



EVRIŞİMSEL SİNİR AĞLARI KULLANILARAK YÜZ MASKESİNİN TESPİT EDİLMESİ

Fatih Ahmet ŞENEL^{1*}

¹Süleyman Demirel Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 32260, Isparta, Türkiye

Özet: Bu çalışmada, hava yoluyla salgın hastalıkların yayıldığı pandemi dönemlerinde, yüz maskesi takan ve takmayan insanların otomatik olarak tespit edildiği bir evrişimsel sinir ağı geliştirilmiştir. Tüm dünyayı etkileyen büyük bir salgında, tek bir kişinin bile dikkatsiz davranışları öncelikle kendi yakın çevresinden başlamak üzere yaşadığı tüm ülkeyi hatta tüm dünyayı tehlikeye atabilme potansiyeline sahiptir. Bu nedenle basit gibi görülen bir yüz maskesinin, salgın boyunca kullanımı küçümsenmemelidir. Gerekli tüm tedbirlerin üst düzeyde alınması bir zorunluluktur. Her ülkenin kendi kolluk kuvvetleri tarafından gerekli denetimler gerçekleştirilmektedir. Ancak insan sayısının kolluk kuvvetlerinin denetleyebileceğinden çok daha fazla olması nedeniyle teknolojik gelişmelerden faydalanılmak zorunda kalınmaktadır. Geliştirilen bu sistemle birlikte, yüz maskesi denetiminin insan gücü yerine yapay zekâ kullanan sistemler tarafından yapılması amaçlanmıştır. Bu amaçla, ilk olarak gerçek insan yüzü fotoğraflarından oluşan veri seti oluşturulmuştur. Oluşturulan veri setinde maskeli ve maskesiz olmak üzere toplamda 418 adet resim bulunmaktadır. Resimler seçilirken farklı renk ve şekillerde maskelerin veri setinde yer alması sağlanmıştır. Doğrudan resim girdisi ile çalışan ve sınıflandırma işlemlerinde kullanılan evrişimsel sinir ağları ile sınıflandırma işlemi gerçekleştirilmiştir. İkili sınıflandırma olarak ele alınan bu problemde, evrişimsel sinir ağı mimarisinin en iyi sonucu vermesi için hiper parametre ayarlaması yapılmıştır. Modelin optimum parametreleri ayarlanarak sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma işlemi sonucunda %95'lik bir doğruluk yüzdesi elde edilmiştir. Elde edilen bu başarı yüzdesi, evrişimsel sinir ağlarının yüzde bulunan maskenin tespit edilmesinde başarılı bir şekilde kullanılabileceğini göstermiştir.

Anahtar kelimeler: Covid-19, Derin öğrenme, Maske, Pandemi, Yapay zeka


Detecting Face Mask Using Convolution Neural Network

Abstract: In this study, a convolutional neural network was developed to detect people who wear and do not wear face masks during periods of epidemics spreading with airborne. In a major pandemic that affects the whole world, the careless behavior of a single person has the potential to endanger the entire country, even the whole world, starting from his immediate environment. For this reason, using a simple face mask during the pandemic should not be underestimated. It is a must to take all necessary precautions at the highest level. Necessary audits are carried out by each country's own law enforcement officers. However, because the number of people is much more than the law enforcement officers can control, technological developments have to be utilized. With this developed system, it is aimed to perform face mask control by artificial intelligence systems instead of manpower. For this purpose, the data set consisting of real human face photographs was generated firstly. In the data set generated, there are 418 face pictures in total, with a mask, and without a mask. While selecting the pictures, masks with different colors and shapes are included in the data set. The classification process was carried out with the convolutional neural networks working with direct raw image input and it is often used in classification processes. In this problem, which is considered as binary classification, hyper parameter adjustment has been made to give the best result of the convolutional neural network architecture. The classification process was carried out by adjusting the optimum parameters of the model. As a result of the classification process, an accuracy rate of 95% was obtained. This percentage of success obtained showed that the convolutional neural networks can be used successfully in detecting the mask on the face.

Keywords: Covid-19, Deep learning, Mask, Pandemic, Artificial intelligence

*Sorumlu yazar (Corresponding author): Süleyman Demirel Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 32260, Isparta, Türkiye

E mail: fatihsenel@sdu.edu.tr (F.A. ŞENEL)

Fatih Ahmet ŞENEL  <https://orcid.org/0000-0003-1918-7277>

Gönderi: 30 Nisan 2021

Kabul: 03 Haziran 2021

Yayınlanma: 01 Ekim 2021

Received: April 30, 2021

Accepted: June 03, 2021

Published: October 01, 2021

Cite as: Şenel FA. 2021. Detecting face mask using convolution neural network. BSJ Eng Sci, 4(4): 160-167.

