



# Artık Ağ Tabanlı Uygulamayla Gözlerde Bulunan Bakterilerin Sınıflandırılması

## Classification of Bacteria in Eyes with a Residual Network Based Application

Betül ÖZÇINAR

Altınbaş Üniversitesi

Elektrik ve Bilgisayar Mühendisliği Bölümü

İstanbul, Türkiye

203720931@ogr.altinbas.edu.tr

ORCID:0000-0002-7693-2766

Sefer KURNAZ

Altınbaş Üniversitesi

Bilgisayar Mühendisliği Bölümü

İstanbul, Türkiye

sefer.kurnaz@altinbas.edu.tr

ORCID: 0000-0002-7666-2639

### Öz

Araştırmada, ResNet mimarisi kullanılarak TensorFlow ve Keras kütüphaneleri kullanılarak bir derin öğrenme modeli oluşturulmuştur. Çalışmada 6 farklı bakteri sınıfı için toplamda 689 adet bakteri resmi veri kümesi olarak kullanılmıştır. Yazılım tasarımı, veri ön işleme, model oluşturma ve eğitim adımlarını içermektedir. Veri ön işleme aşamasında, resimler normalize edilmiş ve boyutlandırılmıştır. Model oluşturma aşamasında, ResNet mimarisi tercih edilmiştir çünkü derin ağların daha iyi öğrenme yetenekleri sunabileceği bilinmektedir. Model eğitimi sırasında, eğitim verisi üzerinde iteratif bir yaklaşım benimsenmiş ve optimize edici işlevler kullanılarak ağırlıklar ayarlanmıştır. Sonuçlar, tasarlanan yazılımın %83,33 doğruluk oranı ile bakteri resimlerini başarılı bir şekilde sınıflandırdığını göstermektedir. Bu sonuçlar, derin öğrenme tekniklerinin biyomedikal görüntü analizinde potansiyelini vurgulamaktadır. Bu çalışma, bakteri sınıflandırma konusunda daha geniş veri kümeleri ve daha gelişmiş özellik mühendisliği tekniklerinin entegrasyonunu içerecek şekilde genişletilebilir.

**Anahtar sözcükler:** Derin öğrenme, Makine öğrenmesi, Sınıflandırma, Artık ağ (residual network),Yapay zeka

### Abstract

In the research, a deep learning model using the ResNet architecture was constructed using the TensorFlow and Keras libraries. A dataset comprising a total of 689 bacterial images was utilized for 6 distinct bacterial classes. The software design encompasses data preprocessing, model creation, and

training steps. During data preprocessing, the images were normalized and resized. The ResNet architecture was chosen for model creation, as deep networks are known to offer enhanced learning capabilities. Throughout model training, an iterative approach was adopted on the training data, and the network's weights were adjusted using optimization functions. The results demonstrate that the designed software effectively classifies bacterial images with an accuracy rate of 83.33%. These findings underscore the potential of deep learning techniques in biomedical image analysis. This study can be expanded to encompass larger datasets and more advanced feature engineering techniques for bacterial classification.

**Keywords:** Deep learning, Machine learning, Classification, Residual network, Artificial Intelligent

### 1. Giriş

Günümüzde görüntüleri sınıflandırmak, algılamak ve yeniden yapılandırmak için çeşitli derin öğrenme sistemlerinden yararlanılmaktadır. Bunların başında da Convolutional Neural Network (CNN) yapıları gelmektedir. Bu CNN yapısı gelen görüntüyü alır algılar, sınıflandırma yapar ve tekrar yapılandırır. Amacımız verilen görüntüyü algılayabilen ve sınıflanmasına yardımcı olan bir yapıda olmasıdır.

Evrimsel Sinir Ağı, derin sinir ağlarından biridir. Evrimsel sinir ağı birçok katmandan oluşur. CNN, eğer boyut yeterliyse, büyük ağ boyutu ve çok sayıda eğitim örneği gerektiren derin bir sinir ağına meydana gelen sınırlamayı iyileştirir [1].

## 1.1 Makine Öğrenmesi

Bilgi teknolojisinin şaşırtıcı gelişimi, eğitimsel yenilikleri kolaylaştırmak için etkisinin zaten dünyaya yayılmış olduğu ağ öğrenimi için yeni bir vizyon yaratmıştır. Bu nedenle, birçok ülke bilgisayar teknolojisine önem vermekte ve eğitim reformunu etkili ve verimli bir şekilde kolaylaştırmasını beklemektedir. Bilgisayar ve İnternet öğretilerinin geleneksel öğretime uygulanmasının bir tür dönüşüm gerektirdiği iyi bilinmektedir. Sonuç olarak, uygun öğrenme modelinin araştırılması ve geliştirilmesi, kullanıcılar ve bilgisayarlar, eğitmen ve öğrenciler arasındaki karşılıklı etkileşimi ve öğrenenler arasındaki etkileşimi ciddi şekilde dikkate almalıdır.

Makine öğrenimi, insanların bilgisayarları, makinelerin kalıpları tanıyabilmesi veya bilgisayarda girdilerden öğrenebilmesi için programlamasını sağlar. Öğrenme kavramı, bilgiyi bilgiye dönüştürme sürecidir. Bir makine öğrenimi algoritması, "deneyimi temsil eden eğitim verileridir. Çıktı ise, genellikle bazı görevleri yerine getirebilen başka bir bilgisayar programı biçimini alan neredeyse bir uzmanlık şeklidir [2].

