

YÜZ GÖRÜNTÜLERİNE AYRIK KOSİNÜS DÖNÜŞÜMÜ UYGULANARAK GÖRÜNTÜ SINIFLANDIRMA SONUÇLARININ İYİLEŞTİRİLMESİ

Abdullah ŞENER *^{ID}

Burhan ERGEN **^{ID}

Alınma: 20.02.2022; düzeltme: 14.11.2022; kabul: 06.12.2022

Öz: Günümüzde teknolojinin gelişmesi yapay zekâ çalışmalarının da hızlı bir şekilde gelişmesine olarak sağlamaktadır. Gelişen yapay zekâ çalışmaları arasında son zamanlarda popülerliği yüksek olan konulardan birisi sanal ortamlarda gerçekçi sahte yüzlerin oluşturulması ve kullanılmasıdır. Yapılan çalışmada içerisinde sahte ve gerçek yüzlerin yer aldığı görüntüler kullanılarak yüzlerin sahte/gerçek olduğunu ayırt etmek için bir dizi çalışmalar yapılmıştır. Yapılan çalışmada iki farklı sınıflandırma modeli (VGG, Xception) ve görüntüler üzerinde üç farklı yöntem (normal görüntü, Fourier dönüşümlü görüntü, Ayrik Kosinüs dönüşümlü görüntü) uygulanarak ayrı ayrı sınıflandırma işlemleri gerçekleştirilmiştir. Elde edilen sonuçlar karşılaştırılarak araştırmacılara kaynak olarak sunulmuştur.

Anahtar Kelimeler: Görüntü sınıflandırma, Derin öğrenme, Fourier dönüşümü, Ayrik Kosinüs dönüşümü

Improving Image Classification Results by Applying Discrete Cosine Transform to Face Images

Abstract: Today, the development of technology enables the rapid development of artificial intelligence studies. One of the most popular topics among the developing artificial intelligence studies is the creation and use of realistic false faces in virtual environments. In the study, a series of studies were conducted to distinguish between false and real faces based on images containing false and real faces. In the study, two different classification models (VGG, Xception) and three different methods (normal image, Fourier transform image, discrete cosine transform image) were applied to images and separate classification processes were performed. The obtained results were compared and provided to the researchers as a resource.

Keywords: Image classification, Deep learning, Fourier transform, Discrete Cosine transform

1. GİRİŞ

Teknolojinin gelişmesiyle birlikte son yıllarda derin öğrenme konusunda önemli gelişmeler yaşanmıştır (Wu, X. ve diğ., 2017). Bir veya daha fazla gizli katmandan oluşan yapay sinir ağı ve benzeri makine öğrenmesi yöntemlerini içeren metoda derin öğrenme denilmektedir. Derin öğrenmede amaç içerdiği en az bir yapay sinir ağını kullanarak verilerden yeni veriler elde edilmesidir (Bengio, Y. ve diğ., 2007)(Francois-Lavet ve Vincent, 2018). Günümüzde derin öğrenme teknikleri birçok alanda kullanılmaktadır. Bu alanlardan bir tanesi bilgisayar ortamında

* Bingöl Üniversitesi, Genç Meslek Yüksekokulu, Bilgisayar Teknolojileri Programı, 12500 Bingöl, Türkiye

** Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 23100 Elazığ, Türkiye

İletişim Yazarı: Abdullah ŞENER (asener@bingol.edu.tr)

görüntü üretimidir (Wu, X. ve diğ., 2017). İlk olarak derin öğrenme yöntemi kullanılarak bilgisayar ortamında görüntü üretebilen model 2014 yılında Goodfellow tarafından geliştirilmiştir (Goodfellow, I. ve diğ., 2014). Bu model GAN (Çekişmeli üretken ağlar) olarak bilinmektedir (Çelik, G., ve Talu, M. F.,2019). GAN'ların gelişmesiyle birlikte bilgisayarlar, insanları kolay bir şekilde aldatabilecek gerçekçi yüz görüntüleri üretebilmektedir (Liu, Z ve diğ., 2020).

Son yıllarda, bilgisayarlı görme alanında gelişmeler hızlı bir şekilde gerçekleşmektedir. Bu gelişmelerin bir sonucu olarak; görüntü tanıma, nesne algılama, görüntü sınıflandırma vb. gibi birçok konunun popülerleşmesini sağlamıştır (X. Liu ve diğ., 2019). Görüntü sınıflandırma işlemi; kullanıcının belirlediği özelliklere göre görüntüyü meydana getiren piksellerin her bir görüntü üzerindeki diğer piksellerle karşılaştırılıp benzerlik oranı yüksel olanların aynı sınıflarda toplanması işlemidir (Campbell, J.B., 2011). Görüntü sınıflandırma işleminin temel amacı aynı spektral özelliklere sahip görüntüleri gruplandırmaktır (Gao J., 2009).

Literatürde görüntüler üzerinde yüz tespitinde sınıflandırma yöntemlerinin kullanılması ile ilgili birçok çalışma mevcuttur. Bu çalışmalardan bazıları incelenecek olursa; Zehra ve Burhan yaptıkları çalışmada yüz imgelerinin belirli bir kişiye ait olup olmadığını sınıflandırma yöntemleri kullanarak gerçekleştirmişlerdir (Karhan, Z., ve Ergen, B., 2013). Nhu-Tai Do ve ark. yaptıkları çalışmada adli bilişim görüntüleri üzerinde yüzleri tespit etmek için derin bir evrimsel sinir ağı önermişlerdir (Do, N. T.,ve diğ., 2018). Nesrin ve Derya destek vektör makineleri kullanarak yüz tanıma uygulaması geliştirmişlerdir (Atasoy, N. A. ve Tabak,D., 2018). Ersin ve Çetin görünüm tabanlı yüz tanıma yöntemleri kullanılarak cinsiyet belirleme çalışmasını gerçekleştirmişlerdir (Öztürk, E., & Kurnaz, Ç., 2020). Yaman ve ark. çalışmalarında derin öğrenme ile yüz görüntülerinden cinsiyet tanıma üzerine çalışmışlardır (Akbulut, Y., ve diğ., 2017). Adhinata, F. ve Junaidi, A. FaceNet algoritması ve denetimli makine öğrenimi kullanılarak videoda cinsiyet sınıflandırması konusu üzerine çalışmışlardır (Adhinata, F., ve Junaidi, A., 2022). X. Tao ve D. Pan yaptıkları çalışmada Ölçekte değişmez özellik dönüşümüne ve bulanık akıl yürütmeye dayalı yüz tanıma işlemini gerçekleştirmişleridir (Tao, X., ve Pan, D., 2022).