1. Giriş

Cerrahi maske, sağlık çalışanlarının cerrahi müdahaleler sırasında kullandıkları maskelerdir. Solunum yoluyla hastalıkların bulaşmasının önüne geçmek için kullanılan bir tedbir yöntemidir. Cerrahi maske kullanan kişiler kendilerinde bulunan bir hastalığın yayılması riskini azalttıkları gibi farklı bir kişiden de hastalıkları alma risklerini azalmaktadırlar (Til, 2020). Her ne kadar

cerrahi maskeleri, isminden anlaşılacağı üzere sadece sağlık çalışanlarının takabileceği anlaşılrsa da farklı iş dallarında çalışan insanlarında zaman zaman maske takma gereksinimleri olmaktadır. Tozlu bir iş yerinde çalışan insanlar, zehirli gazların ortaya çıktığı laboratuvarlarda çalışan insanlar vb. maske takan ama sağlık çalışanı olmayan kişilere örnek verilebilir (Ediz ve ark., 2001; Göksel ve Engür, 2016; Çavuşoğlu ve ark.,



2020). Tüm bu sayılanların haricinde dünyamızdaki farklı şartların gelişmesiyle birlikte tüm insanların maske takmasının zorunlu olması da gündeme gelebilmektedir. Örnek olarak, solunum yoluyla bulaşan bir salgın hastalık zamanında herkes maske takmak zorunda kalabilir. 2019 yılının sonunda Çin'de ortaya çıkan ve tüm dünyayı etkisi altına alan Covid-19 virüsü nedeniyle, neredeyse tüm ülkelerde pandemi ilan edilmiş ve salgın boyunca maske takmak zorunlu hale gelmiştir.

Tehlikeli ve hızla yayılan bir salgın hastalık karşısında ülke yönetimleri maske takmayı zorunlu tutabilmekte ve bu kurala uymayan insanlara cezai yaptırımlar uygulayabilmektedir. Tüm ülkelerde cezai yaptırımları uygulayan, denetleyen merciler kolluk kuvvetleridir. Salgın gibi bir durum zamanında denetimler kolluk kuvvetleri tarafından artırılmakta ve kurallara uymayan insanlara cezai işlemler uygulamaktadırlar. Evlerinin dışına çıkan insanların sayısı ile kolluk kuvvetlerinin sayısı kıyaslanınca, tüm insanları denetlemenin pek mümkün olmadığı anlaşılmaktadır. Bu durumda kolluk kuvvetleri insan yoğunluğunun fazla olduğu bölgelerde denetim yapmakta ve harici bölgelerde yeterince denetim yapma fırsatı bulamamaktadır. Kurallara uymayan insanların tespit edilmesi ve maskesiz çıkışların engellenebilmesi için günümüz teknolojilerinden faydalanılarak kolluk kuvvetlerinin yükleri azaltılabilmektedir. Öyle ki, kolluk kuvvetlerinin denetim yapmadığı alanlarda kameralar vasıtasıyla otomatik olarak maskesiz insanların tespit edilebilmesi imkânı bulunmaktadır. Günümüzde artık kameraların bulunmadığı neredeyse hiçbir sokak kalmamıştır. Her dükkânda, her apartmanda güvenlik amacıyla kamera sistemleri bulunmaktadır. Ülkemizde her cadde ve kavşakta MOBil Elektronik Sistem Entegrasyonu (MOBESE) kamera sistemleri bulunmaktadır. MOBESE sistemlerine entegre edilecek bir sistemle, maskesiz insanların tespit edilebilmesi zor bir problem değildir (Sevinç ve Karabatak, 2019; Yıldırım ve ark., 2019).

Literatür incelendiğinde, son yılların popüler konusu olan derin öğrenme ile ilgili olarak hemen hemen tüm disiplinlerde yapılmış çalışmalar bulunmaktadır. Yüz tanıma, plaka tanıma gibi problemler artık standart çözülebilen problemler halini almıştır. Sağlık sektörü incelendiğinde, hastalıkların teşhisinde derin öğrenmenin sıklıkla kullanıldığı görülmektedir. Özellikle radyolojik görüntüler üzerinden hastalık tespiti hızla artmaya devam etmektedir.

Fujima ve ark. (2020) yaptıkları çalışmada, radyolojik beyin görüntülerinden yola çıkarak, tehlikeli bir virüs olan papilloma virüsünü derin öğrenme yöntemi ile tespit etmeyi amaçlamışlardır. Toplamda 120 hastaya ait görüntüler kullanarak %83'lük bir başarı elde etmişlerdir. Sonuç olarak derin öğrenmenin papilloma virüsünün tespit edilmesinde yardımcı bir araç olarak kullanılabilirliğini göstermişlerdir. Dai ve ark. (2020) çalışmalarında, beyin kan damarları duvarlarında, patlayınca ölümcül risk oluşturan baloncuk şeklindeki (anevrizma) radyolojik bulguları derin öğrenme ile tespit