Pek çok başarılı makine öğrenimi uygulaması vardır. Makine öğrenimi uygulamaları, dolandırıcılığı tespit etmeyi öğrenen veri madenciliği programlarından bilgi filtreleme sistemlerine ve hatta kendi kendini süren araçlara kadar çeşitlilik gösterir. "Makine öğrenimi, istatistik, yapay zeka, felsefe, bilgi teorisi, biyoloji, bilişsel bilim, hesaplama karmaşıklığı ve kontrol teorisi dahil olmak üzere birçok alanın kavram ve sonuçlarından yararlanır." Makine öğrenimini kullanan teori ve algoritmalarda önemli gelişmeler olmuştur [3].

Makine öğrenimi, verilerin sınıflandırılmasını sağlar. Uygulama, eğitilmiş (denetimli) veya eğitim verisiz (denetimsiz) verilerdeki kalıbı tanır. Sınıflandırmada, veriyi "anlamlandırma" kavramına makine öğrenmesinde "kümeleme" denir. Kümeleme algoritmalarının bazı örnekleri arasında K-Means, Farthest-First, Beklenti-Maksimizasyon (EM) ve diğerleri sayılabilir [4].

Makine öğrenimi (ML) teknikleri, karmaşık davranışlarla karşılaşıldığında bile büyük miktarda makine verisini eyleme dönüştürülebilir bilgilere dönüştürmeyi mümkün kılar [5]. Makine öğrenmesi daha önceleri sadece insanların problemleri çözdüğü düşünülen çeşitli problemleri algılamayı ve onları çözmeyi öğrenen sistemlerdir. Eğitim alanında, Askeri alanlarda, Tıp alanında vs. birçok alanda ilerleme kaydedilirken bu alanlarda devasa miktarda bir veri kümesi açığa çıkmıştır. Makine Öğrenmesi teknikleri bu yüzden büyük verilerle problem çözmede, onları algılamada yetersiz kalmıştır. Bu yetersizliği gidermek için veri bilimciler tarafından derin öğrenme yapısı ortaya çıkmıştır. Makine öğreniminde sistem içinde nitelikli olanlar seçilir ve bunlara göre istatistik parametre verileri öğrenir.

## 1.2 Derin Öğrenme

Derin öğrenme de makine öğreniminin bir alt sınıfıdır [6]. Temel prensip, yapay nöronlarla yapay sinir ağları (YSA) oluşturmak ve ardından bir kayıp fonksiyonu kurmaktır.

İleriye yayılım ve geriye doğru geri besleme sayesinde, sürekli olarak büyük miktarda veriye dayanır.

Oluşturulan eğitim kümesi parametreleri veri modeline en iyi uyacak şekilde değiştirir [7]. Geleneksel makine öğrenimi ile karşılaştırıldığında, derin öğrenme büyük veri işleme için daha uygundur. Algoritma başarımı, veri hacminin artmasıyla artar. Geleneksel makine öğreniminden farklı olarak derin öğrenme, uygulama özelliklerinin yapay olarak belirlenmesine dayanmamaktadır. Bunun yerine, verilerden doğrudan daha yüksek seviyeli özellikler elde etmeye ve çoklu özellik dönüşümleri yoluyla derin seviyeli bir makine öğrenimi modeli elde etmeye çalışır [6].

Derin öğrenme, başlangıcından bu yana onlarca yıllık bir gelişme yaşadı. MP modeli ve hebb öğrenme kuralı önerisinden Amerikalı bilim adamı Rosenblatt tarafından algılayıcı öğrenmesinin keşfine kadar, sonraki algılayıcı önerisi, sinir ağının gelişimi için dönüm noktası olmuştur [8].

Derin öğrenme modeli, girdiyi ağırlıklarla çarparak çıktı üretir ve sonuç olarak tüm değerleri toplar.


$$Y = \sum (\text{ağırlık} * \text{girdi}) + \text{sapma} \quad (1)$$

Y model çıktısı ve sapma (bias), modeli optimize etme gereksinimine göre seçilen bir sabittir [9].

Derin öğrenme, görüntü sınıflandırma, konuşma tanıma, bilgisayarla görme, doğal dil işleme, biyoinformatik, reklamcılık, e-ticaret, dijital pazarlama, robot öğrenme ve diğerleri gibi birçok alanda uygulamalara sahiptir [10,11]. Derin öğrenme çerçevesine dayalı yaklaşım, tipik bir veriye dayalı yaklaşımdır ve büyük miktarda eğitim verisi ve sınav verisi gerektirir [12].

### 1.2.1 AlexNet

2012 yılında ILSVRC, büyük ölçekli nesne algılama ve görüntü sınıflandırma algoritmaları için yapılan yarışmada 1.olan Alex AlexNet mimarisini ortaya çıkarmıştır. Standart özellikleri ve sınıflandırıcı eğitim tekniklerini kullanan Krizhevsky sinir ağlarını, özellikle evrişim sinir ağlarını kullanıp yarışmada derece yapmıştır. Oluşturduğu modeli, tamamen bağlantılı 3 katmandan ve 5 evrişimli katmandan oluşur. AlexNet'in ilk katmanı, genişlik, yükseklik ve derinlik (kırmızı, yeşil, mavi) için sırasıyla 227 x 227 x 3 boyutunda filtrelenmiş bir görüntünün girişi için kullanılır. AlexNet 1000 bağlı katmanı birbirine bağlar ve katmanların geri kalanı bir özellik çıkarıcı olarak çalışır. AlexNet, her girdi görüntüsü için çıktı katmanından hemen önce gizli katman aktivasyonlarını içeren 4096 boyutlu bir özellik vektörü üretebilmektedir. AlexNet'in kendisi 650.000 nöron ve 60 milyon parametre içeren devasa bir yapıdır [13].

