrenme algoritmasına sahip dört tür YSA sınıflandırıcı kullanılmıştır. Kullanılan sınıflandırıcıya ait YSA yapısı, giriş, gizli ve çıkış katmanı olmak üzere üç katmandan oluşmaktadır. Bu çalışmada, giriş katmanının boyutu TBA öznelik sayısına, çıkış katmanının boyutu ORL veri kümesinde 40 farklı sınıf olduğu için 40'a, gizli katmanının boyutu ise 60'a kurulmuştur. Sınıflandırıcılarda kullanılan algoritmalar sırasıyla, sabit bir öğrenme oranına sahip gradyan tabanlı BP algoritması, adaptif bir öğrenme oranına sahip gradyan tabanlı BP




algoritması, sabit adaptasyon kazanç oranına sahip LKT tabanlı YSA algoritması [8] ve adaptif adaptasyon kazanç oranına sahip [24]'de önerilen LKT tabanlı YSA algoritmasıdır. Bu algoritmaların başarımları, eğitim hatası yakınsaması, eğitim tanıma oranı ve test tanıma oranı açısından karşılaştırmalı olarak değerlendirilmiştir. Her algoritmanın eğitim ve test süreçleri 2.53 GHz CPU ve 4 GB RAM içeren bir bilgisayarda gerçekleştirilmiştir. Adil bir karşılaştırma için algoritmalara ait parametreler ise şu şekilde ayarlanmıştır. (i) Önerilen yüz tanıma sisteminde kullanılan LKT tabanlı YSA algoritmasının [24] adaptasyon kazanç oranı $a_t(0) = 1.01$ değerine ayarlanırken, diğer LKT tabanlı algoritmasının [8] adaptasyon kazancı $a_t = 1.01$ değerine ayarlanmıştır. (ii) Her iki LKT tabanlı YSA algoritması için hata sinyalinin başlangıç değeri $e_t(0) = 0.01$ olarak ayarlanmıştır. (iii) Gradyan tabanlı BP algoritmalarının öğrenme oranları ise $\eta = 0.95$ olarak seçilmiştir.

Tablo 1, 2 ve 3'te sırasıyla uygulama 1, 2 ve 3 için TBA ile çıkarılan özneliklere karşı her bir algoritmanın test tanıma oranları verilmiştir. Tablo 1, 2 ve 3'ten görüldüğü gibi, adaptif adaptasyon kazanç oranına [24] sahip önerilen yüz tanıma sistemi, test için kullanılan yüz görüntülerini yüksek doğrulukta tespit ederek kişileri tanımlamada diğer yüz tanıma sistemlerinden daha iyi bir başarımla sergilemiştir. Tablo 1, 2 ve 3'te sunulan sonuçlar, bu çalışmada önerilen sistemin tanıma başarımının diğerlerine kıyasla, öznelik sayısının değişimine karşı oldukça gürbüz olduğunu göstermiştir. Ayrıca en iyi başarımlar, 60 adet öznelik için gözlemlenmiştir. Bu yüzden de Şekil 2, 3 ve 4'de, en iyi başarımın elde edildiği bu öznelik sayısı dikkate alınarak, tüm yüz tanıma sistemlerinin hata, eğitim ve test başarımları devir sayısına göre çizdirilmiştir.


Şekil 2'de, önerdiğimiz yüz tanıma sistemi ile hata yakınsamasındaki gelişme açık bir şekilde gözlemlenmiştir. Şekil 2'de görüldüğü gibi, önerilen LKT-tabanlı yüz tanıma sistemi, üç uygulama için yaklaşık 20 devir içinde minimum ortalama kare hata (Mean Square Error, MSE) değerine ulaşmıştır. Bu nedenle önerilen sistemin eğitim hatası yakınsama oranı diğerlerinden çok daha hızlıdır.

Şekil 3'te, her üç uygulama için eğitim tanıma oranlarının değişimi verilmiştir. Şekil 3'ten görüldüğü gibi, tüm uygulamalar için, önerilen sistem 40 devir içinde eğitimin % 100'ünü tamamlamıştır.