etmeyi amaçlamışlardır. Bilgisayarlı Tomografi (BT) görüntülerini kullanarak derin sinir ağlarını eğitmişlerdir. Veri setlerinde 311 adet hasta bulunmaktadır. BT görüntülerini, katman kalınlıkları 0,5mm olacak şekilde dilimler halinde işlemişlerdir. %96,7'lik bir başarı ile çalışmalarını tamamlamışlardır. Nayak ve ark. (2020) yaptıkları çalışmada, Manyetik Rezonans Görüntüleri kullanarak, beyindeki olası anormallikleri ve göğüs kanserinin tespiti işlemi derin öğrenme yöntemi ile tespit etmişlerdir. Beyin anormalliklerinin tespitinde iki farklı veri seti kullanmışlardır. %95 ve %96,67'lik sınıflandırma başarıları elde etmişlerdir. Göğüs kanserinin tespiti için kullandıkları veri setinde ise %94,79'luk bir sınıflandırma yüzdesi elde etmişlerdir. Bargshady ve ark. yaptıkları çalışmada hasta insanların yüz ifadelerinden yola çıkarak ağrı yoğunluğunu sınıflandırmayı amaçlamışlardır (Bargshady ve ark., 2020). UNBC-McMaster Shoulder Pain veri tabanından kullanacakları veri setini elde etmişlerdir. Kullandıkları Evrişimsel Sinir Ağları ile %98,4 eğitim, %90 test başarıları elde etmişlerdir.

Derin öğrenmenin kullanım alanları sadece sağlık sektörü ile kısıtlı değildir. Shahverdy ve ark. (2020) çalışmalarında, sürücü davranışlarının derin öğrenme ile sınıflandırılması problemini ele almışlardır. 5 farklı sınıf tanımlamışlar ve araç içine sabitlenmiş bir telefondan hareket sensörü, hız sensörlerinden verileri toplamışlardır. Bu verilere ek olarak araçlara OBD soketinden bağladıkları cihaz ile de motor RPM verisini, hız verisini ve aniden gazın kesilmesi verilerini toplamışlardır. Pencere tekniği ile verileri işleyerek derin sinir ağına eğitim için vermişlerdir. Farklı birçok derin sinir ağı modeli kullanmışlardır. En iyi test oranı %99,98 olacak şekilde bir başarı elde etmişlerdir. Dimitriou ve ark. (2020) çalışmalarında elektronik devre kartlarının onarım ve lehimleme aşamasında, fazla miktarda lehimin kullanılması ile oluşacak sorunları ortadan kaldırmak için derin öğrenme yöntemleri ile devre elemanının ve lehimlenecek yerin görüntülerini analiz eden ve kullanılması gereken lehim hacmini tahmin eden bir sistem geliştirmişlerdir. Fei ve ark. (2020) yaptıkları çalışmada yüz ifadelerinden yola çıkarak duygu analizi yapan bir derin sinir ağı geliştirmişlerdir. AlexNet mimarisini kullanarak sınıflandırma işlemini gerçekleştirmişlerdir. Kullandıkları veri setinden 7 farklı duyguya ait yüz resimleri bulunmaktadır. Geleneksel sınıflandırıcılar, AlexNet ve bunların kombinasyonlarını kullanarak farklı modeller elde etmişlerdir. Farklı veri setleri kullanarak geliştirdikleri modellerle en yüksek %97'lik bir başarı skoru elde etmişlerdir. Gündüz ve Cedimoğlu (2019) yaptıkları çalışmada derin öğrenme algoritmalarını kullanarak yüz resimlerinden cinsiyet tahmini işlemini gerçekleştirmişlerdir. Evrişimsel sinir ağlarının geliştirilmiş versiyonlarından olan AlexNet ve VGG16 mimarileri ile kendi geliştirdikleri modellerini karşılaştırmışlardır. Sonuç olarak AlexNet mimarisinden daha iyi çalışan ve sonuç üreten bir mimari

geliştirmişlerdir. Doğan ve Türkoğlu (2018) yaptıkları çalışmalarında 32 sınıftan olan bitkilere ait yaprak görüntülerinden yaprakların ait olduğu sınıfı derin öğrenme ile tespit etmeyi amaçlamışlardır. Literatürde yer etmiş AlexNet, VGG16, VGG19, ResNet50, GoogleNet gibi popüler öğrenme mimarilerini kullanarak problemlerini çözmüşlerdir. %99,72'lik en yüksek doğru sınıflandırma başarısı elde ederek, problemin çözümünü gerçekleştirmişlerdir.

Derin öğrenme ve evrimsel sinir ağları ile yapılan çalışma örneklerini daha da artırmak mümkündür. Bu çalışmada, cerrahi yüz maskesi takan ve takmayan insanların evrimsel sinir ağları ile tespit edilmesi işlemi gerçekleştirilmiştir. Gerçekleştirilen bu sistemle, kolluk kuvvetlerinin kontrolünde olan kamera sistemleri üzerinden, maske takmanın zorunlu olduğu zaman dilimlerinde, maskesiz dışarı çıkan insanların tespit edilmesi amaçlanmıştır. Böylece hem kolluk kuvvetlerinin iş yükleri azaltılmış olacak hem de salgın hastalıkların yayılması gibi riskli durumların olabildiğince minimuma indirilmesi gerçekleştirilmiş olacaktır.