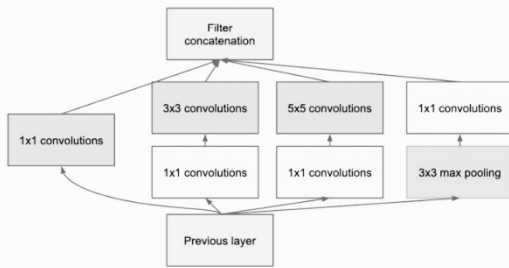


Şekil-1: 1000 katmanlı Alexnet mimari modeli

### 1.2.2 GoogleNet

AlexNet in 2012 yılında yarışmayı kazanmasının ardından GoogLeNet, 2014 yılında ImageNet Büyük Ölçekli Görsel Tanıma Mücadelesi (ILSVRC) yarışmasında önerilen sistem olmuştur. Önceki sistemlerden farklı olarak ağıın derinliği ve genişliği artırılırken hesap maliyetini düşük tutmasıdır. Sistem AlexNetin aksine 12 kat daha fazla parametre içermektedir.

LeNet fikrinden yola çıkarak, Christian Szegedy ağ yapısı kavramını, yani ağ modelini 22 katman yapan ve ağdaki bilgi işlem kaynaklarının kullanımını büyük ölçüde geliştiren bir "temel nöron" yapısı oluşturmayı önerdi. Bu sistem bilgi işlem yükünü artırmadan ağıın genişliğini ve derinliğini artıran bir yapıya sahiptir. Mimari aynı boyutun özelliklerini bir araya getirmek için yapı, 1x1, 3x3, 5x5 boyutunda evrişim çekirdeklerini ve CNN'de yaygın olarak kullanılan 3x3 boyutunda en büyük havuzlama katmanını istifler. Bir yandan ağıın genişliğini artırırken diğer yandan ağıın ölçeklenebilirliğini artırır [14].




Şekil-2: GoogLeNet veri mimari modeli

### 1.2.3 Vgg16-Vgg19

ImageNet veri kümesinde önceden eğitilmiş Visual Geometry Group (VGG16) modeli, 13 evrişimli katmana ve ardından 3 tam bağlı katmana sahiptir. VGG-16 modeli, diğer ağlara kıyasla tüm bozulma türleri ve seviyeleri için sınıflandırma doğruluğu ve esnekliği açısından mükemmel performans gösterdiği için seçilmiştir. Bu ağ, evrişimli katmanlar arasında doğrultulmuş doğrusal birim (ReLU) işlevini kullanan, artan derinlikle birbiri üzerine yığılmış daha küçük (3x3) evrişimli katmanlarla karakterize edilmiştir.

Bu sistem önceki tekniğe göre önemli bir gelişme sağlamıştır. Sistemde oluşturdukları derinliği 16 ile 19 katmanına iterek yaklaşık 138 tane eğitilebilir parametreye dönüştürdüler. Vgg 16 ile Vgg19 arasındaki tek fark layer sınıflarının farklı olmasından kaynaklanmaktadır [15].



Şekil-3: Vgg16 Katman Modeli

### 1.2.4 Residual Network

2015 yılında Microsoft Research'teki araştırmacılar tarafından önerilen ResNet, Rezidüel Ağ adı verilen yeni bir mimariyi tanıttı [16]. Bu model önceki mimariye kıyasla daha derin bir yapıya sahiptir. Sistemin hata oranı %3,27 dir. Bu oran insanın hata yapma oranını da geçerek çok büyük bir başarı anlamına gelmektedir.

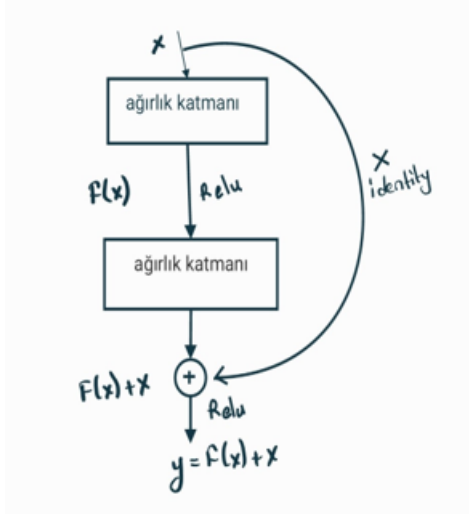
Evrişimli sinir ağı(CNN) modellerinden biri olan artık sinir ağı (ResNet). Son yıllarda "Görüntü İşleme ve Tanıma" alanında muazzam ilerleme kaydedilmiştir. Deep Neural Networkler de daha derin ve daha karmaşık hale gelmektedir. Bir Sinir Ağına (Neural Network) daha fazla katman eklemenin, onu görüntü ile ilgili görevler için daha sağlam hale getirebileceği kanıtlanmıştır [17]. Ancak aynı zamanda doğruluklarını kaybetmelerine de neden olabilir. Rezidüel Ağların (Residual Network) devreye girdiği yer burasıdır.

Derin öğrenme (Deep Learning) uygulayıcıları tarafından bu kadar çok katman ekleme eğilimi, karmaşık görüntülerden önemli özellikleri çıkarmaktır. Böylece, ilk katmanlar kenarları algılayabilir ve sondaki katmanlar, bir arabanın lastikleri gibi tanımlanabilir ve şekilleri algılayabilir. Ancak ağa 30'dan fazla katman eklersek, performansı düşer ve düşük bir doğruluk elde eder. Bu, katmanların eklenmesinin bir sinir ağına daha iyi hale getireceği düşüncesine aykırıdır. Bunun nedeni aşırı uyum gösterme değildir, çünkü bu durumda sorunu tamamen çözmek için atlama ve düzenleme teknikleri kullanılabilir. Esas sorun burada kaybolan gradyanlardır. Artık Sinir Ağı (ResNet) (He et al., 2016), tipik bir evrişimli sinir ağı yapısında bir "atlama yapısı" içeren artık bir yapısal bloğu ifade eder. Ayrıca derin sinir ağındaki artan katman sayısına (1000'den fazla katman) rağmen mükemmel bir eğitim doğruluğu ve performansı sağlama yeteneğine sahiptir.