Yapılan çalışmada sahte/gerçek yüz görüntüleri kullanılarak, sınıflandırma modellerinin doğruluk oranlarını arttırmada Fourier ve Ayırk Kosinüs dönüşümün etkisi tespit edilmeye çalışılmıştır. Bu çalışmada VGG-19 ve Xception sınıflandırma modelleri kullanılmıştır. Her bir modelinde veri setindeki görüntüler işleme tabii tutulmadan, görüntülere Fourier dönüşümü işlemine tabii tutularak ve görüntülere ayırk kosinüs dönüşümü işlemine tabii tutularak sınıflandırma işlemleri gerçekleştirilmiştir. Elde edilen sonuçlara göre kullanılan yöntem ve modeller karşılaştırılmıştır.

Çalışmanın diğer bölümleri hakkında özet bilgiler şu şekildedir; 2. bölümde Materyal ve Metotlardan bahsedilmiştir. Ayrıca yine bu bölümde önerilen yöntem ile ilgili bilgiler yer almaktadır. Deneysel analiz sonuçlarına 3. bölümde yer verilmiştir. Tartışma ve sonuçlar ise 4. ve 5. bölümde yer almaktadır.


2. MATERYAL VE METOD

Bu bölümde sınıflandırma işlemini gerçekleştirilen veri seti ve sınıflandırma işleminde kullanılan modeller hakkında bilgiler içermektedir.

2.1. Veri Seti

Yapılan çalışmada kullanılacak sınıflandırma modellerinin performanslarını değerlendirmek için içerisinde gerçek ve sahte yüzlerin bulunduğu görüntülerden oluşan açık kaynaklı bir veri seti kullanılmıştır. Kullanılan veri seti Yonsei Üniversitesi Bilgisayar Bilimleri Bölümü, Hesaplama Zekâ ve Fotoğraf Laboratuvarı tarafından oluşturulmuştur. Veri seti 960 sahte ve 1081 gerçek yüz görüntüleri olmak üzere toplamda 2041 görüntüden oluşmaktadır.

Ayrıca sahte yüzlerin bulunduğu görüntüler kolay, orta ve zor olmak üzere 3 kategoriye ayrılmıştır. Veri setindeki görüntüler 600x600 piksel çözünürlüğe sahiptir (C.I. a. P.Lab. 2019). Veri setini oluşturan görüntülerin bazıları Şekil 1’de gösterilmektedir.



Şekil 1:
Gerçek ve Sahte görüntüler (C.I. a. P.Lab. 2019).

2.2. Derin Öğrenme

Derin öğrenme, birden fazla katmandan oluşmuş üzerinde çalıştığı veri setine uygun tahminler yapabilen veya sonuçlar üretebilen bir makine öğrenme yöntemleridir. Derin öğrenmedeki amaç, temelinde içerdiği yapay sinir ağını kullanarak üzerinde çalıştığı verilerden yeni veriler türetmektir. Derin öğrenme yöntemleri arasında popülerliği en yüksek olan yöntem Evrişimli Sinir Ağları (CNN) mimarisidir (Gu J, ve diğ., 2018). CNN mimarisi insan beyninin görsel korteksinin çalışma prensibine benzer şekilde ortak özelliklere sahip görüntüleri tanımakta ve bir araya getirerek görüntüler üzerinde sınıflandırma işlemlerini gerçekleştirir (Min S., ve diğ., 2017). CNN mimarisi evrişim katmanı, doğrusal olmayan katman, havuzlama katmanı, düzleştirme katmanı ve tamamen bağlı katmanlarının birleşiminden oluşmaktadır (Hanbay K., 2020). CNN mimarisinin yapısına ve katmanların özelliklerine bakılacak olursa; en yoğun matematiksel işlemlerin gerçekleştiği katman evrişim katmanıdır. Evrişim katmanı CNN mimarisinin temelini oluşturmaktadır. Bu katmanda görüntülere bazı filtreler uygulanarak düşük ve yüksek seviyeli özellik saptama işlemi gerçekleştirilir. Doğrusal olmayan katmanda sistemde doğrusal olmayan durumların belirlenmesi gerçekleştirilmektedir. Bu katmanda en iyi sonucu ReLU fonksiyonu vermektedir. ReLU fonksiyonu aşağıda gösterilen denklem 1 gibidir.

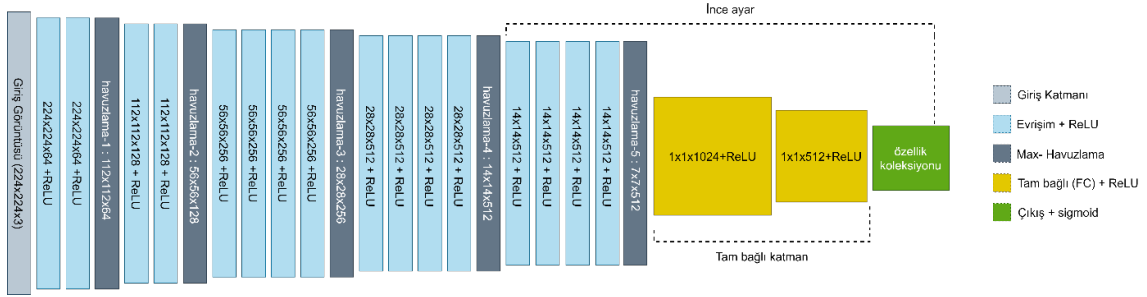
$$(f * g)(t) = \int_{-\infty}^{+\infty} f(T)g(t - T)dT \quad (1)$$

Havuzlama katmanında ise özellik haritalarının boyutu küçültülüp sistem üzerindeki ağırlık sayısı azaltılarak ağ içerisindeki parametrelerin sayısının azaltılması işlemi gerçekleştirilmektedir. Bu işlemleri maximum havuzlama (görüntü nxn matrislere bölünerek bu matrisler içindeki en

yüksek değeri alınarak) veya ortalama havuzlama (görüntü $n \times n$ matrislere bölünerek bu matrisler içindeki değerlerin ortalaması alınarak) işlemi ile gerçekleştirmektedir. Düzleştirme Katmanının görevi CNN mimarisinin son katmanı olan tam bağlı katmanın girişi için verileri hazırlamaktır. Genellikle bu katman kendisine gelen verileri tek boyutlu bir matrise dönüştürerek bu işlemi gerçekleştirir. Tam bağlı katman giriş katmanı ve çıkış katmanı arasında ilişki kurma işlemini gerçekleştirmektedir (Niepert M. ve diğ., 2014)(Kurt F., 2018).