İnsanların taktığı cerrahi yüz maskelerinin tespit edilmesi ile ilgili olarak yapılmış çalışmalar bulunmaktadır ve bu alanda çalışmalar yapılmaya devam etmektedir. Jiang ve ark. (2020) RetineFaceMask ismini verdikleri bir maske tespit etme algoritması geliştirmişlerdir ve büyük bir veri seti üzerinde çalışmışlardır. Transfer Learning yöntemi ile ön eğitilmiş derin öğrenme ağını kullanmışlardır. ResNet ve MobileNet ön eğitilmiş mimarilerini kullanarak maske tespiti işlemi gerçekleştirmişlerdir. Bu çalışmada farklı olarak ön eğitilmiş bir derin öğrenme mimarisi kullanılmamıştır. Kullanılan veri seti Jiang ve ark. (2020) tarafından kullanılan veri setinden daha küçük boyuttadır. Fakat kullandıkları veri setleri incelendiğinde, bu çalışmada kullanılan veri seti ile aynı kapsama sahiptir. Bu çalışmada veri setine dahil edilen tüm maske kombinasyonları Jiang ve ark. (2020) 'nın veri setinde de bulunmaktadır. Ayrıca bu çalışmada önce yüz tanıma sonra maske tespiti işlemi yapılmamış doğrudan maskenin tespiti gerçekleştirilmiştir.

2. Materyal ve Yöntem

Bu bölümde çalışmada kullanılan veri seti ve derin öğrenme mimarisi detaylı bir şekilde açıklanmıştır. Gerçekleştirilen çalışma da Python programlama dili 3.6 versiyonu ve Keras derin öğrenme kütüphanesi kullanılmıştır. Yapılan tüm eğitim ve test aşamaları Google Colab Tesla Grafik İşlemci Birimi üzerinde gerçekleştirilmiştir. Google'ın belirli bir kısıta kadar ücretsiz olarak sunduğu bu araç ile çalışma tamamlanmıştır.

2.1. Veri Setinin Oluşturulması

Bu çalışmada özellikle pandemi dönemleri gibi yüz maskelerinin takılmasının zorunlu olduğu durumlarda, otomatik olarak maske takan ve takmayan insanların tespit edilmesi evrimsel sinir ağları kullanılarak

gerçekleştirilmiştir. Veri seti oluşturulurken Google arama motorunun görsel arama özelliğinden yararlanılmıştır. Arama motorundan resimler elde edilirken gerekli telif haklarına dikkat edilmiş ve telif hakkı olan resimler çalışmaya dâhil edilmemiştir. Gerek Türkçe gerek İngilizce anahtar kelimeler kullanılarak hem cerrahi yüz maskesi takan insanların olduğu hem de maske takmayan insan yüzlerini içeren resimlerden veri seti oluşturulmuştur. Kullanılan anahtar kelimelerden bazıları; "Maske", "Mask", "Yüz maskesi", "Face mask", "Surgery mask", "Cerrahi maske" vb. gibidir.

Bu çalışmada, veri setinde 212 adet maskeli yüzleri içeren ve 206 adet maskesiz yüzleri içeren toplamda 418 adet resim kullanılmıştır. Veri seti oluşturulurken maskelerin farklı şekil ve renklerini içerecek şekilde resimlere yer verilmesine dikkat edilmiştir. Ayrıca kullanılan fotoğraflar sadece bir kişinin bulunduğu durumların haricinde birden fazla kişinin bulunduğu durumları da içermektedir. Fotoğrafta birden fazla kişi varsa hepsi maskeli veya maskesiz olan örneklerden seçilerek veri setine dahil edilmiştir. Aksi durumda aynı fotoğraf karesinde hem maskeli hem de maskesiz yüzlerin bulunduğu fotoğraflar doğal olarak sınıflandırmada hatalara yol açacaktır. Bu durumun üstesinden gelmek için, sınıflandırma işleminden önce fotoğrafta sadece bir insan olacak şekilde gerekli kırpılmaların yapılması gerekmektedir. Bu çalışmada kullanılan fotoğraflarda bir veya daha fazla insan yüzü olabilmektedir. Buna ek olarak fotoğraftaki tüm insanların maskeli veya maskesiz olma kısıtı bulunmaktadır. Şekil 1 ve Şekil 2'de veri setinde bulunan maskeli ve maskesiz örnek yüz resimleri verilmiştir. Ayrıca birden fazla kişinin olduğu örnek resimler de Şekil 3'te verilmiştir.



Şekil 1. Örnek maskeli yüz resimleri.



Şekil 2. Örnek maskesiz yüz resimleri.



Şekil 3. Birden fazla kişinin olduğu örnek resimler.

2.2. Veri Setinin Genişletilmesi

Evrimsel sinir ağlarının kullanıldığı çalışmalarda, kullanılan ağı öğrenme başarısının artırılması için

eğitim aşamasında girdi resimlerinin olabildiğince çeşitlendirilmesi gerekmektedir. Aksi halde eğitim verisini çok iyi öğrenen bir ağ mimarisi elde edilirken test verisi üzerinden istenen sonuçlar elde edilmeyebilmektedir. Bu nedenle eğitim aşamasında kullanılan veri seti üzerinde ölçekleme, döndürme, kaydırma, yansımaları alma ve burkma gibi özellikler kullanılarak veri setinin çeşitlendirilmesi gerçekleştirilmiştir. Eğitim işlemi boyunca Keras derin öğrenme kütüphanesinin ImageDataGenerator aracı kullanılarak eğitim verileri genişletilmiştir. Şekil 4'te veri seti genişletilirken elde edilen örnek resimler gösterilmiştir.




