

## (Araştırma Makalesi)

Derin Öğrenme ile *Aspergillus* Mantar Türlerinin SınıflandırılmasıSimara SAFARLI<sup>1</sup>, Uğur GÜREL<sup>2</sup>, Yasemin ÖZ<sup>3</sup><sup>1</sup>Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, 26040, Eskişehir, ORCID No : <http://orcid.org/0000-0003-3447-9593><sup>2</sup>Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, 26040, Eskişehir, ORCID No : <http://orcid.org/0000-0001-9088-1515><sup>3</sup>Eskişehir Osmangazi Üniversitesi, Tıp Fakültesi, Temel Tıp Bilimleri Bölümü, 26040, Eskişehir, ORCID No : <http://orcid.org/0000-0003-2243-7644>**Anahtar Kelimeler:**Aspergillus,  
Sınıflandırma,  
Derin Öğrenme,  
Evrişimsel Sinir Ağı

**Özet:** Küf mantarları doğada yaygın olarak bulunan ve genellikle saprofit, mantarlardır. Küf mantarları, özellikle bağışıklığı yetersiz olan hastalarda fırsatçı invaziv enfeksiyonlara neden olarak ölüm oranlarının artmasına neden olabilirler. Küf mantarlarının neden olduğu fırsatçı enfeksiyonların en yaygın etkenleri *Aspergillus* türleri, sıklıkla da *A. fumigatus* ve takiben *A. flavus*'tur. Çalışmamızda, Derin Öğrenme algoritmalarından biri olan Evrişimsel Sinir Ağı (ESA) modeli oluşturulmuş ve küf mantarlarından *A. flavus* ve *A. fumigatus* türlerinin mikroskopik görüntüleri kullanılarak tür tayini yapılmıştır. Çalışmada, her bir tür için 525 adet olmakla, toplamda 1050 görüntüden oluşan veri seti kullanılmıştır. Bu görüntüler gri tona dönüştürülerek üzerinde çalışma yapılmıştır. Çalışmamızda, deneyler 73 kez tekrar edilerek sınıflandırma sonucu %97.62 oranında eğitim doğruluğu ve %91.90 test doğruluğu olarak elde edilmiştir.

## (Research Article)

Classification of *Aspergillus* Fungi Species with Deep Learning**Keywords:**Aspergillus,  
Classification,  
Deep Learning,  
Convolutional Neural Network

**Abstract:** The mold fungi are commonly found in nature and are usually saprophyte fungi. Mold fungi can lead to an increase in mortality rates by causing opportunistic invasive infections, especially in immunocompromised patients. The most common causes of opportunistic infections caused by mold fungi are species of *Aspergillus*, frequently *A. fumigatus*, and subsequently *A. flavus*. In our study, the Convolutional Neural Network (CNN) model, which is one of the Deep Learning algorithms, was created and species determination was made using microscopic images of the mold fungi *A. flavus* and *A. fumigatus* species. In the study, a dataset consisting of a total of 1050 images, with 525 images for each species, was used. These images were converted to grayscale and worked on. In our study, experiments were repeated 73 times, resulting in a training accuracy of 97.62% and a test accuracy of 91.90% in classification.

**1. GİRİŞ**

*Aspergillus* türleri doğada yaygın olarak bulunan küf mantarlarıdır. Doğal habitatları gübre yığınları veya çürüyen gıdaların bulunduğu organik materyalden zengin ortamlardır. Bununla birlikte, insanlarda basit yüzeysel enfeksiyonların yanı sıra, özellikle bağışıklık defekti olan hastalarda ciddi fırsatçı enfeksiyonlara neden olabilirler [1]. Küf mantarlarının neden olduğu fırsatçı enfeksiyonların en sık etkenleri *Aspergillus* türleridir.

Enfeksiyon çevresel kaynaklardan, sıklıkla solunum yoluyla bulaşır ve tüm *Aspergillus* enfeksiyonlarının en sık etkeni *A. fumigatus*'tur. *A. flavus*, genellikle ikinci sırada yer almakla birlikte, *Aspergillus* nedenli yuvarlak doku enfeksiyonlarından daha sıklıkla izole edilen türdür [2]. Ayrıca *A. flavus*'un kontamine ettiği gıdalarda sekonder metabolit olarak aflatoksin ürettiği ve aflatoksinin potent bir karsinojenik madde (karaciğer kanserine neden olur) olduğu bilinmektedir [3]. Farklı *Aspergillus* türlerinin antifungal duyarlılık özellikleri ve dolayısıyla tedavileri farklılık gösterdiğinden, etkenin tür

düzeyinde tanımlanması büyük önem taşımaktadır. Ancak küf mantarlarında tanımlama büyük oranda mantarın mikroskopik ve makroskopik morfolojik özelliklerinin değerlendirilmesine dayandığından, değerlendiricinin bilgi ve tecrübesi son derece önemlidir ve genellikle tanımlama, birçok merkezde genus düzeyinde sınırlı kalmaktadır. Bu nedenle, küf mantarlarının doğru ve güvenilir tanımlanmasını yapabilecek sistemlerin geliştirilmesine yönelik çalışmalar ilgi çekmektedir.