Artık yapı bloğu şu şekilde ifade edilebilir;

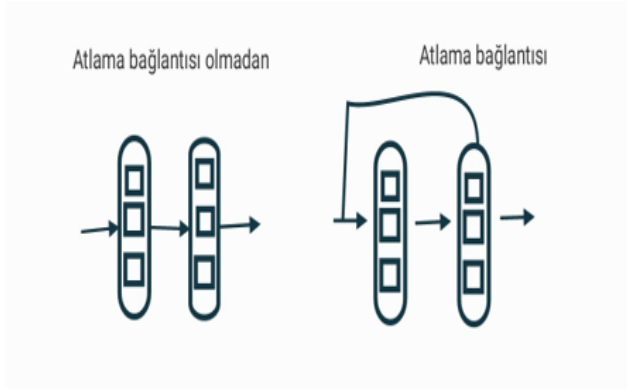
Bu network arkasındaki yaklaşım, katmanların temel haritalamayı öğrenmesi yerine, ağıın artık haritalamaya uymasına izin vermektir. Dolayısıyla, ilk eşleme olan  $H(x)$  yerine, ağıın,

$F(x) := H(x) - x$ 'e uygulanmasına izin verir, bu da  
 $H(x) := F(x) + x$ 'i verir. (2)



Şekil-1:  $F(x)$  artık fonksiyon ekleme modeli (resnet)

Atlama bağlantıları aşağıda gösterilmiştir:

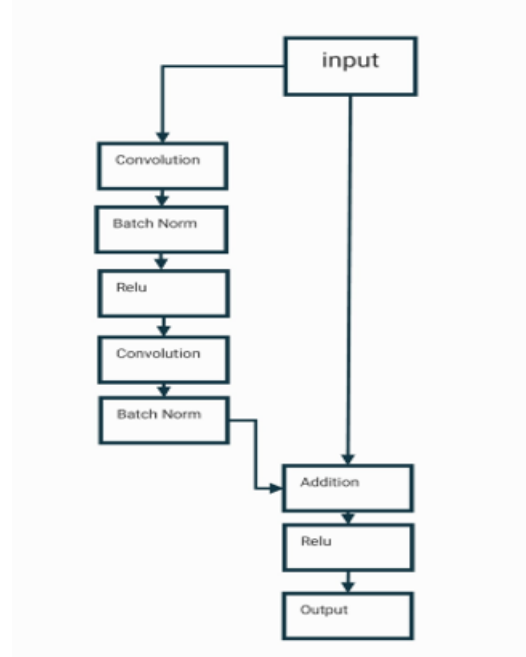


Şekil-2: Atlama bağlantılı ve atlama bağlantısız model

Bir önceki katmanın çıktısı, artık blokta sonraki katmanın çıktısına eklenir. Atlama veya atlama 1, 2 veya hatta 3 olabilir. Toplama sırasında,  $x$ 'in boyutları, evrişim sürecinden dolayı  $F(x)$ 'ten farklı olabilir, bu da boyutlarının küçülmesine neden olur. Bu nedenle,  $x$ 'in boyutlarını değiştirmek için ek bir  $1 \times 1$  evrişim katmanı ekleriz.

Artık bir blok, bir  $3 \times 3$  evrişim katmanına ve ardından bir toplu normalleştirme katmanına ve bir ReLU etkinleştirme işlevine sahiptir. Bu, yine bir  $3 \times 3$  evrişim katmanı ve bir toplu normalleştirme katmanı ile devam ettirilir. Atlama bağlantısı temel olarak bu iki katmanı da atlar ve doğrudan ReLU etkinleştirme işlevinden önce ekler. Bu tür artık bloklar, artık bir ağ oluşturmak için tekrarlanır.

Mevcut tüm CNN mimarilerinin derinlemesine bir karşılaştırması yapıldıktan sonra, ResNet, sınıflandırma görevleri için en düşük %5 hata oranını %3,57'de tutarak diğer tüm mimarileri geride bırakarak öne çıktı. İnsanlar bile çok daha düşük hata oranlarına sahip değildir.