Şekil 4. Veri seti genişletme sonucunda elde edilen örnek çıktılar.

2.3. Evrişimsel Sinir Ağı

Bu çalışmada sekiz katmanlı bir evrişimsel sinir ağı mimarisi kullanılmıştır. Her iki evrişimsel katmanından sonra bir adet havuzlama katmanı eklenmiştir. Literatür incelendiğinde evrişimsel katmanlarından sonra havuzlama katmanının kullanılmasının eğitim aşamasını olumlu yönde etkilediği görülmektedir. Her bir evrişimsel katmandan sonra bir havuzlama katmanı kullanılabilir gibi her iki evrişimsel katmandan sonra bir adet havuzlama katmanının kullanılması da genel olarak kabul görmektedir (Chollet, 2018). Evrişimsel katmanlardan sonra düzleştirme işlemi gerçekleştirilmiştir. Düzleştirme işleminden sonra iki adet tam bağlı katman kullanılmış ve çıktı katmanına ulaşılmıştır. Tablo 1'de kullanılan mimari katmanları ve nöron sayıları verilmiştir. Ayrıca Şekil 5'te kullanılan mimari görsel olarak gösterilmiştir. Bu çalışmada ele alınan problemin çıktısı ikili problem sınıfında yer almaktadır (Chollet, 2018). Bu nedenle eğitim ve test veri setleri ikili (binary) sınıflandırılarak çıktı katmanında aktivasyon fonksiyonu olarak sigmoid seçilmiştir.

Tablo 1. Kullanılan evrişimsel sinir ağı mimarisi

Katman	Katman	Nöron Sayısı	Filtre Boyutu	Aktivasyon Fonksiyonu
1	Evrişimsel Katman	256	3x3	Relu
2	Evrişimsel Katman	256	3x3	Relu
	Maksimum Havuzlama		2x2	
3	Evrişimsel Katman	512	3x3	Relu
4	Evrişimsel Katman	512	3x3	Relu
	Maksimum Havuzlama		2x2	
5	Evrişimsel Katman	64	3x3	Relu
6	Evrişimsel Katman	64	3x3	Relu
	Maksimum Havuzlama		2x2	
	Düzleştirme İşlemi			
7	Tam bağlı katman	512		Relu
8	Tam bağlı katman	512		Relu
Çıktı	Tam bağlı katman	1		Sigmoid



Şekil 5. Kullanılan evrişimsel sinir ağı mimarisi.

Tablo 1'de verilen mimari hiper parametre optimizasyonu ile elde edilen ve ele alınan problemde en iyi sınıflandırma sonucunun alınabildiği derin öğrenme mimarisidir. Hiper parametre optimizasyonu yapılırken eğitim aşamasındaki iterasyon sayısı, ağırlık güncelleme işlemi yapması için işleme alacağı resim sayısını belirten batch büyüklüğü, girdi resminin çözünürlüğü ve son olarak öğrenme katsayısı parametreleri ele alınmıştır. Tablo 2'de hiper parametre için kullanılan değerler ve optimum değerler gösterilmiştir. Tablo 3'te ise, Tablo 1'de ifade edilen

katman sayısı ve nöron sayılarının farklı bazı değerleri için elde edilen doğruluk yüzdeleri verilmiştir. Eğitim işleminde kayıp fonksiyonu olarak Ortalama Karesel Hata (OKH) ve ağırlık güncellemeleri optimizasyonu için "Adam" yöntemi kullanılmıştır. OKH hesabı eşitlik 1'de gösterildiği şekilde hesaplanmaktadır.

$$OKH = \frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2 \quad (1)$$

Burada, y_i gerçek sınıf etiketini ifade ederken, \tilde{y}_i tahmin edilen sınıf etiketini temsil etmektedir.


Tablo 2. Hiper parametre ayarlanırken kullanılan değerler

Parametreler	Değerler	Optimum Değer
İterasyon Sayısı	30, 50, 150, 250	50
Batch Büyüklüğü	1, 2, 4, 8, 16, 32	16
Resim Çözünürlüğü	64x64x3, 128x128x3, 256x256x3	64x64x3
Öğrenme Katsayısı	1e-01, 1e-02, 1e-03, 1e-04, 1e-05, 1e-06	1,00e-05


Tablo 3. Örnek farklı katman ve nöron sayıları için elde edilen doğruluk yüzdeleri

Katmanlardaki Nöron Sayıları	Katman Sayısı	Doğruluk Yüzdesi (%)
256, 256, 512, 512, 64, 64, 512, 512	8	95
256, 256, 512, 512, 256, 256, 256, 256	8	93
32, 32, 128, 128, 64, 64, 32, 32	8	88
64, 64, 256, 256, 256, 256	6	85
512, 512, 128, 128	4	84


Şekil 6, 7 ve 8'de sırasıyla girdi resminin çözünürlüğünün farklı değerleri, öğrenme katsayısı ve batch büyüklüğü ve için elde edilen test sonuçları verilmiştir



Şekil 6. Girdi resmi çözünürlüğünün sınıflandırma başarısına olan etkisi.