Bu çalışmada, insan sağlığı için oldukça tehlikeli olan *Aspergillus* türlerinden *A.flavus* ve *A.fumigatus* mantarlarının tanımlanabilmesi için derin öğrenme algoritmalarından biri olan Evrişimsel Sinir Ağı (ESA) modeli oluşturularak tür tayini yapılmıştır.

Literatüre baktığımızda birçok farklı çalışmanın olduğunu görmekteyiz. Billones ve arkadaşları, 9 çeşit *Aspergillus* mantar türünün mikroskopik görüntüleri üzerinden ESA ile tanımlanmasını ve sınıflandırmasını yapmışlardır. Çalışmada iki aşamalı bir yöntem izlenmiştir. İkinci aşama sınıflandırma iyileştirme amaçlı yapılmıştır. Çalışmada 4545 görüntüden, 3600 eğitim, 900 doğrulama ve 45'i test için kullanılmak üzere ayrılmıştır. Çalışmada ilk aşamada sınıflandırma sonucu: Accuracy %87.50, Loss 0.4107, Val Accuracy %95.65, Val Loss 0.1211 olarak elde edilmiştir. İkinci aşamada ise iyileştirme yapılarak elde edilen sonuçlar: Accuracy %94.20, Loss 0.1459, Val Accuracy %94.31, Val Loss 0.1459 olmuştur [4].

Diğer bir çalışmada, Fan ve arkadaşları, mikroskopik mantar görüntüleri ve göğüs kanseri histolojisi veri setleri kullanarak ince taneli nesne tanımlanmasını ve sınıflandırılmasını yapmışlardır. Makalede kullanılan görüntüler Peking Union Hospital ile işbirliği ile elde edilmiştir. Beş *Aspergillus* türünün (*A.flavus*, *A.fumigatus*, *A.niger*, *A.nidulans* ve *A.terreus*) her birine ait 400 görüntüden oluşan 2000 klinik görüntü toplanmıştır. Mantar görüntülerinin sınıflandırılması sonucu diğer ince taneli nesne sınıflandırma algoritmaları ile karşılaştırılarda 0.943 doğruluk oranı göstererek en iyi sonuç elde edilmiştir. Göğüs kanseri histolojisi görüntülerinin sınıflandırılması, aynı veri seti ile yapılan 5 yöntemden 0.960 doğruluk oranı göstererek daha iyi sonucu göstermiştir [5].

Polap ve arkadaşları, mikroskopik görüntü tanımlanması üzerine çalışma yapmışlardır. Bu çalışmada, karışık bakteri görüntüleri içeren orjinal bir veri seti kullanılmıştır. Her bir görselde ise 4213 bakteri bulunmaktadır. Çalışmada, diğer mimariler ile karşılaştırılarda encoder-decoder mimarisinin çok iyi sonuçlar verdiği ve girdi görüntülerinde en az %2 ila %20 daha fazla tanınan bakteri sayısını elde ettiği sonucuna varılmıştır. Önerilen mimari ile %92 oranında doğruluk elde edilmiştir [6].

Mital ve arkadaşları çalışmalarında, 9 çeşit *Aspergillus* mantar türünün önceden eğitilmiş ESA ile sınıflandırılmasını yapmışlardır. Kullanılan veri seti toplamda 1152 görselden oluşmaktadır, bu görsellerden 785'i eğitim, 337'si ise doğrulama için kullanılmıştır.

Görüntülerin Image Batch Processor uygulaması ile yeniden boyutlandırılması yapılmıştır. %93.3333 oranında bir test doğruluk oranı elde edilmiştir. Önceden eğitilmiş modellerden MobileNetV2, DenseNet201 ve ResNet101 modelleri güvenilir bir değer elde etmiştir. Bu 3 model arasından MobileNetV2 en küçük boyuta ve eğitim süresine sahip olmuştur. MobileNetV2, 3 demeye aşamasından birinci denemede %100, ikinci denemede %94.96 ve üçüncü denemede %96.44 doğruluk oranı göstermiştir [7].