2.3. VGG-19

VGG-19, 24 katman derinliğine sahip evrişimsel bir sinir ağıdır. Bu katmanları 16 evrişimsel, 5 havuzlama ve 3 tam bağlantılı katmandan oluşmaktadır (Toğaçar, M., ve diğ., 2020). ImageNet veritabanında bulunan bir milyondan fazla görüntü üzerinde önceden eğitilmiştir. VGG-19 ağı, 224×224 piksel boyutlarında bir görüntü girişine sahiptir. VGG-19 mimarisi incelendiğinde yaklaşık olarak 138 milyon parametreden oluştuğu görülmektedir. VGG-19, parametre sayısını azaltmak için evrişimsel katmanda 3×3 piksel boyutunda filtreler kullanmaktadır. Şekil 2 'de VGG-19 mimarisi gösterilmektedir.

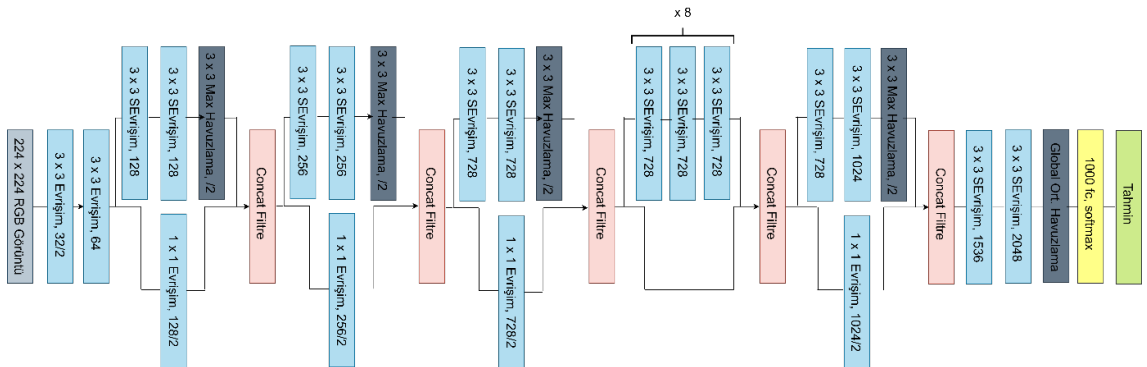


Şekil 2:

VGG-19 mimarisi (Mostafiz, R., ve diğ. 2020).

2.4. Xception

GoogLeNET (Inception V1), Google mühendisleri tarafından "Network-In-Network" çalışmasından esinlenerek oluşturulmuştur (M. Lin, ve diğ., 2014). Daha sonra Inception V2 ve Inception V3 versiyonları geliştirilmiştir (C. Szegedy, ve diğ., 2016). Xception mimarisi, standart Inception modüllerini derinlemesine ayrılabilir evrişimle değiştiren Inception mimarisinin bir uzantısıdır (F. Chollet, 2017)(Söylemez, Ö. F., ve Ergen, B., 2020). ImageNet veritabanında bulunan bir milyondan fazla görüntü üzerinde önceden eğitilmiştir. Xception ağı, 224×224 piksel boyutlarında bir görüntü girişine sahiptir. Girdi olarak alınan verileri sıkıştırılmış parçalara bölmek yerine, her bir çıktı kanalı için uzamsal korelasyonları ayrı eşler ve kanallar arası korelasyona ulaşmak için 1×1 derinlikte evrişim gerçekleştirir. Xception mimarisi Şekil 3'te gösterilmektedir.



Şekil 3:

Xception mimarisi (Ganguly, S., ve diğ., 2022)

2.5. Fourier Dönüşümü

Fourier dönüşümü, bir işaret veya sinyalin, farklı genlik, frekans ve fazlarda kosinüs ve sinüs fonksiyonlarının bir kombinasyonu olarak ifade etmek üzere yapılan matematiksel işleme verilen isimdir (Hanbay, K., ve diğ.,2017)(Cooley J.W. ve Tukey J.W., 1965) (Akben S.B. ve Alkan A.,2015). Fourier dönüşümü görüntü işlemenin önemli konularından birisidir. Fourier dönüşümü yapılmış görüntü sinüzoidal bileşenlerine ayrılmıştır. Bu sayede görüntünün belirli frekanslarını incelemek veya işlemek, uzamsal alandaki geometrik yapısını etkilemek ve değişiklik yapmak kolaydır. $M \times N$ boyutundaki bir F giriş görüntüsünün Fourier dönüşümündeki $F(u,v)$ katsayıları denklem 2 ve denklem 3 yardımıyla aşağıdaki gibi hesaplanır (Hanbay, K., ve diğ.,2017).

$$F(u, v) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) e^{-j2\pi\left(\frac{ux}{M} + \frac{vy}{N}\right)} \quad (2)$$

$$f(x, y) = \frac{1}{MN} \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} F(u, v) e^{j2\pi\left(\frac{ux}{M} + \frac{vy}{N}\right)} \quad (3)$$

Denklem 2 ve denklem 3 kullanılarak elde edilen Fourier katsayıları karmaşık sayılardan oluşur. Bu sayıların gösterimi denklem 4'te gösterildiği gibidir.

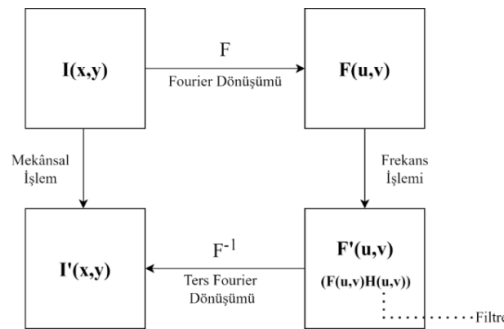
$$H(u, v) = R(u, v) + jI(u, v) \quad (4)$$

Fourier dönüşümü bir görüntüye uygulandıktan sonra yüksek frekanslı geçiş yapılan piksel değerleri yüksek, düşük frekanslı geçiş yapılan frekansların değerleri düşük çıkar. Dönüşüm uygulanan görüntünün tekrar orijinal hâline dönüştürülebilmesi için genlik ve faz bilgilerine ihtiyaç duymaktadır. Genlik ve faz değerleri aşağıda gösterilen denklem 5 ve denklem 6 yardımıyla aşağıdaki gibi hesaplanır.

$$|F(u, v)| = \sqrt{R^2(u, v) + I^2(u, v)} \quad (5)$$

$$\phi(u, v) = \tan^{-1} \frac{I(u, v)}{R(u, v)} \quad (6)$$

Bir görüntünün frekans uzayı-imge işleme aşamaları Şekil 4'te gösterilmektedir.