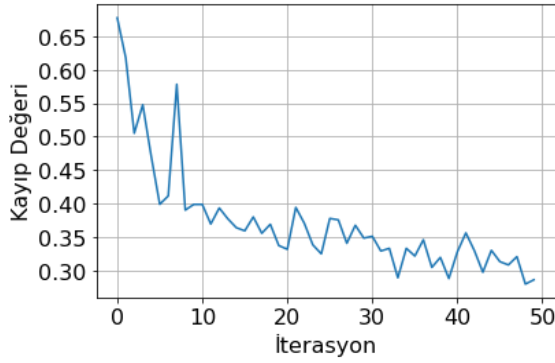
Şekil 7. Öğrenme katsayısının sınıflandırma başarısına olan etkisi.




Şekil 8. Batch büyüklüğünün sınıflandırma başarısına olan etkisi.

3. Bulgular ve Tartışma

Bu çalışmada özellikle pandemi dönemlerinde takılması zorunlu tutulan yüz maskelerinin evrimsel sinir ağları kullanılarak tespit edilmesi amaçlanmıştır. Bu işlem için Bölüm 2.1'de anlatılan toplamda 418 adet görüntü kullanılmıştır. Bu görüntülerden 63 tane maskeli, 61 tane maskesiz olmak üzere toplam 124 tanesi test işlemi için geriye kalanlar ise eğitim işlemi için ayrılmıştır. Böylece Eğitim-Test oranı %70-%30 olarak seçilmiştir. Eğitim işlemi boyunca Keras derin öğrenme kütüphanesinin ImageDataGenerator aracı kullanılarak eğitim verileri genişletilmiştir. Şekil 9'da eğitim işlemi boyunca kayıp fonksiyonunun azalma grafiği ve Şekil 10'da ise sınıflandırma işleminin doğruluk oranının başarı grafiği verilmiştir. Yapılan eğitim işlemi sonucunda test veri seti ile 0.95'lik bir başarı oranı elde edilmiştir.



Şekil 9. Kayıp fonksiyonunun eğitim boyunca değişimi.



Şekil 10. Doğruluk oranının eğitim boyunca değişimi.

Eşitlik 2, 3, 4 ve 5'te bu çalışmada evrişimsel sinir ağı modelinin başarısının ölçüldüğü metrikler verilmiştir. Tablo 4'te ise denklemlerde kullanılan kısaltmaların açıklamasına yer verilmiştir.

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (2)$$

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (3)$$


$$F_1 - \text{skoru} = 2 * \frac{\text{Duyarlılık} * \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (4)$$

$$\text{Doğruluk Oranı} = \frac{DP + DN}{DP + DN + YP + YN} \quad (5)$$

Tablo 4. Denklemlerde kullanılan kısaltmaların açıklaması

Gerçek	Tahmin	Kısaltma
Pozitif	Pozitif	DP (Doğru Pozitif)
Negatif	Pozitif	YP (Yanlış Pozitif)
Pozitif	Negatif	YN (Yanlış Negatif)
Negatif	Negatif	DN (Doğru Negatif)

Tablo 5'te eğitilen evrişimsel sinir ağının test işlemi sonucunda elde edilen sonuçlar gösterilmiştir. Şekil 11'de ise hata matrisi gösterilmiştir.




Şekil 11. Sınıflandırma sonucu hata matrisi.

Tablo 5. Evrişimsel sinir ağı modelinin test sonuçları

Sınıf	Maskeli	Maskesiz
Duyarlılık	0,92	0,98
Kesinlik	0,98	0,92
F ₁ - skor	0,95	0,95
Doğruluk Oranı	0,92	0,98

Tablo 5 incelendiğinde maskesiz yüzlerin sınıflandırılmasında modelin daha başarılı olduğu görülmektedir. Maskesiz yüzlerin açık net olduğu için daha yüksek bir doğruluk yüzdesi elde edilebileceği öngörülmektedir. Maskeli yüzlerin sınıflandırılmasında ise daha düşük bir yüzde ile başarı elde edilmiştir. Çünkü kullanılan maskelerin renkleri ile ten renkleri arasında yeterince farklılık yoksa sistem yanlış sınıflandırmaktadır. Şekil 12'de yanlış sınıflandırma işlemine ait örnek fotoğraflar verilmiştir. Bu durumlar dikkate alındığında sınıflandırma işleminde olası hatalar öngörülebilmektedir. Sonuç olarak, sınıflandırma başarısı, ortalama 0.95'lik doğruluk oranı yani %95'lik bir doğruluk yüzdesi ile gerçekleştirilmiştir.



Şekil 12. Yanlış sınıflandırılan örnekler (a) Maskeli iken maskesiz olarak sınıflandırılan örnek (b) Maskesiz iken maskeli olarak sınıflandırılan örnek.