Gaikwad ve arkadaşları çalışmalarında, ESA kullanarak elma yapraklarında hastalığa neden olan mantarların tanımlanması ve sınıflandırmasını yapmışlardır. Çalışma için kullanılan veri seti (plant pathology dataset) elma kabuğu, elma pası, elma kara çürüğü ve sağlıklı yaprak olmak üzere 4 sınıftan ve toplamda 9164 görüntüden oluşmaktadır. Görüntülerin %60'ı eğitim, %40'ı ise test seti için kullanılmıştır. Sınıf bazında tanıma doğruluğu olarak elma kabuğu-%86.6, elma çürüğü-%86.8, elma pası-%47.6 ve sağlıklı yaprak-%95.7 doğruluk oranları vermiştir. Sınıflandırma sonucunda %88.9 oranında doğruluk elde edilmiştir [8].

Bir diğer çalışmada Gaikwad ve arkadaşları, mango ve şeker elması meyvelerinin yapraklarında bulunan *Colletotrichum gloeosporioides* ve *Cylindrocladium colhounii* mantarının görüntülerinin ESA ile tanımlanmasını yapmışlardır. Çalışmada derin öğrenme modellerinden AlexNet ve SqueezeNet kullanılmıştır. Görüntülerden %80'i eğitim, %20'i ise doğrulama için kullanılmıştır. Sonuç olarak AlexNet modeli daha yüksek doğruluk oranı göstermiştir. AlexNet modeli %93.8, SqueezeNet modeli %87.5 doğruluk oranı göstermiştir [9].

Çalık çalışmasında, gömülü sistemler üzerinde ESA modeli ile nesne sınıflandırması yapmıştır. Çalışmada, Cifar-10 isimli veri seti kullanılmıştır. Veri setindeki toplam 60000 görselden 50000'i eğitim ve doğrulama, 10000 tanesi ise test aşaması için kullanılmıştır. Çalışmanın amacı, daha az zaman ve daha az miktarda hafıza kullanılarak yapılması olmuştur. Ve ESA mimarisi ile problem hızlı ve daha az hafıza kullanarak başarılı şekilde çözülmüştür. Nesne görüntüleri birbirlerine benzemediği için ESA mimarisi nesnelere rahatlıkla ayırmıştır. Sonuç olarak çalışmada, 3GB hafıza kullanılarak %85.9 doğruluk oranı elde edilmiştir [10].

Hao ve arkadaşlarının çalışmasında, ESA ve morfolojik yöntemle mikroskopik *Leucorrhea* görüntülerinde mantarların sınıflandırılması yapılmıştır. Görüntüler, bir pozitif yani mantar içeren ve bir negatif yani mantar içermeyen olarak iki sınıfa ayrılmıştır. Veri setinin %90'ı eğitim ve %10'u test seti olarak kullanılmıştır. Sınıflandırma için ESA yapısı olan LeNet5 uygulanmıştır. Daha sonra ise bir morfolojik yöntem uygulanmıştır. Sınıflandırma sonucu olarak %93.26 doğruluk oranı elde edilmiştir [11].

Wang ve arkadaşları yaptıkları araştırmada, göğüs kanseri mikroskopik görüntülerinin ESA ile sınıflandırılmasını yapmışlardır. Çalışmada, ICIAR2018 veri seti

kullanılmıştır. Veri setinde, her biri 4 sınıfa ayrılmış, toplamda 400 görüntü kullanılmıştır. Sınıflar, normal doku, iyi huylu lezyon, in situ karsinom ve invaziv karsinom olarak ayrılmıştır. Bu görüntülerin 320'si eğitim, 80'i ise doğrulama için ayrılmıştır. Sınıflandırma için VGG modeli kullanılmıştır. Sınıflandırma sonucu doğrulama setinde %92.5, test setinde %91.7 doğruluk oranları elde etmiştir. ESA+DVM sonucu doğrulama setinde %81.25, test setinde %80.6 doğruluk oranları elde edilmiştir [12].

Karakurt ve İşeri, insan hayatı için büyük ölçüde önemli olan meme kanseri olan ve olmayan görüntülerin ESA model kullanarak sınıflandırılmasını yapmışlardır. Çalışmada, 60000 görüntüden 40000'i eğitim, 20000'i test verisi için kullanılmıştır. En iyi sonuç 0.8775 doğruluk oranı, 0.8238 F1 skoru olarak elde edilmiştir [13].