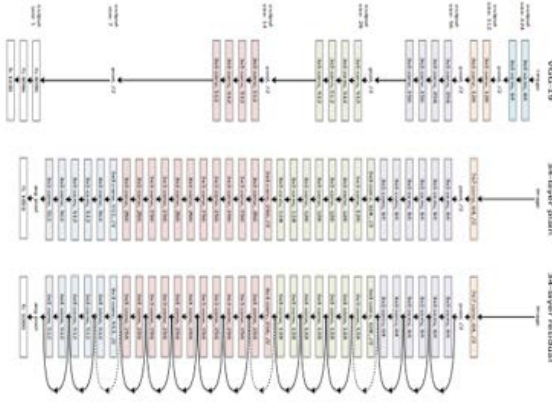


Şekil-3: Atlama bağlantısı yapısı modeli

Ağ bağlantılı sistemler, endüstri mühendisliği sistemi, sosyal sistem vb. dahil olmak üzere çoklu disiplinlerde patlama yaşamıştır. Ağ yapısı, ağ bağlantılı sistemlerin anlaşılması ve keşfedilmesi için bir ön koşuldur. Bununla birlikte, pratikte ağ yapısı her zaman bilinmez, bu nedenle ağ yapısının çıkarımını araştırmak önemli ancak zordur. Faz-uzay tabanlı yöntem ve sıkıştırılabilir algılama tabanlı yöntem gibi bazı model tabanlı yöntemler ve veri güdümlü yöntemler, yapı çıkarım görevlerini araştırmış olsa da, açgözlü yinelemeli optimizasyon prosedürü nedeniyle zaman alıcıydılar ve bu da onları gerçek anlamda tatmin etmeyi zorlaştırıyordu-Zaman yapısı çıkarım gereksinimleri-. L1 ve diğer yöntemlerin yeniden oluşturma süresi kısa olmasına rağmen, yeniden yapılandırma doğruluğu çok düşüktür. Derin öğrenme çerçevesi ile yapı çıkarımı için güçlü temsil edilebilirlik ve zaman verimliliğinden ilham alan bir roman sinerji yöntemi, ağ yapısı çıkarım görevini verimli ve doğru bir şekilde çözmek için derin artık ağı ve tamamen bağlı katman ağını birleştirir [18]. Bu yöntem, geleneksel yöntemlerin uzun yeniden yapılandırma süresi ve düşük doğruluk sorunlarını mükemmel bir şekilde çözer. Ayrıca, önerilen yöntemin ölçeklenebilirliğini gösteren büyük ölçekli karmaşık ağların çıkarım görevini de yerine getirebilir.

### 1.2.5 ResNet'in Ağ Mimarisi

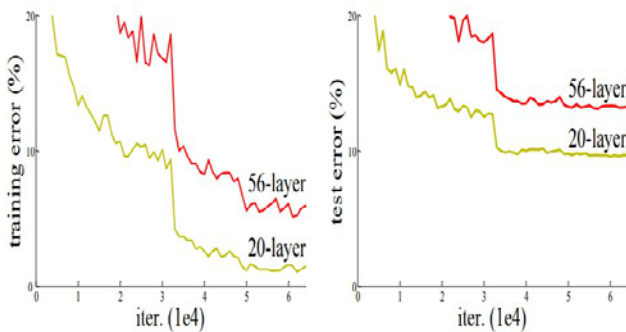
Bu ağ, VGG-19'dan ilham alan 34 katmanlı düz ağ mimarisini kullanır ve ardından kısayol bağlantısı eklenir. Bu kısayol bağlantıları daha sonra mimariyi artık ağa dönüştürür.



Şekil-4: Resnet eklemeye katman gösterimi

Sonuç olarak, artık ağların, zaten derin bir sinir ağına daha fazla katman eklerken kaybolan ve patlayan gradyanları çözme yetenekleri nedeniyle görüntü tanıma ve sınıflandırma görevleri için oldukça popüler hale geldiği söylenebilir. Bin katmanlı bir ResNet'in şu an için pek pratik bir kullanımı bulunmamaktadır.

Aşağıdaki grafikler, düz bir ağı doğruluklarını artık bir ağıyla karşılaştırır. Artan katmanlarla birlikte 56 katmanlı düz bir ağı doğruluğunun ResNet'in doğruluğundan daha erken doymaya başladığını gösterir.



Şekil-5: Düz ağı ve artık ağı karşılaştırılması. Solda eğitim hatası, sağda ise sınav hatası örnek grafiği

Yukarıdaki çizimde, 56 katmanlı bir CNN'nin hem eğitim hem de sınav veri kümesinde 20 katmanlı bir CNN mimarisine göre daha fazla hata oranı verdiğini görebiliriz. 56 katmanlı CNN, ancak daha sonra daha yüksek eğitim hatası bulunmaktadır. Hata oranı üzerinde daha fazla analiz yaptıktan sonra araştırmacılar, bunun kaybolan/patlayan gradyan kaynaklı olduğunu sonucuna varmışlardır.

Geleneksel yöntemlerden farklı olarak, derin öğrenme tabanlı yöntemler, model eğitimi aşaması tamamlandıktan sonra doğrudan ve hızlı bir şekilde sonuç alabilir. Bu nedenle, derin öğrenme tabanlı yöntemlerin hesaplama karmaşıklığı çoğunlukla  $O(1)$ 'dir ve bu geleneksel ağ tabanlı sıkıştırılabilir algılama yönteminden çok daha küçüktür. Bu çalışmalar, derin öğrenmenin yalnızca sinyal kurtarmada iyi bir performans elde etmekle kalmayıp, aynı zamanda bu çerçeveyi kullanarak ağı yapısını yeniden yapılandırma yoluna

ışık tutan çıkarım adımlarında daha az zaman aldığını doğrulamaktadır.