Şekil 12 incelendiğinde, maskeli olup da maskesiz olarak sınıflandırılan örnek fotoğrafta (Şekil 12.a), maske renginin ten rengine yakın olması nedeniyle, sistem yeterince farkı anlayamamış ve sınıflandırma işleminde hata yapmıştır. Maske renginin ten renginden belirgin bir şekilde ayrışması doğruluk yüzdesini artırmaktadır. Şekil 12.b'de ise maskesiz bir yüz yanlışlıkla maskeli olarak

sınıflandırılmıştır. Fotoğrafa dikkat edilirse siyah beyaz olması nedeniyle yanlış sınıflandırma işleminin gerçekleştiği anlaşılmaktadır. Şekil 12.a'da belirttiği gibi, ten rengi ile maske rengi arasında belirgin bir fark oluşmadığı durumda sistem yanlış sınıflandırmalar yapabilmektedir. Gerçek hayatta siyah beyaz fotoğraflar olmayacağı ve renkli fotoğraflarla çalışılacağı için özellikle maskesiz yüzlerin %100 doğrulukla tespit edilebileceği anlaşılmıştır. Çünkü veri setine, öğrenmenin daha iyi gerçekleşebilmesi için siyah beyaz fotoğraf eklenmiş ve yapılan test işleminde siyah beyaz fotoğraf haricindeki tüm renkli maskesiz yüzlerin doğru sınıflandırıldığı görülmüştür. Deneysel sonuçlardan da anlaşıldığı üzere maskesiz yüzlerin sınıflandırılması işleminde çok daha başarılı sonuçlar elde edilmiştir. Maskeli yüz fotoğraflarında ise, maske rengi ile ten rengi ayrımı yeterince belirgin değilse hatalar meydana gelmektedir. Bu açıdan incelendiğinde, sistemin maskeli yüzleri sınıflandırma becerisinin iyileştirilmeye ihtiyacı olduğu anlaşılmaktadır. Çünkü maske ile yüz ten rengi yakın tonlarda ise, geliştirilen model görüntüdeki sınır geçişlerini ayırt etmekte zorlanmaktadır. Dolayısıyla maske tespitinde zorlanmaktadır. Bu duruma bir çözüm önerisi olarak, geliştirilen modelin eğitim aşamasında, yüz ten rengine yakın örneklerin ağı verilmesi ile eğitim işleminin pekiştirilmesi çözümü sunulabilir. Böylece geliştirilen model, çok daha iyi öğrenme gerçekleştirecek ve ağız bölgesine odaklanması gerektiğini öğrenecektir. Ağız bölgesi net olarak anlaşılamayan yüzlerde maske olma ihtimalinin yüksek olduğunu öğrenecektir. Yukarıdaki başarı sonuçlarına ek olarak, bu çalışmada kullanılan fotoğrafların bazı kısıt ve serbestlikleri bulunmaktadır. Geliştirilen sistem, bir fotoğrafta birden fazla insan olsa da başarılı bir şekilde çalışmaktadır. Birden fazla insan olduğu durumlarda, tüm insanların maskeli veya tümünün maskesiz olması zorunluluğu bulunmaktadır. Bu durum, bu çalışmada bir kısıt olarak karşımıza çıkmaktadır. Eğer bir fotoğrafta hem maskeli hem de maskesiz yüzler bulunursa, bu sistem doğru çalışmayacaktır. Bu sorunu çözmek için, kullanılacak olan fotoğraflar ilk olarak bir ön işlemde geçerek, her fotoğraftaki insan sayısı tek olacak şekilde ayarlanmalıdır. Bu çalışmanın konusu maske tanıma olduğu için, böyle bir ön işlem ile çalışılmamıştır. Kullanılan tüm fotoğraflardaki insanların tamamının maskeli veya tamamının maskesiz olduğu durum dikkate alınarak bu sistem geliştirilmiştir.

4. Sonuç

Yapılan bu çalışmada, pandemi dönemi gibi bulaşıcı hastalıkların olduğu dönemlerde, yüz maskesi takmanın zorunlu olduğu ve bu zorunluluğu kontrol edebilecek otomatik bir maske tespit sistemi geliştirilmiştir. Geliştirilen bu sistem, var olan yüz tanıma sistemlerine entegre olarak çalışabilmesi amaçlanmıştır. Bu nedenle, fotoğraflarda, insan yüzlerinin bulunduğu bölgelerin taranması gibi işlemler bu çalışmaya dâhil edilmemiştir. Böylece denetimlerin bütünüyle insan eliyle değil

kameralar vasıtasıyla teknolojinin imkânlarından yararlanılabilmesi sağlanmıştır. Günümüz yapay zekâ teknolojilerinin birçok alanda kullanılabilir olmasıyla birlikte yüz maskesi tespiti işleminde de kullanılabilir olduğu bu çalışma ile gösterilmiştir. Bu çalışmanın devamı olarak kalabalık ortamlara ait insan görüntülerinin kullanıldığı ve hem maske kullanım durumu hem de sosyal mesafelerin korunup korunmadığının tespitinin evrimsel sinir ağları kullanılarak gerçekleştirilmesi hedeflenmektedir. Pandemi dönemlerinde maskesiz insanların tek başlarına gezmesi yayılım riskini daha aza indirgemektedir. Ancak maskesiz olup hem de diğer insanlara yakın mesafede bulunan insanlar büyük riskler taşımaktadır. Bu nedenle bir sonraki çalışmada maske kullanım durumu ile sosyal mesafelerin korunup korunmadığı durumunun da otomatik bir sistem tarafından tespit edilmesi planlanmaktadır.