Tahir ve arkadaşları, 5 çeşit mantar sporları görüntülerinin tanımlanmasını yapmışlardır. Kullanılan veri seti 40800 görüntüden oluşmuştur. Bu görüntülerde, eğitim seti için 30000, test seti için 10800 görüntü olarak ayrılmıştır. ESA mimarisi ile sınıflandırma sonucu %94.8 oranında doğruluk elde edilmiştir [14].

Wahid ve arkadaşları, 7 çeşit bakteri türü görüntülerinin derin ESA ile sınıflandırmasını yapmışlardır. Veri seti, her bakteriye ait 160 görüntü olmakla toplamda 1150 görüntüden oluşmuştur. ESA mimarisinin Xception modeli ile sınıflandırma sonucu %95.5 oranında doğruluk elde edilmiştir [15].

Oktaria ve arkadaşları çalışmalarında, mikroskopik ahşap görüntülerinin türlerine göre ESA ile sınıflandırmasını yapmışlardır. ESA mimarisi olarak AlexNet, ResNet ve GoogLeNet kullanılmıştır. Sınıflandırma sonucu AlexNet mimarisi %96.4 doğruluk oranı ile en iyi sonucu vermiştir [16].

## 2. MATERYAL VE METOT


Bu çalışmada *A.flavus* ve *A.fumigatus* küf mantarlarının mikroskopik görüntülerinin sınıflandırılması yapılmıştır. Bu inceleme için derin öğrenme mimarilerinden biri olan ESA model oluşturuldu ve bu model kullanılarak mikroskopik mantar türleri sınıflandırılmıştır.

Literatüre bakıldığında genellikle ESA model ile yapılmış çalışmalar renkli görüntüler üzerinde olduğu görülmüştür. Bu çalışmada deneyler ilk önce renkli görüntüler ile yapılmıştır. Ancak bu renkli görüntülerin deneyimlenmiş bilgi ekleyerek sonuçları olumlu yönde etkilediği görülmüştür. Dolayısı ile bu etkinin ortadan kaldırılması için görüntüler gri tonlara dönüştürülerek deneyler tekrar edilmiştir.


### 2.1. Veri seti

Çalışmada kullanılan veri seti Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Öğretim Üyesi Prof.Dr.

YASEMİN ÖZ tarafından hazırlanmıştır. Veri setinde ayrı ayrı *A.flavus* türüne ait 525 adet görüntü ve *A.fumigatus* türüne ait 525 adet görüntü olmakla toplamda 1050 görüntü vardır. Girdi verilerinin boyutu bellek hacmini, eğitim süresini ve başarı yüzdesini etkilemektedir. Veri boyutları yüksek verildiği zaman eğitim süresi uzun ve kullanılan bellek yüksek olduğu görülmüştür ama bu durum başarı yüzdesinin yükselmesine de sebep olur. Veri boyutu düşük verildiği zaman ise tam tersine eğitim süresi kısa ve kullanılan bellek az olur. Ancak bu durum başarı yüzdesini de etkilediği için ağırlık derinliği azalır ve performans düşük olabilmektedir [17]. Buna esasen bu çalışmada görüntü boyutları uygun bir giriş boyutları olarak 500x500 piksel ayarlanmıştır. Görüntülerin %80'i eğitim, %20'si test için kullanılmıştır. Şekil 1, *A.flavus* ve Şekil 2, *A.fumigatus* küflerinin her birine dair bir görsel gösterilmiştir.




Şekil 1. *Aspergillus flavus*



Şekil 2. *Aspergillus fumigatus*

### 2.2. Derin öğrenme


Derin öğrenme, yapay sinir ağları kullanarak insan beyninin çalışma prensiplerine benzer şekilde öğrenme yapabilen bir algoritmadır. Bu algoritma, bir yapıdaki verileri insanlar gibi analiz etme yeteneği sağlayarak, makinelerle karmaşık problemleri çözme ve verileri anlama becerisi kazandırır [18]. Derin öğrenme, çok katmanlı yapay sinir ağlarından oluşmaktadır [19]. Bu katmanlar arasında gizli katmanlar bulunur ve verilerin öğrenilmesi için bu katmanlar kullanılır. Derin öğrenme algoritmaları, farklı veri türleri üzerinde tahminleme, sınıflandırma ve analiz gibi birçok görevde kullanılmaktadır. Örneğin, görüntülerin nesne tespiti, metinlerin duygu analizi, seslerin konuşma tanıma gibi alanlarda derin öğrenme algoritmaları kullanılmaktadır. Bu algoritmalar, veri içerisindeki karmaşıklığı anlamak ve desenleri keşfetmek için çok sayıda parametreyi optimize eder. Şekil 3'te genel bir derin öğrenme mimarisi gösterilmektedir.