Şekil 4:
İmge işleme aşamaları (Karhan, Z. ve Ergen, B., 2013).

2.6. Ayrık Kosinüs Dönüşümü

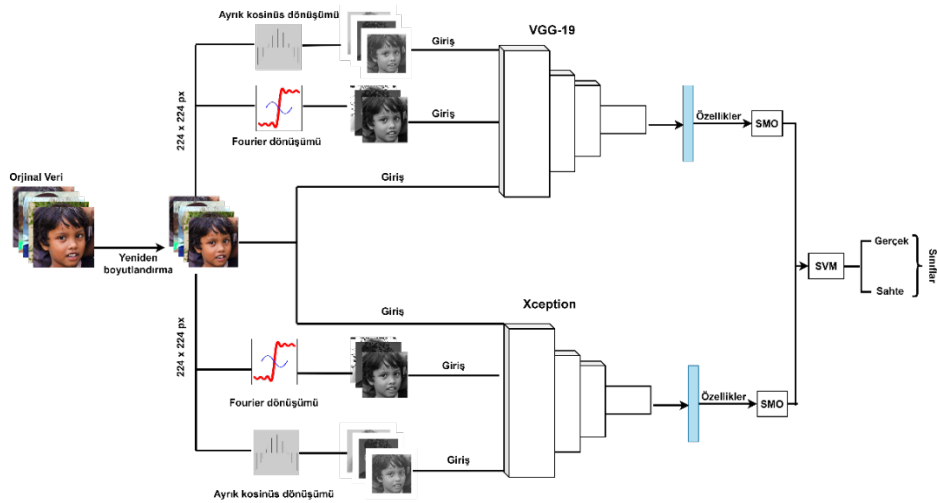
Ayrık Kosinüs dönüşümü (AKD), bir işaretin veya sinyalin frekans düzlemine dönüřtürülürken kosinüs fonksiyonu gibi gösterilmesidir (Atalar M.,2018). NxN boyutundaki bir görüntünün u. satır v. sütundaki AKD katsayısını hesaplamak için aşağıda gösterilen denklem 7 kullanılır.

$$F(u, v) = \frac{2}{N} C(u)C(v) \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} f(x, y) \cos \frac{(2x+1)u\pi}{2N} \cos \frac{(2y+1)v\pi}{2N} \quad (7)$$

Hesaplama yapıldıktan sonra elde edilen kosinüs katsayıları sinyalin gerçek kısmına aittir. Fourier dönüşümü ve diđer bazı dönüşüm yöntemlerinde sinyal gerçek ve sanal kısımlarıyla birlikte ifade edilir. Bu sebepten dolayı bilgi miktarının artmasından nedeniyle bellek kullanım miktarı da artacaktır. AKD kullanımı gerekli bellek miktarını azaltmaktadır (Atalar M.,2018).

2.7. Önerilen Yaklaşım

Yapılan çalışmada Yonsei Üniversitesi Bilgisayar Bilimleri Bölümü, Hesaplamalı Zekâ ve Fotoğraf Laboratuvarı tarafından oluşturulmuş içerisinde sahte ve gerçek yüzlerin yer aldığı veri seti kullanılarak sınıflandırma işlemleri gerçekleştirilmiştir. Yapılan çalışmanın genel tasarımı Şekil 5 te gösterilmektedir. Çalışmada Xception ve VGG-19 sınıflandırma modellerinin doğruluk başarıları karşılaştırılmıştır. Çalışmada ilk olarak görüntülerin yeniden boyutlandırılması işlemi yapılmıştır. Bu işlemin yapılma amacı sınıflandırma işlemi hızlandırmak ve bilgisayar hafızasında fazla yer tüketmesini önlemektir. Yeniden boyutlandırma işleminde görüntüler önceden belirlenmiş sabit bir boyuta getirilir. Görüntü boyutları sabitleştirilirken gereğinden fazla küçülmemesine dikkat edilmelidir. Görüntüler gereğinden fazla küçültülürse bu sefer görüntünün sınıflandırılması için gerekli olan bilgi çıkarımı zorlaşacaktır. Bu bilgiler doğrultusunda veri setindeki görüntüler sınıflandırma işlemlerine geçilmeden önce 224 x 224 piksel çözünürlüğüne düşürülmüştür. Bir sonraki aşamada her bir sınıflandırma modeline veri setindeki görüntülerin normal, ayrık kosinüs dönüşümü uygulanmış ve fourier dönüşümü uygulanmış halleri ayrı ayrı giriş verisi olarak verilerek sınıflandırma üzerindeki etkileri tespit edilmeye çalışılmıştır.



Şekil 5:
Önerilen yaklaşımın genel tasarımı.

3. DENEYSEL SONUÇLAR VE ARAŞTIRMA BULGULARI

Yapılan çalışmada sınıflandırma işlemlerini gerçekleştirilen modellerin performanslarını değerlendirmek için karmaşıklık matrisi kullanılmıştır. Karmaşıklık matrisi oluşturulurken kullanılan terimler; DP: Doğru Pozitif, YP: Yanlış Pozitif, DY: Doğru Negatif ve YN: Yanlış Negatiftir. Bu terimler kullanılarak ayrıca modelin Kesinlik, Duyarlılık, Doğruluk ve F1-Skor değerleri hesaplanabilir. Bu değerleri hesaplamak için aşağıda gösterilen 8, 9, 10 ve 11 te verilen matematiksel işlemlerle hesaplanmaktadır.

$$Kesinlik = \frac{DP}{DP + YP} \quad (8)$$

$$Duyarlılık = \frac{DP}{DP + YN} \quad (9)$$

$$Doğruluk = \frac{DP + DN}{DP + DN + YP + YN} \quad (10)$$

$$F1 - Skor = \frac{2 * Kesinlik * Duyarlılık}{Kesinlik + Duyarlılık} \quad (11)$$

VGG-19 ve Xception modellerinin eğitim ve test işlemleri PyCharm 2021 ile gerçekleştirilmiştir. Modellerde kullanılan veri seti dosyalarının işlenmesi için Python 3.6 kullanılmıştır. Çalışmada kullanılan bilgisayarın işletim sistemi 64-bit Windows 10'dur. Diğer donanım bilgileri ise NVIDIA GeForce® RTX™ 3060 6 GB ekran kartı, 11. Nesil Intel® Core™ i7 2,3 GHz (24M Önbellek, 4,6 GHz'e kadar, 8 Çekirdek) işlemci ve 16 GB bellek.

