



ZEYTİN YAPRAĞINDAKİ HASTALIKLARIN SINIFLANDIRILMASINDA ÖN EĞİTİMLİ EVRIŞİMLİ SİNİR AĞLARININ PERFORMANSLARININ İNCELENMESİ

¹Bünyamin DİKİCİ , ²Mehmet Fatih BEKÇİOĞULLARI , ³Hakan AÇIKGÖZ ,
⁴Deniz KORKMAZ 

^{1,2,3}Gaziantep İslam Bilim ve Teknoloji Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektrik-Elektronik
Mühendisliği Bölümü, Gaziantep, TÜRKİYE

⁴Malatya Turgut Özal Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektrik-Elektronik Mühendisliği
Bölümü, Malatya, TÜRKİYE

¹bunyamin.dikici@gibtu.edu.tr, ²mehmetfatih.bekciogullari@gibtu.edu.tr, ³hakan.acikgoz@gibtu.edu.tr,

⁴deniz.korkmaz@ozal.edu.tr

ÖZ: Zeytin ülkemizin belirli bölgelerinde yetişen oldukça önemli bir üründür. Gümrük ve Ticaret Bakanlığı'nun verilerine göre 2019 yılında yaklaşık 420 bin ton sofralık zeytin üretimi ile dünyadaki toplam üretimin %14'ten fazlası ülkemizde yapılmıştır. Böylece, zeytin yaprağındaki hastalıkların erken teşhisi ve tedavisi üretim kapasitesinin artmasına yol açabilir. Günümüzde birçok alanda olduğu gibi bitki hastalıklarının teşhisi için derin öğrenme algoritmaları yaygın olarak kullanılmaktadır. Bu çalışmada, AlexNet, SqueezeNet, ShuffleNet ve GoogleNet gibi sıklıkla tercih edilen ön eğitilmiş derin öğrenme ağları ile zeytin yaprağındaki hastalıkların sınıflandırılması gerçekleştirilmiştir. Ağ yapıları, zeytin yaprağındaki hastalıkların etiketlerine göre eğitim için yeniden düzenlenmiştir. Veri setinde, veri çoğaltma işlemi uygulanarak hem ham veri seti hem de çoğaltılmış veri seti için ayrı ayrı performans sonuçları alınmıştır. Elde edilen sonuçlar doğruluk, duyarlılık, özgüllük, kesinlik ve F1-Skor gibi performans ölçütleri ile değerlendirilmiştir. En iyi performans iyileştirmesi %7,56 ile AlexNet'in doğruluk değeri için elde edilirken, en düşük iyileştirme oranı %0,63 ile ShuffleNet'in özgüllük değerinden elde edilmiştir.

Anahtar Kelimeler: Ön-eğitilmiş ağlar, Derin öğrenme, Hastalık sınıflandırma, Zeytin yaprağı

Performance Investigation of Pre-Trained Convolutional Neural Networks in Olive Leaf Disease Classification

ABSTRACT: Olive is a very significant crop grown in specific regions of our country. According to the data of the Ministry of Customs and Trade, with the production of approximately 420 thousand tons of table olives in 2019, more than 14% of the total production in the world was made in Turkey. Therefore, early diagnosis and treatment of diseases in olive leaves can lead to increased production capacity. Today, as in many fields, deep learning algorithms are widely used for the diagnosis of plant diseases. In this study, the classification of olive leaf diseases was carried out with the frequently preferred pre-trained deep learning networks such as AlexNet, SqueezeNet, ShuffleNet, and GoogleNet. In the data set, performance results were obtained for both the raw data set and the augmented data set by applying the data augmentation process. The obtained results were evaluated with the performance criteria as accuracy, sensitivity, specificity, precision, and F1-Score. While the best performance improvement was obtained for the accuracy value of AlexNet with 7.56%, the lowest improvement rate was obtained from the specificity value of ShuffleNet with 0.63%.