Şekil 3. Genel Derin Öğrenme mimarisi [20]


### 2.3. Evrişimsel sinir ağı

Evrişimsel Sinir Ağı, görsel tanımlama üzerine bir derin öğrenme algoritmasıdır. ESA modeli, modern makine öğrenmesi uygulamalarında çok yaygın kullanılıyor. Geleneksel ESA modeli, giriş katmanı, evrişim (konvolüsyon) katmanı, havuzlama katmanı, tam bağlantı katmanı ve çıktı katmanlarından oluşmaktadır [21]. Şekil 4'te genel ESA mimarisi gösterilmektedir.



Şekil 4. Genel ESA mimarisi [22]

Girdi katmanı, video, ses ve görüntü verileri olabilir. Verilerin türüne göre sinir ağlarının işlemleri de değişir. Girdi katmanına yüklenen veri görüntü olduğu zaman, renk analizi veya obje kenarlarının bulunması işlemleri gibi işlemler gerçekleştirilir. Bir sinir ağında katmanlar arasında bulunan nöron bağlantılarının sayısal değerleri yani ağırlıkları vardır [23]. Bu ağırlıklar eğitim zamanı çıktı değeri için nöronların önemini göstermektedir. Katmanlar arasında elde edilen çıkış değeri, ağırlıkları ile çarpılarak sonraki katmanın girdi değerini oluşturmaktadır. Girdi katmanından başlayarak çıktı katmanına kadar giden ileri yönlü akış, ileri yayılım algoritması adlanır. İleri yayılım algoritması ile elde edilen sonuçlar sinir ağlarının tahmin değerleridir [24]. Şekil 5'te, bu çalışmada kullanılan ESA mimarisini gösterilmiştir.



Şekil 5. Kullanılan ESA mimarisi

### 2.4. Evrişim katmanı

Evrişim katmanı ESA'nın temel yapı bileşenlerinden biridir. Görüntü verileri, piksellerden oluşan matrislerdir. Bu katman, görüntüler üzerindeki belirli özellikleri öğrenmektedir [25]. Evrişim katmanı görüntüden özellik

çıkarmak için filtreler uygular. Ve bu filtreler çok boyutludur. Uygulanan filtreler 2x2, 3x3, 5x5 boyutlarda olabilir [17]. Aynı zamanda evrişim katmanı, dönüşüm katmanı olarak da adlandırılmaktadır. Yani, filtrelerin görseller üzerinde dolaştırılarak yeni matris oluşturmasıdır [22].

### 2.5. Havuzlama katmanı

Havuzlama katmanı, evrişimli katmanlar arasında yerleşir. Bu katman, sonraki katmanlardaki iş yükünü azaltıyor. Yani, görsel verisi çok fazla büyük olduğunda parametre sayısını azaltarak görseli küçültmektedir. Sonuçta bir bilgi kaybı oluşuyor ve bununla da hesaplama maliyeti azalmaktadır [25]. Lakin bu işlem derinlik boyutuna etki etmez [17].

### 2.6. Değerlendirme metrikleri

Değerlendirme metrikleri, bir modelin performansını ölçmek için kullanılmaktadır. Sınıflandırma problemleri için kullanılan değerlendirme metriklerine doğruluk (accuracy), kesinlik (precision), geri çağırma (recall) ve F1 skoru dahildir [26].

Doğruluk değeri, sınıflandırma modelinin doğru tahminlerinin toplam örnek sayısına oranını göstermektedir. Doğruluk değerinin formülü denklem 1'de verilmiştir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

Burada, TP (True Positive) doğru tahmin edilen pozitiflerin, TN (True Negative) doğru tahmin edilen negatiflerin, FP (False Positive) yanlış tahmin edilen pozitiflerin, FN (False Negative) ise yanlış tahmin edilen negatiflerin sayılarını göstermektedir.

Kesinlik değeri, modelin doğru pozitif sonuçlarının toplam pozitif tahminlere oranını ölçmektedir. Yani tüm örnekler içerisindeki doğru tahmin edilen örneklerin yüzdesini göstermektedir. Denklem 2'de kesinlik değerinin formülü verilmiştir.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (2)$$

Geri çağırma değeri, modelin pozitif örneklerinin doğru sınıflandırma sonucunu ölçmektedir. Geri çağırma değerinin formülü denklem 3'te verilmiştir.


$$\text{Geri çağırma} = \frac{TP}{TP + FN} \quad (3)$$

F1 skor değeri, kesinlik ve geri çağırma değerlerinin harmonik ortalamasını ölçmektedir. F1 skor değerinin formülü denklem 4'te verilmiştir [27].