Yapılan çalışmada içerisinde sahte ve gerçek yüz görüntülerinin bulunduğu toplamda 2041 görüntünün yaklaşık %20'si kullanılarak daha hızlı sonuç alınması hedeflenmiştir. Çalışmada kullanılan 400 görüntünün 270'i eğitim, 100'ü test ve 30'u ise doğrulama için kullanılmıştır. Yapılan çalışma üç aşamalı iki deney analizinden oluşmaktadır. Birinci deneyde VGG-19 sınıflandırma mimarisi kullanılarak sahte ve gerçek yüz görüntülerinin sınıflandırma işlemi gerçekleştirilmiştir. Birinci deneyin aşamalarına bakıldığında; ilk aşamada veri setindeki görüntülere herhangi bir görüntü işleme tekniği uygulanmamıştır. Sadece görüntüler sınıflandırma modelinin giriş görüntü boyutu olan 224 x 224 piksel çözünürlüğe dönüştürülmüştür. Yeniden boyutlandırılan görüntüler sınıflandırılmıştır. Birinci deneyin ikinci aşamasında ise görüntülere sınıflandırma modeli için yapılan yeniden boyutlandırma işlemine ilave olarak her bir görüntüye Fourier dönüşümü uygulanmıştır. Daha sonra elde edilen yeni görüntüler sınıflandırılmıştır. Birinci deneyin üçüncü aşamasında ise 224 x 224 piksel çözünürlüğe dönüştürülmüş görüntülerin her birine Ayrık Kosinüs dönüşümü uygulanmıştır. Elde edilen yeni görüntüler sınıflandırılmıştır. Birinci deneyin analiz sonuçları Tablo 1'de gösterilmektedir. Analiz sonuçlarına göre VGG-19 mimarisinde en iyi sınıflandırma başarısını görüntülerin Ayrık Kosinüs dönüşümü gerçekleştirilen yöntemi ile sağlanmıştır. Elde edilen genel sınıflandırma başarılarına bakıldığında sırası ile normal görüntüler üzerinde % 40, Fourier dönüşümü gerçekleştirilen görüntüler üzerinde %40 ve Ayrık Kosinüs dönüşümü uygulanan görüntülerde %70 doğruluk oranı elde edilmiştir.

Tablo 1. VGG-19 sınıflandırma mimarisi sonuçları.

Yöntem	Sınıflar	Duyarlılık %	Kesinlik %	F-Skor %	Doğruluk %
Normal	Gerçek	41	47	44	40
	Sahte	38	33	36	
Fourier D.	Gerçek	40	40	40	40
	Sahte	40	40	40	
AKD	Gerçek	69	73	71	70
	Sahte	71	67	69	

İkinci deneyde Xception sınıflandırma mimarisi kullanılarak sahte ve gerçek yüz görüntülerinin sınıflandırma işlemi gerçekleştirilmiştir. İkinci deneyin aşamaları birinci deneyde olduğu gibi görüntüye ilk önce yeniden boyutlandırma işlemi gerçekleştirilip 224 x 224 piksel çözünürlüğe dönüştürülmüştür. Daha sonra ise yine birinci deneyde olduğu gibi görüntülerin normal hâli, Fourier dönüşümlü uygulanmış hâli ve Ayrık kosinüs dönüşümü uygulanmış hâli sırası ile sınıflandırma işlemine tabii tutulmuştur. İkinci deneyin analiz sonuçları Tablo 2’de gösterilmektedir. Analiz sonuçlarına göre bu sınıflandırma mimarisinde de en iyi sınıflandırma başarısını görüntülerin Ayrık Kosinüs dönüşümü gerçekleştirilen yöntem ile sağlanmıştır. Elde edilen genel sınıflandırma başarılarına bakıldığında sırası ile normal görüntüler üzerinde %63, Fourier dönüşümü gerçekleştirilen örüntüler üzerinde %43 ve Ayrık Kosinüs dönüşümü uygulanan görüntülerde %67 doğruluk oranı elde edilmiştir.

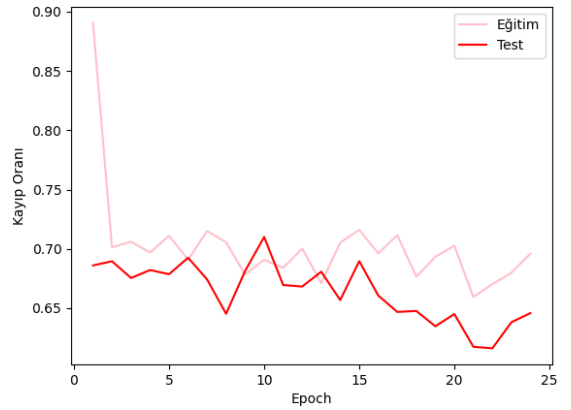
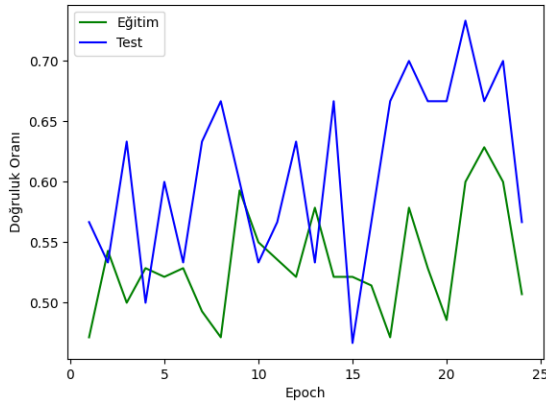
Tablo 2. Xception sınıflandırma mimarisi sonuçları.

Yöntem	Sınıflar	Duyarlılık %	Keskinlik %	F-Skor %	Doğruluk %
Normal	Gerçek	62	67	65	63
	Sahte	64	60	64	
Fourier D.	Gerçek	44	47	45	43
	Sahte	43	40	41	
AKD	Gerçek	69	60	64	67
	Sahte	65	73	69	

Yapılan çalışmada kullanılan modellerin yöntemlere göre eğitim vs. test doğruluk başarı oranları ve eğitim vs. test kayıp oranları Şekil 6’da gösterilmektedir.