Şekil 4'te ise eğitim aşaması tamamlanan yüz tanıma sistemlerinin test başarımlarının devir sayısına göre değişimine yer verilmiştir. Görüldüğü üzere, bu çalışmada önerilen yüz tanıma sistemi, bütün uygulamalar için diğer sistemlere kıyasla yaklaşık 100 devir içinde daha yüksek bir test tanıma oranı sağlamıştır. Sonuç olarak; önerilen yüz tanıma sisteminde LKT tabanlı YSA algoritmasının sınıflandırıcı olarak kullanılması başarımları önemli ölçüde artırmıştır. Yapılan bu çalışma, önerilen yüz tanıma sisteminin başarımının, diğer sağlam öznelik çıkarma yöntemleriyle birleştirilerek daha da geliştirilebileceğini doğrulamıştır.



Şekil 3. 60 adet TBA özneteliği için algoritmaların eğitim tanıma oranı başarımları (a) uygulama 1 (b) uygulama 2 (c) uygulama 3



Şekil. 4. 60 adet TBA özneliği için algoritmaların test tanıma oranı başarımları (a) uygulama 1 (b) uygulama 2 (c) uygulama 3

6 Sonuç

Bu çalışmada, LKT tabanlı YSA algoritması [24] kullanılarak yeni otomatik bir yüz tanıma sistemi önerilmiştir. Bu amaç doğrultusunda, ilk olarak en bilgilendirici öznelikleri çıkarmak ve hesap karmaşıklığını azaltmak için TBA metodu kullanılmıştır. Ardından, çıkarılan öznelikle LKT tabanlı YSA bir sınıflandırıcı olarak beslenmiştir. Önerilen yüz tanıma sisteminin

başarımı, diğer sistemlerle karşılaştırmalı olarak ORL veri kümesi üzerinde değerlendirilmiştir. Deneysel sonuçlar, önerilen yüz tanıma sisteminin, adaptif adaptasyon kazanç oranı parametresi yardımıyla, daha yüksek eğitim hızının yanı sıra daha yüksek eğitim ve test tanıma oranları sağladığını kanıtlamıştır.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %11