$$\text{F1 skor} = \frac{2 * \text{Kesinlik} * \text{Geri çağırma}}{\text{Kesinlik} + \text{Geri çağırma}} \quad (4)$$

### 3. BULGULAR

Bu çalışmadaki ESA model giriş katmanı, üç adet Evrişim2D, üç adet MaxHavuzlama, iki adet Yoğun ve dört adet Bırakma katmanlarından oluşmaktadır. Optimizasyon algoritması olarak RMSprop algoritması kullanılmıştır. Optimizasyon algoritması görüntü sınıflandırma modellerinin performansını yükseltmek için kullanılmaktadır. Bu algoritmanın öğrenme oranı hiperparametresi 0.001 olarak belirlenmiştir. Öğrenme oranı, ağırlık güncellemelerindeki adımların büyüklüğünü kontrol etmektedir. Yığın boyutu (batch\_size) olarak 12 rakamı belirlenmiştir. Yığın boyutu, eğitim veri setinde modelin bir seferde işleyeceği örnek sayısını belirlemektedir. Görüntü boyutları, 500x500 piksel olarak girilmiştir. Modelin eğitiminin doğru ve tam olması açısından erken durdurma kullanılmıştır. Erken durdurma, model tam olarak eğitildiğinde girilen dönem sayısını tamamlamadan otomatik olarak modeli durdurur. Dönem sayısı, veri setinin işlenerek ağırlıklarının güncellenmesidir [24]. Çalışmada bu özellik sayesinde, toplamda 1000 dönem içerisinde, bine kadar gitmeden modelin eğitimi 71'ci dönemde, %97.62 eğitim doğruluğu olarak tamamlanmıştır. Eğitilmemiş verilerin F1 skor değeri %86.23 olarak elde edilmiştir.

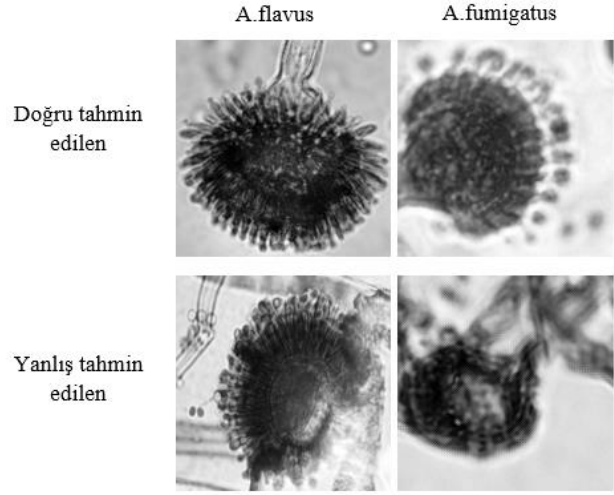


Şekil 6. Eğitim ve Doğrulama verilerinin kayıp oranları



Şekil 7. Eğitim ve Doğrulama verilerinin doğruluk oranları

Şekil 6, eğitilen modelde eğitim verilerinin kayıp oranının 0.0822 olduğunu göstermektedir. Şekil 7 ise en yüksek doğruluk oranının %97.62 olduğunu göstermektedir. Sonuçlara esasen eğitilmemiş verilerin F1 skor değeri, %86.23 olarak elde edilmiştir. Şekil 8'de doğru ve yanlış tahmin edilen görüntülere ait birer örnek verilmiştir.



Şekil 8. Doğru ve yanlış tahmin edilen görüntü örnekleri

Tablo 1'de önceden eğitilmemiş ESA modeller ile yapılan çalışmaların bu çalışma ile karşılaştırılması verilmiştir.

**Tablo 1.** Önceden eğitilmemiş ESA modeller ile yapılan çalışmaların karşılaştırılması

Yazar	Veri Seti	Yöntem	Tanıma Oranı
Simara Safarlı, Uğur Gürel, Yasemin Öz	A.flavus, A.fumigatus	ESA model	%97.62
Robert Kerwin Billones vd.	9 çeşit Aspergillus	ESA model	%94.20
Muhammad Waseem Tahir vd.	5 çeşit mantar sporu	ESA model	%94.8
Mengran Fan vd.	Mikroskopik Mantar ve Göğüs kanseri Histoloji görüntüleri	ESA model	%94.3
Sukanya S Gikwad vd.	Pant Pathology	ESA model	%88.9
Meral Karakurt ve İsmail İşeri	Meme Patoloji Görüntüleri	ESA model	%87.75
Caner Çalık	Cifar-10	ESA model	%85.9

### 4. TARTIŞMA VE SONUÇ

Literatüre bakıldığında evrişimsel sinir ağları oldukça yaygın olarak kullanılmaktadır. Bu algoritma, tanımlama ve sınıflandırma problemleri üzerine gelişmiş bir algoritmadır. Evrişimsel sinir ağları ile yapılan çalışmalar içerisinde özellikle tıp alanında olan çalışmalar önde gelmektedir.