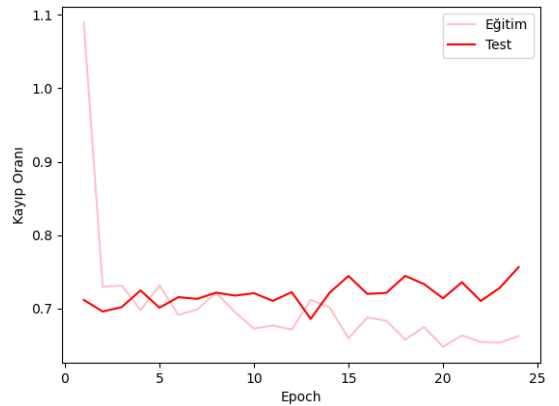
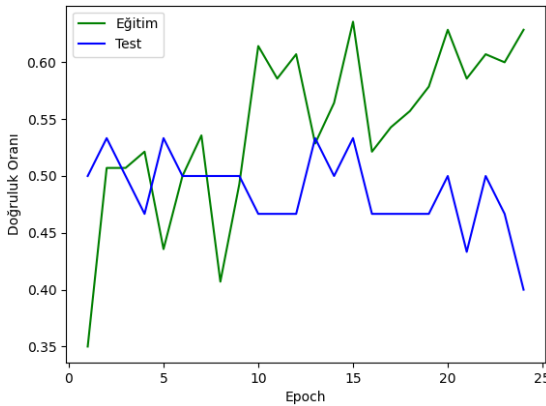
VGG-19



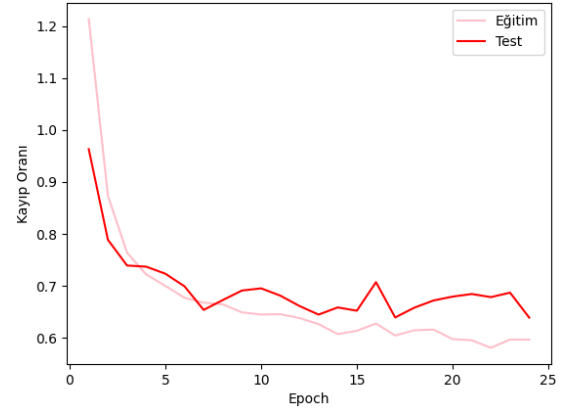
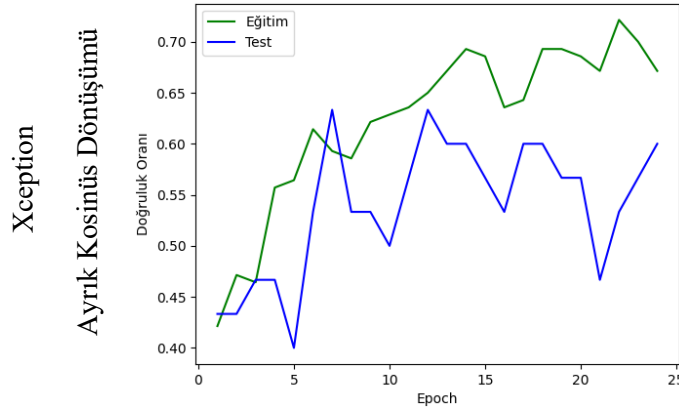
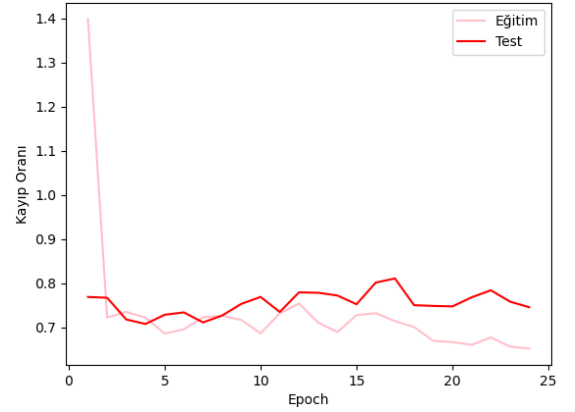
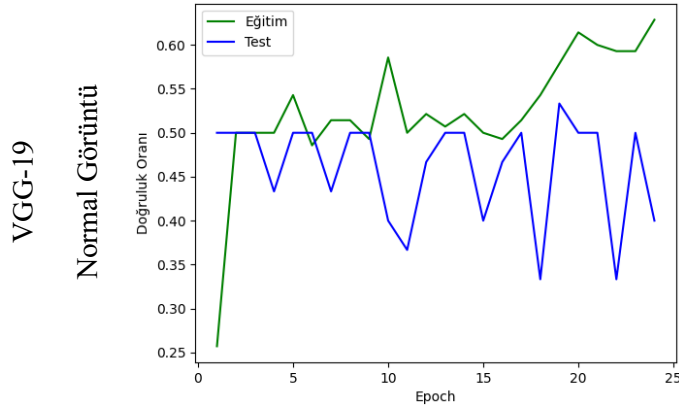
Ayrık Kosinüs Dönüşümü