## 2. Litaratür İncelemesi

İncelemelerde bulunduğumuz bazı benzer çalışmalara bakacak olursak; "Bacteria Classification using Image Processing and Residual Neural Network (ResNet) [19]" başlıklı çalışmada Residüel Sinir Ağı (ResNet) kullanarak Bakteri Sınıflandırması üzerine bir çalışma yapılmıştır. Görüntü işlemeye dayalı bu sınıflandırma da mikroorganizmaların tespiti, insan sağlığı ve yaşamını dikkate alarak yapılmış olup, daha hızlı eğitim süresi nedeniyle ResNet-50'yi kullanmışlardır. Görüntüleri belirli oranlardaki piksel boyutlarını ikiye katlayarak ve 679 görüntüden 33 sınıftan oluşan DIBAS veri kümesini kullanarak çalışmalarını gerçekleştirmişlerdir. Ayrıca çalışmalarında veri büyütme yaparak çıktı etiketlerini koruyan girdi dönüşümlerinden yararlanarak etiketli eğitim kümesinin hem boyutunu hem de çeşitliliğini artırmak için bu tekniği kullanmışlardır. "Deep Learning Approach for Classifying Bacteria types using Morphology of Bacterial Colony[20]" adlı çalışmada Bakteri Kolonisi Morfolojisini kullanarak 40 orijinal fotoğraftan türetilen 5000 artırılmış görüntüden oluşan bir eğitim kümesi kullanılarak üç bakteri kolonisinin sınıflandırılmasının en yüksek doğrulukla (%97:19) gerçekleştirilebileceğini doğrulamışlardır. Escherichia coli, Klebsiella pneumonia ve Staphylococcus aureus dahil olmak üzere üç bakteri türünün %92 'nin üzerinde bir sınıflandırma doğruluğu ve düşük kaynak kullanan beş modelden (ResNet50, Tuned VGG – 16, MobileNet, DS-CNN, DeepBacteria) üçü (ResNet50, Tuned VGG – 16, MobileNet) ile nasıl sınıflandırılacağını göstermişlerdir. "Fingerprint Classification Using Deep Neural Network Model Resnet50 [21]" başlıklı çalışmada ise FVC2004 Parmak İzi Görüntüleri Veri Tabanı kullanarak bir sınıflandırma gerçekleştirmişlerdir. Bu amaç için önceden eğitilmiş ImageNet ağırlıklarına sahip ResNet50 kullanılmışlardır. Modelin zaman açısından verimli olması nedeniyle parmak izi görüntülerini ön işleme tabi tutmadan eğitmişlerdir. 10 farklı parmak görüntüsünü 0-9 tek tip sınıfta ayırmışlardır. Her sınıfta aynı parmağın farklı izlere sahip 8 özel görüntüsünü eklemişler. Daha sonra görüntüleri 150x150 olarak yeniden boyutlandırıp tek bir sınıfta 480 görüntü elde etmek için bu 8 görüntüyü çoğaltmışlardır. Böylece, çoğunlukla 4800 görüntü veri kümesi düzenleyip, bunlardan 3840 görüntü DNN (ResNet50) görselini kurmak için ve 960 görüntü sınavı için almışlardır. ResNet50 modeli tarafından dikkate değer bir doğruluk elde ettiklerini söylemişlerdir. Daha iyi performans için modelin çok küçük veri tabanlarında ve farklı parametrelerle sınanıp edip, diğer veri tabanlarıyla da çalıştırılması gerektiğini vurgulamışlardır. "Bacterial Image Classification Using Convolutional Neural Networks [22]" başlıklı çalışmada ise hastalıkların teşhisi için bakterilerin sınıflandırılmasına yönelik bilgisayar destekli bir yaklaşım sunmuşlardır. Bu sınıflandırma problemi için derin öğrenme sinir ağını kullanmışlardır. Özellik çıkarma ve sınıflandırma için derin artık ağları (ResNet) yani ResNet-34 ve ResNet-50 modelleri gibi ResNet CNN modellerinin farklı varyantları kullanılmıştır. Modelin öğrenme oranı sunulmuş

ve doğrulama için karışıklık matrisini de sunmuşlardır. ResNet-50 CNN modelini kullanarak %99,9 doğrulukla yirmi bakteri kategorisini sınıflandırıp mevcut çalışmalardan bazıları ile yapılan karşılaştırmalarda, yaklaşımlarının daha iyi doğruluk sağladığını göstermişlerdir. "Deep Convolutional Neural Network for Microscopic Bacteria Images Classification [23]" adlı çalışmada Transfer öğrenmeye dayalı 'Xception mimarisi' ile insan için ölümcül olabilecek 7 bakteri çeşidi seçilmiş ve her çeşidin en az 160 görüntü içerdiği 1150 bakteri görüntüsünden oluşan bir veri kümesi hazırlanmıştır. Eğitim veri kümesinden 7 çeşit 920 bakteri görüntüsü üzerinde eğitilmiş olup daha sonra, sınav veri kümesinden 7 çeşitten 230 bakteri görüntüsü üzerinde performans değerlendirilmiş olup bakteri görüntüsü sınıflandırmasında yaklaşık %97,5 tahmin doğruluğu ile umut verici bir performans göstermektedir.

### 3. Araştırmamızda Kullandığımız Yapı ve Örnekler ve Elde Edilen Sonuçlar

Bakteriler hemen hemen her yerde bulunan tek hücreli organizmalardır: yerde, okyanusta, ellerinizde ve bağırsaklarınızda. Bazıları zararlı olsa da çoğu değildir ve hatta bazıları insan sağlığına faydalıdır [24].

İnsan vücudunda bulunan birçok bakteri türü vardır. Biz bu çalışmamızda bir insanın gözünde bulunan bazı bakteri türlerini inceleyeceğiz. Kullandığımız veri kümesi ImageNet'tir ve bu veri kümesini kullanarak ResNet-50 mimarisini değerlendirip elde ettiğimiz sonuçları size aktarmaya çalışacağız. Sistemimizde bazı bakteri türlerinden faydalanacağız. Bunların bir kısmı gözümüzde yaşamaktadır.


Gözümüzde yaşayan tüm mikroorganizma toplamını oluşturan 4 tane bakteri cinsi bulunmaktadır. Bunlar; Staphylococci, Diphtheroids, Propionibacteria ve Streptococci'dir. Sağlıklı insanların gözünde de ayrıca gözlerinin yüzeyinde bulunan TT virüsü de insanların gözleri yüzeyinin %65'ini kapsamaktadır. Gözümüzde yaşayan tüm bu mikroorganizmalar yaşımıza, ırkımıza, sosyal çevremize, yaşadığımız bölgeye, kullandığımız kontakt lense, hastalık durumumuza bağlı olarak değişmektedir [25].

Göz ile yapılmış çalışmalarda elde edilen bazı bakterilerin isimleri şunlardır.

- Staphylococcus
- Streptococcus
- Corynebacterium
- Propionibacterium
- Proteobacteria
- Acetobacteria
- Firmicatus
- Cyanobacteria
- Bacteroidetes
- Pseudomonas
- Klebsiella oxytoca

Yukarıda gözlerde bulunan bazı yararlı ve hastalık yapan bakterilerdir. Bizler de bu bakteri çeşitlerini kullanarak Artık ağ yapısını kullanarak sınıflandırmamızı yapacağız.