Kaynaklar

- [1] P. N. Belhumeur, J. P. Hespanha and D. J. Kriegman, Eigenfaces vs. fisherfaces: Recognition using class specific linear projection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19 (7), 711–720, 1997. doi: [10.1109/34.598228](https://doi.org/10.1109/34.598228)
- [2] C. F. Bobis, R. C. Genezalez, J. A. Cancelas, I. Alvarez and J. M. Enguita, Face recognition using binary thresholding for features extraction. In *Proceedings of the IEEE International Conference on Image Analysis and Processing (ICIAP)*, pp. 1077-1080, IEEE, 1999. doi: [10.1109/ICIAP.1999.797742](https://doi.org/10.1109/ICIAP.1999.797742)
- [3] S. Cagnoni, A. Poggi, and G. L. Porcari, A modified modular eigenspace approach to face recognition. In *Proceedings of the 10th International Conference on Image Analysis and Processing (ICIAP)*, pp. 490-495, IEEE, 1999. doi: [10.1109/ICIAP.1999.797643](https://doi.org/10.1109/ICIAP.1999.797643)
- [4] S. C. Yan, H. Wang, X. O. Tang and T. Huang, Exploring features descriptors for face recognition. In *Proceedings of the 32nd IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP)*, pp. 629-632, 2007. doi: [10.1109/ICASSP.2007.365986](https://doi.org/10.1109/ICASSP.2007.365986)
- [5] M. Kirby and L. Sirovich, Application of the Karhunen-Loeve procedure for the characterization of human faces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12, 103–108, 1990. doi: [10.1109/34.41390](https://doi.org/10.1109/34.41390)
- [6] W. Hu, O. Farooq and S. Datta, Wavelet based subspace features for face recognition. In *Proceedings of the International Congress on Image and Signal Processing (ICSP)*, pp. 426-430, IEEE, 2008. doi: [10.1109/CISP.2008.618](https://doi.org/10.1109/CISP.2008.618)
- [7] A. S. Mian, M. Bennamoun and R. Owens, An efficient multimodal 2D-3D hybrid approach to automatic face recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29 (11), 1927–1943, 2007. doi: [10.1109/TPAMI.2007.1105](https://doi.org/10.1109/TPAMI.2007.1105)
- [8] K. H. Lim, K. P. Seng, L. Ang and S. W. Chin, Lyapunov theory-based multilayered neural network. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 56 (4), 305-309, 2009. doi: [10.1109/TCSII.2009.2015400](https://doi.org/10.1109/TCSII.2009.2015400)
- [9] L. Ang, K. H. Lim, K. P. Seng and S. W. Chin, A Lyapunov theory-based neural network approach for face recognition. *Intelligent Systems for Automated Learning and Adaptation*, IGI Global Press, pp. 23–48, 2010. doi: [10.4018/978-1-60566-798-0.ch002](https://doi.org/10.4018/978-1-60566-798-0.ch002)
- [10] M. J. Er, S. Wu, J. Lu and H. L. Toh, Face recognition with radial basis function (RBF) neural networks. *IEEE Transactions on Neural Networks*, 13 (3), 697–710, 2002. doi: [10.1109/TNN.2002.1000134](https://doi.org/10.1109/TNN.2002.1000134)
- [11] M. J. Er, W. L. Chen and S. Q. Wu, High-speed face recognition based on discrete cosine transform and RBF neural network. *IEEE Transactions on Neural Networks*, 16 (3), 679–691, 2005. doi: [10.1109/TNN.2005.844909](https://doi.org/10.1109/TNN.2005.844909)
- [12] J. Zhou, Y. Liu and Y. H. Chen, Face recognition using kernel PCA and hierarchical RBF network. In *Proceedings of the 6th IEEE International Conference on Computer Information Systems and Industrial Management Applications (CISIM)*, 239-244, 2007. doi: [10.1109/CISIM.2007.28](https://doi.org/10.1109/CISIM.2007.28)
- [13] S. H. Lin, S. Y. Kung and L. J. Lin, Face recognition/detection by probabilistic decision-based neural network. *IEEE Transactions on Neural Networks*, 8, 114–132, 1997. doi: [10.1109/72.554196](https://doi.org/10.1109/72.554196)
- [14] S. A. Nazeer, N. Omar and M. Khalid, Face recognition system using artificial neural network approach. In *Proceedings of the International Conference on Signal Processing, Communication and Networking (ICSCN)*, 420-425, 2007. doi: [10.1109/ICSCN.2007.350774](https://doi.org/10.1109/ICSCN.2007.350774)
- [15] R. Chellappa, C. Wilson and S. Sirohey, Human and machine recognition of faces: A survey. *Proceedings of the IEEE*, 83 (5), 705–740, 1995. doi: [10.1109/5.381842](https://doi.org/10.1109/5.381842)
- [16] D. Valentin, H. Abdi, A. J. O’toole and G. W. Cottrell, Connectionist models of face processing: A survey. *Pattern Recognition*, 27, 1209–1230, 1994. doi: [10.1016/0031-3203\(94\)90006-X](https://doi.org/10.1016/0031-3203(94)90006-X)
- [17] J. Bilski and L. Rutkowski, A fast training algorithm for neural networks. *IEEE Transactions on Circuits and Systems II: Analog Digital and Signal Processing*, 45 (6), 749-753, 1998. doi: [10.1109/82.686696](https://doi.org/10.1109/82.686696)
- [18] C. Charalambous, Conjugate gradient algorithm for efficient training of artificial neural networks. *IEEE Proceedings*, 139 (3), 301–310, 1992. doi: [10.1049/ip-g-2.1992.0050](https://doi.org/10.1049/ip-g-2.1992.0050)
- [19] G. Lera and M. Pinzolas, Neighborhood based Levenberg-Marquardt algorithm for neural network training. *IEEE Transactions on Neural Networks*, 13 (5), 1200-1203, 2002. doi: [10.1109/TNN.2002.1031951](https://doi.org/10.1109/TNN.2002.1031951)
- [20] S. Osowski, P. Bojarczak and M. Stodolski, Fast second order learning algorithm for feedforward multilayer neural network and its applications. *Neural Networks*, 9 (9), 1583–1596, 1992. doi: [10.1016/S0893-6080\(96\)00029-9](https://doi.org/10.1016/S0893-6080(96)00029-9)
- [21] L. Behera, S. Kumar and A. Patnaik, On the adaptive learning rate that guarantees convergence in feedforward networks. *IEEE Transactions on Neural Networks*, 17 (5), 1116–1125, 2006. doi: [10.1109/TNN.2006.878121](https://doi.org/10.1109/TNN.2006.878121)
- [22] X. Jing and L. Cheng, An optimal-PID control algorithm for training feed-forward neural networks. *IEEE Transactions on Industrial Electronics*, 60 (6), 2273-2283, 2013. doi: [10.1109/TIE.2012.2194973](https://doi.org/10.1109/TIE.2012.2194973)
- [23] K. P. Seng, Z. Man and H. R. Wu, Lyapunov theory-based radial basis function networks for adaptive filtering. *IEEE Transactions on Circuits Systems I: Fundamental Theory Applications*, 49 (8), 1215-1220, 2002. doi: [10.1109/TCSI.2002.801255](https://doi.org/10.1109/TCSI.2002.801255)
- [24] N. Acır and E. C. Mengüç, Lyapunov theory based adaptive learning algorithm for multilayer neural