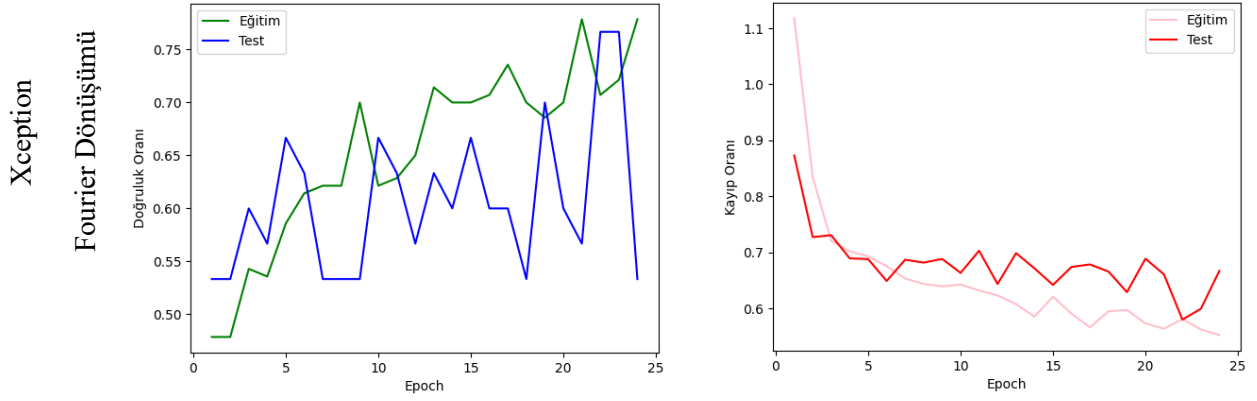


VGG-19

Fourier Dönüşümü

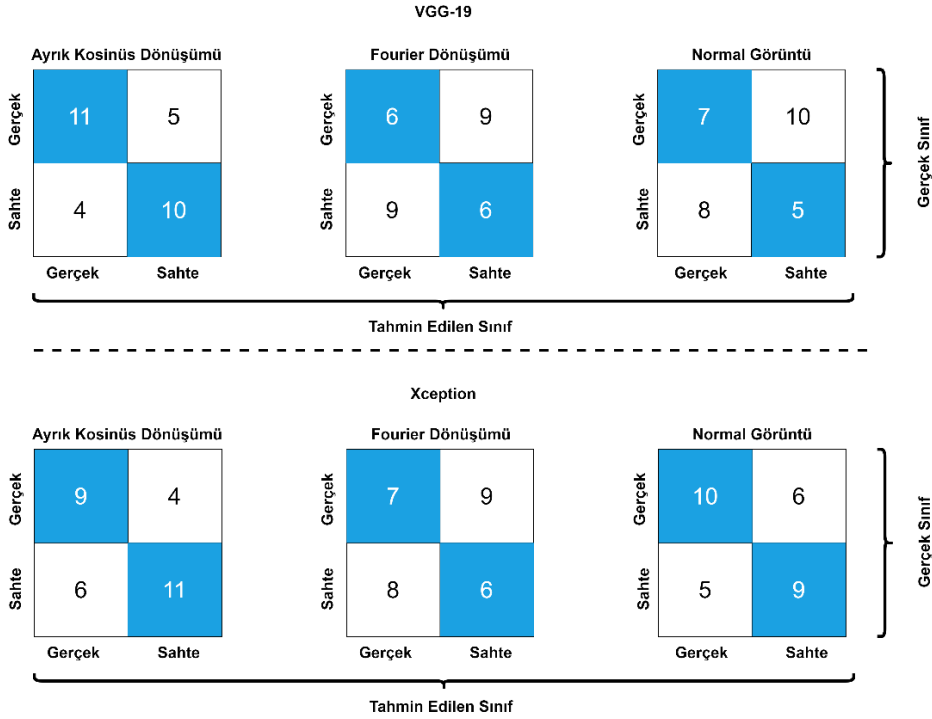






Şekil 6:
Sınıflandırma mimarilerinin yöntemlere göre doğruluk ve kayıp oranları grafikleri.

Yapılan çalışmada veri setinde bulunan toplamda 2041 görüntünün %20'si kullanılmıştır. Deneysel sonuçları veri setini oluşturan küçük bir parça üzerinde değerlendirilmesi işlemi daha hızlı gerçekleştirmek ve veri setinin geneline uygulamak için bu çalışmada sadece 400 görüntü kullanılmıştır. Çalışmada kullanılan 400 görüntünün yaklaşık %8'i (30 görüntü) doğrulama işlemi için kullanılmıştır. Çalışmanın bir sonraki aşamasında doğrulama görüntüleri ile her bir yöntem ve sınıflandırma mimarisi ayrı ayrı değerlendirilmiştir. Yapılan çalışmada doğrulama işleminde elde edilen sonuçlara göre yöntemlerin karmaşıklık matrisleri Şekil 7'de gösterilmektedir.



Şekil 7.
Yöntemleri karmaşıklık matrisleri

4. TARTIŞMA

Yapılan çalışmada gerçek ve sahte yüz görüntülerinin bulunduğu veri seti üzerinde iki sınıflandırma mimarisi ve üç yöntem karşılaştırılmıştır. Karşılaştırma sonucunda en iyi sınıflandırma doğruluk oranını VGG-19 sınıflandırma mimarisi kullanılarak ve görüntüler üzerine Ayrık Kosinüs dönüşümü uygulanarak elde edilmiştir. Yapılan çalışmada kullanılan veri seti ve benzerini kullanılarak yapılan çalışmalar ve sonuçlarına ilişkin bilgiler Tablo 3'te gösterilmektedir.

Tablo 3. Benzer veri setleri ile gerçekleştirilmiş çalışmaların karşılaştırılması.

Makale	Mimari/Yöntem	Değer (%)
Mittal, H. ve ark.(Mittal, H., ve diğ., 2020)	IQIEA-FS	58,3
McCloskey ve Albright (S. McCloskey ve M. Albright, 2019)	SVM/ AN-Pipeline Feature	70
Kim, D. ve ark. (Kim, D., ve diğ., 2018)	Deep Learning Based	88.7
Önerilen Yöntem	VGG-19/ AKD	70
	Xception / AKD	67

5. SONUÇ

Günümüzde teknolojinin gelişmesiyle birlikte sanal ortamlarda kolay bir şekilde yüksek çözünürlükte ve oldukça gerçekçi sahte yüz görüntüleri hazırlanabilmektedir. Bu durum pek çok olumsuz sonuçları beraberinde getirmektedir. Bu olumsuz sonuçların başında sanal ortamlarda dolandırıcılık ve aldatma, görüntüler üzerinde oynama ve manipülasyonlar vb. durumlar gelmektedir. Yapılan çalışmada, bu sahtecilik problemini çözmek için bir yüzün gerçek yüz mü yoksa sahte yüz mü olduğunu belirlemeye yönelik bir yöntem önermektedir. Önerilen yöntem ile görüntüler üzerinde Ayrık Kosinüs dönüşü uygulanmasının gerçek/sahte yüz ayrımının tespiti üzerinde önemli etkisi olduğunu göstermektedir. Yapılan çalışmada VGG-19 sınıflandırma mimarisi ve Ayrık Kosinüs dönüşümü ile %70 doğruluk oranı başarıyla elde edilmiştir.

Gelecek çalışmalarda kullanılan veri setindeki görüntüler ve kullanılan mimari üzerinde değişikliklerle elde edilen doğruluk başarı oranının iyileştirilmesi hedeflenmektedir.

ÇIKAR ÇATIŞMASI

Yazarlar, bilinen herhangi bir çıkar çatışması veya herhangi bir kurum/kuruluş ya da kişi ile ortak çıkar bulunmadığını onaylamaktadırlar.

YAZAR KATKISI

Abdullah Şener çalışmanın kavramsal ve/veya tasarım süreçlerinin belirlenmesi, makale taslağının oluşturulması, son onay ve tam sorumluluk, Burhan Ergen çalışmanın kavramsal ve/veya tasarım süreçlerinin yönetimi, fikirsel içeriğin eleştirel incelemesi, son onay ve tam sorumluluk.