Katkı Oranı Beyanı

Tüm işlemler eserin tek yazarı tarafından yapılmıştır.

Çatışma Beyanı

Yazar bu çalışmada hiçbir çıkar ilişkisi olmadığını beyan etmektedirler.

Kaynaklar

- Bargshady G, Zhou X, Deo RC, Soar J, Whittaker F, Wang H. 2020. Enhanced deep learning algorithm development to detect pain intensity from facial expression images. *Expert Syst App*, 149: 113305. DOI: 10.1016/j.eswa.2020.113305.
- Chollet F. 2018. *Deep Learning with Python*. Simon & Schuster, NY, USA, 1th ed., pp: 384.
- Çavuşoğlu İ, Hatun EKTİ, Güvendi A, Gökcan A, Demir H. 2020. Bir yeraltı altın madeninde kişisel koruyucu donanımlar için risk değerlendirilmesi. *Yerbilimleri*, 41(1): 100-113.
- Dai X, Huang L, Qian Y, Xia S, Chong W, Liu J, Di Leva A, Hou X, Ou C. 2020. Deep learning for automated cerebral aneurysm detection on computed tomography images. *Int J Comp Assis Radiol and Surg*, 15(4): 715-723.
- Dimitriou N, Leontaris L, Vafeiadis T, Ioannidis DI, Wotherspoon T, Tinker G, Tzovaras D. 2020. Fault diagnosis in microelectronics attachment via deep learning analysis of 3-D laser scans. *IEEE Trans on Indust Electr*, 67(7): 5748-5757.
- Doğan F, Türkoğlu İ. 2018. Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması. *Sakarya Univer J Comp and Inf Sci*, 1(1): 10-21.
- Ediz İG, Yuvka Ş, Beyhan S, Çolpan R. 2001. GLİ Tunçbilek-Ömerler bölgesinde mekanize üretimde toz sorunu. *Türkiye 17 Uluslararası Madencilik Kongresi ve Sergisi-TUMAKS*, 19-22 Haziran, Ankara, Türkiye, pp. 169-176.
- Fei Z, Yang E, Li DDU, Butler S, Ijomah W, Li X, Zhou H. 2020. Deep convolution network based emotion analysis towards mental health care. *Neurocomputing*, 388: 212-227. DOI: 10.1016/j.neucom.2020.01.034.
- Fujima N, Andreu-Arasa VC, Meibom SK, Mercier GA, Truong MT, Sakai O. 2020. Prediction of the human papillomavirus status in patients with oropharyngeal squamous cell carcinoma by FDG-PET imaging dataset using deep learning analysis: A hypothesis-generating study. *European J Radiol*, 126: 108936. DOI: 10.1016/j.ejrad.2020.108936.

- Göksel ULAY, Engür MO. 2016. Bir mobilya işletmesinde iş güvenliği uygulamaları ve bunların işletmeye maliyeti. Selçuk-Teknik Derg, 2016: 1260-1274.
- Gündüz G, Cedimoğlu İH. 2019. Derin öğrenme algoritmalarını kullanarak görüntüden cinsiyet tahmini. Sakarya Univ J Comp and Inf Sci, 2(1): 9-17.
- Jiang M, Fan X, Yan H. 2020. Retinamask: A face mask detector. URL: <https://arxiv.org/abs/2005.03950> (erişim tarihi: 05 Mart 2021)
- Nayak DR, Dash R, Majhi B, Pachori RB, Zhang Y. 2020. A deep stacked random vector functional link network autoencoder for diagnosis of brain abnormalities and breast cancer. Biomedical Signal Proces and Cont, 58: 101860. DOI: 10.1016/j.bspc.2020.101860.
- Sevinç AY, Karabatak M. 2019. A Target tracking application on mobese videos. In 2019 7th International Symposium on Digital Forensics and Security (ISDFS) (pp. 1-5). IEEE.
- Shahverdy M, Fathy M, Berangi R, Sabokrou M. 2020. Driver behavior detection and classification using deep convolutional neural networks. Expert Sys with App, 149: 113240. DOI: 10.1016/j.eswa.2020.113240.
- Til UDA. 2020. Yeni Koronavirüs hastalığı Hakkında bilinmesi gerekenler. Ayrıntı Derg, 8(85): 53-57.
- Yıldırım ZB, Özdemir BE, Eren E. 2019. Trafikteki araç sayımlarının farklı görüntü işleme teknikleri kullanılarak karşılaştırılması. In: Proceedings of the 2nd Int Congress on Engineering and Architecture, 22-24 April 2019, Marmaris, Turkey, pp. 242-248.