- networks. *Neural Network World*, 24 (6), 619–636, 2014. doi: [10.14311/NNW.2014.24.035](https://doi.org/10.14311/NNW.2014.24.035)
- [25] E. C. Mengüç and N. Acır, A novel adaptive filter design using Lyapunov stability theory. *Turkish Journal of Electrical Engineering and Computer Sciences*, 23 (3), 719-728, 2015. doi: [10.3906/elk-1212-29](https://doi.org/10.3906/elk-1212-29)
- [26] E. C. Mengüç and N. Acır, Real-time implementation of Lyapunov stability theory-based adaptive filter on FPGA. *IEICE Transactions on Electronics*, 99 (1), 129-137, 2016. doi: [10.1587/transele.E99.C.129](https://doi.org/10.1587/transele.E99.C.129)
- [27] E. C. Mengüç and N. Acır, An augmented complex-valued Lyapunov stability theory based adaptive filter algorithm. *Signal Processing*, 137, 10-21, 2017. doi: [10.1016/j.sigpro.2017.01.031](https://doi.org/10.1016/j.sigpro.2017.01.031)
- [28] E. C. Mengüç and N. Acır, A generalized Lyapunov stability theory-based adaptive FIR filter algorithm with variable step sizes. *Signal, Image and Video Processing*, 11 (8), 1567-1575, 2017. doi: [10.1007/s11760-017-1121-8](https://doi.org/10.1007/s11760-017-1121-8)
- [29] E. C. Mengüç and N. Acır, A novel adaptive filter algorithm for tracking of chaotic times series. 2011 IEEE 19th Signal Processing and Communications Applications Conference (SIU), 490-493, 2011. doi: [10.1109/SIU.2011.5929694](https://doi.org/10.1109/SIU.2011.5929694)
- [30] H. K. Khalil, *Nonlinear Systems*. Macmillan, New York, NY, 1992.
- [31] ORL Database of Faces, The database of faces Olivetti Research Laboratory. <http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html>, Accessed 3 March 2015.
- [32] C. S. Leung, A. C. Tsoi and L. W. Chan, Two regularizes for recursive least squared algorithms in feedforward multilayered neural networks. *IEEE Transactions on Neural Networks*, 12 (6), 1314-1332, 2001. doi: [10.1109/72.963768](https://doi.org/10.1109/72.963768)