KAYNAKLAR

1. Adhinata, F., & Junaidi, A. (2022). Gender Classification on Video Using FaceNet Algorithm and Supervised Machine Learning. *International Journal of Computing and Digital Systems*, 11(1), 199-208.
2. Akben, S. B., & Alkan, A. (2015). Density-based feature extraction to improve the classification performance in the datasets having low correlation between attributes. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 30(4), 597-603.
3. Akbulut, Y., Şengür, A., & Ekici, S. (2017). Gender recognition from face images with deep learning. In *2017 International artificial intelligence and data processing symposium (IDAP)* (pp. 1-4).
4. Atalar, M. (2008). *İmge Dizilerindeki Artıkların İşlenmesi*. Gazi Üniversitesi Fen Bilimleri Enstitüsü Y. Lisans Tezi.
5. Atasoy, N. A., & Tabak, D. (2018). Destek Vektör Makineleri Kullanarak Yüz Tanıma Uygulaması Geliştirilmesi. *Engineering Sciences*, 13(2), 119-127.
6. Bengio, Y., & LeCun, Y. (2007). Scaling learning algorithms towards AI. *Large-scale kernel machines*, 34(5), 1-41.
7. C.I. a. P.Lab. (2019). *Real and Fake Face Detection* (ed.). Available: <https://www.kaggle.com/ciplab/real-and-fake-facedetection>
8. Campbell, J. B., & Wynne, R. H. (2011). *Introduction to remote sensing*. Guilford Press.
9. Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1251-1258).
10. Cooley, J. W., & Tukey, J. W. (1965). An algorithm for the machine calculation of complex Fourier series. *Mathematics of computation*, 19(90), 297-301.
11. Çelik, G., & Talu, M. F. (2019). Çekişmeli üretken ağ modellerinin görüntü üretme performanslarının incelenmesi. *Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22(1), 181-192.
12. Do, N. T., Na, I. S., & Kim, S. H. (2018). Forensics face detection from GANs using convolutional neural network. *ISITC, 2018*, 376-379.
13. François-Lavet, V., Henderson, P., Islam, R., Bellemare, M. G., & Pineau, J. (2018). An introduction to deep reinforcement learning. *Foundations and Trends® in Machine Learning*, 11(3-4), 219-354.
14. Ganguly, S., Ganguly, A., Mohiuddin, S., Malakar, S., & Sarkar, R. (2022). ViXNet: Vision Transformer with Xception Network for deepfakes based video and image forgery detection. *Expert Systems with Applications*, 210, 118423.
15. Gao, J. (2009). *Digital analysis of remotely sensed imagery*. McGraw-Hill Education.
16. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., & Bengio, Y. (2014). Advances in neural information processing systems. *Curran Associates, Inc*, 27, 2672-2680.
17. Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., ... & Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern recognition*, 77, 354-377.

18. Hanbay, K. (2020). Hyperspectral image classification using convolutional neural network and two-dimensional complex Gabor transform. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35(1), 443-456.
19. Hanbay, K., Talu, M. F., & Özgüven, Ö. F. (2017). Fourier Dönüşümü Kullanılarak Gerçek Zamanlı Kumaş Hatası Tespiti. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 32(1).
20. Karhan, Z., & Ergen, B. (2013). Classification of face images using discrete cosine transform. In *2013 21st Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4).
21. Kim, D., Choi, S., & Kwak, S. (2018). Deep learning based fake face detection. *Journal of the Korea Industrial Information Systems Research*, 23(5), 9-17.
22. Kurt F., (2018). Makalenin başlığı. *Sinir Ağlarında Hiper Parametrelerin Etkisinin İncelenmesi [yüksek lisans tezi]*. Ankara:Hacettepe Üniversitesi.
23. Liu, X., Deng, Z., & Yang, Y. (2019). Recent progress in semantic image segmentation. *Artificial Intelligence Review*, 52(2), 1089-1106.
24. Liu, Z., Qi, X., & Torr, P. H. (2020). Global texture enhancement for fake face detection in the wild. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 8060-8069).
25. M. Lin, Q. Chen, and S. Yan, (2014).“Network in network,” 2nd Int. Conf. Learn. Represent. ICLR 2014 - Conf. Track Proc.
26. Mateen, M., Wen, J., Song, S., & Huang, Z. (2018). Fundus image classification using VGG-19 architecture with PCA and SVD. *Symmetry*, 11(1), 1.
27. McCloskey, S., & Albright, M. (2019). Detecting GAN-generated imagery using saturation cues. In *2019 IEEE international conference on image processing (ICIP)* (pp. 4584-4588).
28. Min, S., Lee, B., & Yoon, S. (2017). Deep learning in bioinformatics. *Briefings in bioinformatics*, 18(5), 851-869.
29. Mittal, H., Saraswat, M., Bansal, J. C., & Nagar, A. (2020). Fake-face image classification using improved quantum-inspired evolutionary-based feature selection method. In *2020 IEEE Symposium Series on Computational Intelligence (SSCI)* (pp. 989-995).
30. Mostafiz, R., Rahman, M. M., Islam, A. K., & Belkasim, S. (2020). Focal liver lesion detection in ultrasound image using deep feature fusions and super resolution. *Machine Learning and Knowledge Extraction*, 2(3), 10.
31. Niepert M. Ahmed M. Kutzkov K., (2014). Learning convolutional neural networks for graphs. In *International conference on machine learning*, . Germany:2016. p. 2014-2023.
32. Öztürk, E., & Kurnaz, Ç. (2020). Görünüm Tabanlı Yüz Tanıma Yöntemleri Kullanılarak Cinsiyet Belirleme. *Avrupa Bilim ve Teknoloji Dergisi*, 111-120.
33. Söylemez, Ö. F., & Ergen, B. (2020). Farklı Evrimsel Sinir Ağı Mimarilerinin Yüz İfade Analizi Alanındaki Başarılarının İncelenmesi. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 11(1), 123-133.
34. Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2818-2826).

35. Tao, X., & Pan, D. (2022). Face Recognition based on Scale Invariant Feature Transform and Fuzzy Reasoning. *Internet Technology Letters*, e346.
36. Toğaçar, M., Ergen, B., & Özyurt, F. (2020). Evrişimsel Sinir Ağı Modellerinde Özellik Seçim Yöntemlerini Kullanarak Çiçek Görüntülerinin Sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 32(1), 47-56.
37. Torun, T. K., & Marmarali, A. (2011). Online fault detection system for circular knitting machines. *Textile and Apparel*, 21(2), 164-170.
38. Wu, X., Xu, K., & Hall, P. (2017). A survey of image synthesis and editing with generative adversarial networks. *Tsinghua Science and Technology*, 22(6), 660-674.