Çalışmamızda, evrişimsel sinir ağları model ile *A.flavus* ve *A.fumigatus* mikroskopik mantar türlerinin sınıflandırılması başarılı bir şekilde yapılmıştır. Çalışmada, en iyi sonuca varmak için denemeler zamanı eğitim ve test veri seti karıştırılarak tekrar bölünmüştür. Eğitimler sonucunda, doğruluk oranının düşük olmasına esasen ve kayıp değerleri azaltmak için optimize edici değiştirilerek RMSprop optimizasyon algoritması kullanılmıştır. Sonuç olarak yapılan denemeler içerisinde en yüksek sonuç %97.62 oranında eğitim doğruluğu ve %91.90 oranında test doğruluğu olarak elde edilmiştir. Tablo 1'deki karşılaştırmaya esasen, önceden eğitilmemiş evrişimsel sinir ağı model ile yapılan çalışmalar arasındaki en iyi sonucu bu çalışma göstermiştir.

## Etik Hususlar

### Etik kurallara uyum

Bu çalışma, insan gönüllüleri ve deneysel hayvan içeren çalışmalarda gerçekleştirilen tüm prosedürleri, kurumsal ve / veya ulusal araştırma komitesinin etik standartlarına ve 1964 Helsinki deklarasyonuna ve daha sonraki değişikliklerine veya karşılaştırılabilir etik standartlara uygun olarak yürütülmüştür.

### Finansman

Bu çalışma, kamu, ticari veya kar amacı gütmeyen sektörlerdeki fon kuruluşlarından özel bir hibe alınmamıştır.

### Çıkar çatışması

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

## KAYNAKÇA

- [1] Ayberkin, E., Çiftçi, E. 2009. Çocuklarda Aspergillus Enfeksiyonları. J Pediatr Inf, 3, 118-25.
- [2] Kilich, M. A. 2007. Aspergillus flavus: the major producer of aflatoxin. Molecular plant pathology, 8(6), 713-722. DOI:10.1111/j.1364-3703.2007.00436.x
- [3] Gourama, H., Bullerman, L. B. 1995. Aspergillus flavus and Aspergillus parasiticus: Aflatoxigenic fungi of concern in foods and feeds: A review. Journal of Food protection, 58(12),1395-1404. DOI:10.4315/0362-028X-58.12.1395
- [4] Billones, R. K. C., Calilung, E. J., Dadios, E. P., Santiago, N. 2020. Aspergillus Species Fungi Identification Using Microscopic Scale Images. In 2020 IEEE 12th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNICEM), 3-7 December, Manila, Philippines, 1-5.
- [5] Fan, M., Chakraborti, T., Eric, I., Chang, C., Xu, Y., Rittscher, J. 2020. Fine-Grained Multi-Instance Classification in Microscopy through Deep Attention. In 2020 IEEE 17th International Symposium on Biomedical Imaging (ISBI), 3-7 April, Iowa City, IA, USA, 169-173.
- [6] Polap, D., Wozniak, M., Korytkowski, M., Scherer, R. 2020. Encoder-Decoder Based CNN Structure for Microscopic Image Identification. In International Conference on Neural Information Processing, 23-27 November, 301-312.
- [7] Mital, M. E., Tobias, R. R., Villaruel, H., Maningo, J. M., Billones, R. K., Vicerra, R. R., Dadios, E. 2020. Transfer Learning Approach for the Classification of Conidial Fungi (genus aspergillus) Thru Pre-Trained Deep Learning Models. In 2020 IEEE Region 10 Conference (TENCON), 16-19 November, Osaka, Japan, 1069-1074.
- [8] Gaikwad, S. S., Rumma, S. S., Hangarge, M. 2021. Fungi classification using convolution neural network. Turkish Journal of Computer and Mathematics Education (TURCOMAT), 12(10), 4563-4569. DOI:10.17762/turcomat.v12i10.5200
- [9] Gaikwad, S. S., Bhalerao, S., Rumma, S. S., Hangarge, M. 2021. Classification of Microscopic Images of Fungi Using Deep Learning Models. SAMRIDDHI: A Journal of Physical Sciences, Engineering and Technology, 13(SUP 2), 105-110.
- [10] Çalık, R. C. 2018. Gömülü Sistem Üzerinde Evrişimsel Sinir Ağları ile Nesne Sınıflandırması. TOBB ETÜ, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 78s, Ankara.
- [11] Hao, R., Wang, X., Zhang, J., Liu, J., Du, X., Liu, L. 2019. Automatic detection of fungi in microscopic leucorrhea images based on convolutional neural network and morphological method. In 2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC), 15-17 March, Chengdu, China, 2491-2494.
- [12] Wang, Y., Sun, L., Ma, K., Fang, J. 2018. Breast cancer microscope image classification based on CNN with image deformation. In Image Analysis and Recognition: 15th International Conference, 27-29 June, Povo de Varzim, Portugal, 845-852.
- [13] Karakurt, M., & İşeri, İ. 2022. Patoloji Görüntülerinin Derin Öğrenme Yöntemleri İle Sınıflandırılması. Avrupa Bilim ve Teknoloji Dergisi, (33), 192-206. DOI:10.31590/ejosat.1011091
- [14] Tahir, M. W., Zaidi, N. A., Rao, A. A., Blank, R., Vellekoop, M. J., & Lang, W. 2018. A fungus spores dataset and a convolutional neural network based approach for fungus detection. IEEE transactions on nanobioscience, 17(3), 281-290.
- [15] Wahid, M. F., Hasan, M. J., & Alom, M. S. (2019, September). Deep Convolutional Neural Network for Microscopic Bacteria Image Classification. In 2019 5th International Conference on Advances in Electrical Engineering (ICAEE), 26-28 September, Dhaka, Bangladesh, 866-869.