Yapacağımız sınıflandırma gözde bulunan bakteri türlerinin hangi bakteri çeşidine ait olduğunu bulmaktır. Araştırmamızda yaklaşık 689 bakteri görüntüsünü (internet ortamından alınan) kullanarak türünü ve adını ayırt edip sınıflandırmaya çalıştık. Bunun için görsellerimizi aynı ölçüde olmasına dikkat ettik. Araştırmamızda 200 x 200 luk resim skalasını kullandık. Doğrulama bölünmesini 0,2 olarak ayarladık çünkü bu sayede %80 ini eğitim için ayırmış olduk, %20 sini ise doğrulamayı kullanmak için ayırmış bulunuyoruz. Batch size ı 32 olarak belirledik. İlk başta eğitim alt kümesini oluşturmamız lazım. Alt kümemizi oluşturduktan sonra aldığımız çıktı aşağıdaki gibidir.



Şekil-6: Bakteri sınıflandırmamızdaki veri kümesinden elde ettiğimiz altı görüntümüz

Çizelge-1: Kullandığımız Resnet-50 için alacağımız 4 veri Modeli Örneği

Layer (type)	Output Shape	Param #
resnet50 (Functional)	(None, 2048)	23587712
flatten (Flatten)	(None, 2048)	0
dense (Dense)	(None, 512)	1049088
dense_1 (Dense)	(None, 5)	2565
Total params: 24,639,365		
Trainable params: 1,051,653		
Non-trainable params: 23,587,712		

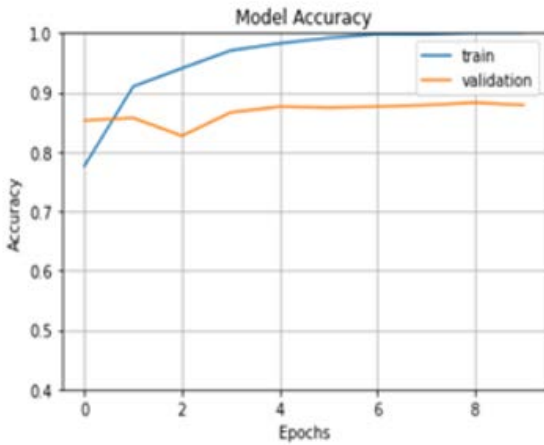
Burada kullandığımız veri kümemiz Resnet50 veri kümesidir. Dikkat etmemiz gereken kullandığımız artık ağ modeli (Resnet-50)'ye göre yaklaşık olarak 24,5 milyon küsur değer elde edilmiştir. Ancak eğitebildiğimiz kısım yaklaşık sadece 1 milyona küsur kısmıdır.

## 4. Tartışma ve Sonuçlar

Araştırmamızın amacı, döngüsel öğrenme oranı, veri büyütme ve transfer öğrenme kullanarak Resnet50 veri kümesinde bakteri görüntüsünden gözümüzde bulunan bakterileri sınıflandırmak için Resnet performanslarını uygulamak ve değerlendirmektir. Kullanılan eski sistemlerle karşılaştırıldığında doğruluk oranındaki artış ve gittikçe küçülen hata payıyla önceki sistemlere göre daha ileri düzey bir doğrulama elde edilmiştir.

Kullanmış olduğumuz veri kümesi Image-net ile araştırmanın en önemli sonuçlarından biri olarak tasarlanan yazılımın %83,33 doğruluk oranıyla bakteri resimlerini sınıflandırdığının gözlemlenmesidir. Bu sonuç, derin öğrenme yöntemlerinin görüntü sınıflandırma görevlerinde etkili bir şekilde kullanılabileceğini vurgulamaktadır. Özellikle bakteri sınıflandırma gibi biyomedikal uygulamalarda, bu tür tekniklerin sağladığı başarılar sağlık alanında da büyük olumlu etkilere sahip olabilir.

Bu çalışma, derin öğrenme yöntemlerinin ResNet modeli aracılığıyla görüntü sınıflandırma alanındaki başarısını vurgulamaktadır. Ancak, bu alandaki potansiyelin henüz tam olarak keşfedilmediğini ve gelecekte daha geniş veri kümeleri ve daha gelişmiş özellik mühendisliği tekniklerinin entegrasyonu ile daha da geliştirilebileceğini göstermektedir. Bu çalışmanın sonuçları, derin öğrenme ve görüntü işleme alanlarında ilerlemeyi teşvik etmektedir.



**Şekil-7:** Örnek sınıflandırmamız için baz aldığımız eğitim ve doğrulama doğruluğu modeli

Resnet 50 performans ölçümleri ve doğrulama değerleri yukarıda gösterilmiştir.

## 5. Yazar Katkı Beyanı

Gerçekleştirilen çalışmada Yazar fikrin oluşması, tasarımın yapılması ve literatür taraması, elde edilen sonuçların değerlendirilmesi, kullanılan malzemelerin temin edilmesi ve sonuçların incelenmesi başlıklarında ve yazım denetimi ve içerik açısından makalenin kontrol edilmesi başlıklarında katkı sunulmuştur.

## 6. Etik Kurulu Onayı ve Çıkar Çatışması Beyanı

Hazırlanan Makalede etik kurul izni alınmasına gerek yoktur. Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır.