- [16] Oktaria, A. S., Prakasa, E., & Suhartono, E. 2019. Wood Species Identification Using Convolutional Neural Network (CNN) Architectures on Macroscopic Images. *Journal of Information Technology and Computer Science*, 4(3), 274-283.
- [17] İnik, Ö., Ülker, E. 2017. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- [18] Günal, A. 2020. Derin Öğrenme Nedir? Nerelerde Kullanılır? <https://www.bilimya.com/derin-ogrenme-nedir-nerelerde-kullanilir.html> (Erişim Tarihi: 08.06.2023).
- [19] Şeker, A., Diri, B., Balık, H. H. 2017. Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64.
- [20] Doğan, Ö. 2020. Derin Öğrenme Nedir? Yapay Sinir Ağları Ne İşe Yarar? <https://teknoloji.org/derin-ogrenme-nedir-yapay-sinir-aglari-ne-ise-yarar/> (Erişim Tarihi: 08.06.2023).
- [21] Hussain, M., Bird, J. J., Faria, D. R. 2019. A study on cnn transfer learning for image classification. In *Advances in Computational Intelligence Systems: Contributions Presented at the 18th UK Workshop on Computational Intelligence*, 5-7 September, Nottingham, UK 191-202.
- [22] Aydın, A. G. A. 2021. Derin Öğrenme. *Bilgisayar Bilimlerinde Teorik Ve Uygulamalı Araştırmalar*, 105s.
- [23] Tüfekçi, M., Karpaz, F. 2019. Derin Öğrenme Mimarilerinden Konvolüsyonel Sinir Ağları (CNN) Üzerinde Görüntü İşleme-Sınıflandırma Kabiliyetinin Arttırılmasına Yönelik Yapılan Çalışmaların İncelenmesi. In *International Conference on Human-Computer Interaction, Optimization and Robotic Applications*, 5-7 July, Ürgüp, Nevşehir, 28-31.
- [24] Kayalı, N. S., Omurca, S. İ. Konvolüsyonel Sinir Ağları (CNN) ile Çin Sayı Örüntülerinin Sınıflandırması. *Computer Science*, (Special), 184-191. DOI:10.53070/bbd.989668
- [25] Li, Q., Cai, W., Wang, X., Zhou, Y., Feng, D. D., Chen, M. 2014. Medical image classification with convolutional neural network. In *2014 13th international conference on control automation robotics & vision (ICARCV)*, 10-12 December, Singapore, 844-848. 989668
- [26] Ay, Ş. 2020. Model Performansını Değerlendirmek – Metrikler. <https://medium.com/deep-learning-turkiye/model-performans%C4%B1n%C4%B1-de%C4%9Ferlendirmek-metrikler-cb6568705b1> (Erişim Tarihi: 10.06.2023).
- [27] Abacı, B. 2019. Makine Öğrenmesi Performans Ölçütleri. [https://imlab.io/2019/07/14/machine-](https://imlab.io/2019/07/14/machine-learning-performance-metrics/)

learning-performance-metrics/ (Erişim Tarihi: 10.06.2023).