## Kaynakça

- [1] Samudre, P, Shende, P, & Jaiswal, V. *Optimizing Performance of Convolutional Neural Network Using Computing Technique*. 2019 IEEE 5th International Conference for Convergence in Technology.2019, doi:10.1109/I2CT45611.2019.9033876
- [2] S. S.-S. a. S. Ben-David, *Understanding Machine Learning: From Theory to Algorithms*, New York, NY: Cambridge University Press, 2014, pp. 5-19.
- [3] T. M. Mitchell, *Machines Learning, McGraw-Hill Science/Engineering/Math*, 1997, pp. 2-8.
- [4] H. Daumé III, *A Course in Machine Learning, CIML License*, 2012, pp.51-60.
- [5] L. Wu, H. Zhou, X. Ma, J. Fan, and F. Zhang, *Daily reference evapotranspiration prediction based on hybridized extreme learning machine model with bio-inspired optimization algorithms: Application in contrasting climates of China*, J. Hydrol, vol. 577, Oct. 2019, Art. no. 123960. <https://doi.org/10.1016/j.jhydrol.2019.123960>
- [6] Goodfellow, I, Bengio, Y, Courville, A. *Deep learning (Vol. 1)Cambridge MIT press*, 2016 -326-366.<https://www.worldcat.org/title/deep-learning/oclc/1002916636>
- [7] Xing, Y, Zhao, Y, & Zhong, Y. (2020). *Design and Implementation of Mass Log Analysis Method Based on Deep Learning*. 2020 IEEE 9th Joint International Information Technology and Artificial Intelligence Conference. doi: 10.1109/ITAIC49862.2020.9339136
- [8] Dong, Y, & Liang, G. (2019). *Research and Discussion on Image Recognition and Classification Algorithm Based on Deep Learning*. 2019 International Conference on Machine Learning, Big Data and Business Intelligence.2019 doi: 10.1109/MLBDBI48998.2019.00061
- [9] Sharma, O. (2019). *Deep Challenges Associated with Deep Learning*. 2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing, doi:10.1109/COMITCon.2019.8862453
- [10] Dong, C, Loy, C.C, He, K. and Tang, X, 2014, September. *Learning a deep convolutional network for image super-resolution*.In European conference on computer vision (pp. 184-199). Springer,Cham, [https://doi.org/10.1007/978-3-319-10593-2\\_13](https://doi.org/10.1007/978-3-319-10593-2_13)
- [11] Min, S, Lee, B and Yoon, S, 2017. *Deep learning in bioinformatics. Briefings in bioinformatics*, 18(5), pp.851-869, <https://doi.org/10.1093/bib/bbw068>
- [12] Keke Huang a , Shuo Li a , Wenfeng Deng a , Zhaofei Yu b,c , Lei Ma c,d,(2021), *Structure inference of networked system with the synergy of deep residual network and fully connected layer network*, *The Official Journal of the International Neural Network Society*, European Neural Network Society & Japanese Neural Network Society, <https://doi.org/10.1016/j.neunet.2021.10.016>

- [13] A. Krizhevsky, I. Sutskever, and G. E. Hinton, *Imagenet classification with deep convolutional neural networks*, in *Advance*
- [14] Szegedy, Christian, et al. *Going deeper with convolutions*. Proceedings of the IEEE conference on computer vision and pattern recognition. 2015.
- [15] Dodge, Samuel, and Lina Karam. *Understanding how image quality affects deep neural networks*. Quality of Multimedia Experience (QoMEX), 2016 Eighth International Conference on. IEEE, 2016.
- [16] yu, C, Liu, Z, & Yu, L. (2019). *Block-sparsity recovery via recurrent neural network*. *Signal Processing*, 154, 129–135. <https://doi.org/10.1016/j.sigpro.2018.08.014>
- [17] Rahadian, R, & Suyanto, S. (2019). *Deep Residual Neural Network for Age Classification with Face Image*. 2019 International Seminar on Research of Information Technology and Intelligent Systems (ISRITI). doi:10.1109/ISRITI48646.2019.9034664
- [18] Lin Dong, Kohei Inoue (2021), *Super-resolution reconstruction based on two-stage residual neural network*, Department of Communication Design Science, Kyushu University, 4-9-1, Shiobaru, Minami-ku, Fukuoka, 815-8540, Japan. <https://doi.org/10.1016/j.mlwa.2021.100162>
- [19] Yılmaz, A., Karaca, A., Aydın, M. E., Arslan, M., & Özgür, U. (2023, August 22). *Bacteria classification using image processing and residual neural network (ResNet)*. *Journal of Biomedical Engineering and Informatics*, 1(1), 1-10.
- [20] Amano, M., Mai, D.-T., Sun, G., Vu, T. N., Hoi, L. T., Hoa, N. T., & Ishibashi, K. (2022, July). *Deep Learning Approach for Classifying Bacteria types using Morphology of Bacterial Colony*. In 2022 43rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) (pp. 2165-2168). IEEE.
- [21] Khan, M. A., Saleem, M. A., Ali, W., Sharif, M. S., & Akhtar, N. (2023, Haziran 20). *Fingerprint Classification Using Deep Neural Network Model Resnet50*. *International Journal of Advanced Computer Science and Applications*, 1(1), 1-6.
- [22] Sivaprasad, S., Ghosh, A., Kundu, S., & Ghosh, S. K. (2022, Mayıs 10). *Bacterial Image Classification Using Convolutional Neural Networks*. *Biomedical Signal Processing and Control*, 57, 1-10.
- [23] Zhang, Y., Liu, Y., Wang, Q., Zhang, H., & Ding, X. (2022, Nisan 20). *Deep Convolutional Neural Network for Microscopic Bacteria Images Classification*. *IEEE Transactions on Biomedical Engineering*, 69(4), 3024-3033.
- [24] Aparna Vidyasagar, Stephanie Pappas published October 14, 2021. *What are bacteria?*, <https://www.livescience.com/51641-bacteria.html>
- [25] Mahir E. (2019). *Gözümüzde Yaşayan Yararlı Bakteriler*, <https://bilimgenc.tubitak.gov.tr>