Keywords: Pre-trained networks, Deep learning, Disease classification, Olive leaf

GİRİŞ (INTRODUCTION)

Modern tarımsal teknolojiyle birlikte sınırlı miktarda olan tarımsal araziler ve su kaynakları 7 milyarı aşkın dünya nüfusuna yetecek yemek ihtiyacını karşılayabilmektedir (Mohanty ve diğ., 2016). Ancak, bu kaynakların bilinçsizce kullanılan kimyasal gübrelere ve zirai ilaçlara maruz kalması kirliliğe sebep olmaktadır. Bundan dolayı tarımsal üretimde elde edilen ürün kalitesi ile birlikte verim de azalmaktadır. Öte yandan, her geçen gün artan insan nüfusu ile orantılı olarak gıda ihtiyacı da artmaktadır. Bu yönüyle tarım konusu ülkelerin kendi ihtiyaçlarını karşılamada yeterliliği konusunda stratejik olarak önemli bir yere gelmiştir. Nitekim tarımsal üretimde verimliliği düşürdüğü bilinen zirai hastalıklar ile mücadelede günümüz teknolojisinin daha etkin kullanılması ürün verimliliğini pozitif yönde etkileyeceği düşünülmektedir. Bitkilerde görülen hastalıkların erken tespitinin yapılması ile yeterli miktarda ve etkin bir şekilde zirai ilaçlama programlarının yapılmasının önünü açacaktır. Bu durumun çevre kirliliğinin önüne geçilmesine ve ürün verimliliğinin artırılmasında olumlu katkı sağlaması düşünülmektedir.

Zeytin, ülkemizin özellikle batısında ve güneyinde önemli bir alanda yetiştirilmektedir (Erilmez ve Erkan, 2014). Bu bitkinin üretimini negatif yönde etkileyen bazı zirai hastalıkların teşhisinin erken ve ekonomik olarak yapılması gerekmektedir. Zeytin yaprağından hastalığın erken teşhisi ile ürün kalitesinin ve verimin artırılması hedeflenmektedir. Ülkemizin potansiyeli de göz önüne alındığında ilerleyen yıllarda bu alanda üretimde atılım yapabilmesi ve ekonomiye daha çok katkı sağlaması olasıdır.

Son yıllarda bilgisayar teknolojisinin gelişmesiyle birlikte bitki hastalıkları teşhisinde derin öğrenme tabanlı birçok çalışma yapılmıştır. Uğuz ve Uysal çalışmalarında zeytin yaprağı hastalığının sınıflandırılması için evrişimli sinir ağı (ESA) tabanlı bir model önermişlerdir. Türkiye’de zeytin bitkisinde yaygın olarak görülen iki ayrı hastalıklı yapraklardan oluşan görüntüler ile sağlıklı görüntülerin toplanmasıyla veri seti oluşturmuşlardır. Önerilen model VGG-16 ve VGG-19 yöntemleri ile karşılaştırılmıştır. Elde edilen görüntülere uygulanan farklı veri artırımı yöntemlerinin sınıflandırma performansına olumlu etki ettiği vurgulanmıştır. Ayrıca bu çalışmada farklı kayıp fonksiyon optimizasyon yöntemlerinin sınıflandırma sonucuna etkisi deneysel sonuçlar ile gösterilmiştir. Performans değerlendirme ölçütlerine göre önerilen model karşılaştırma yöntemlerine göre daha üstün sınıflandırma performansı göstermiştir (Uğuz ve Uysal, 2020). Uysal çalışmasında zeytin yaprağının üç farklı hastalığını önerdikleri ESA tabanlı bir yöntem ile sınıflandırmışlardır. Farklı optimizasyon algoritmaları ile farklı iterasyon sayılarının sınıflandırmaya etkisi araştırılmıştır. Yapılan tez çalışmasında veri artırımı işlemi uygulandığında önerilen modelin en iyi sınıflandırma performansı sergilediği deneysel sonuçlar ile gösterilmiştir (Uysal, 2020). Korkut ve arkadaşları çalışmalarında bitki yapraklarındaki hastalığın tespiti için destek vektör makinası (DVM) tabanlı bir makine öğrenmesi yöntemi kullanmışlardır. Birçok bitkinin hastalıklı ve sağlıklı fotoğraflarından veri seti oluşturulmuştur. Oluşturulan veri setinin özellik çıkarımı yapılmıştır. Daha sonra önerilen modelden ve karşılaştırma metodu olarak kullanılan farklı yöntemlerden sağlıklı ve hastalıklı olmak üzere iki kategoride sınıflandırma işlemi yapılmıştır. Sınıflandırma problemlerinde yaygın olarak kullanılan performans metrik değerlendirme sonuçlarına göre önerilen makine öğrenmesi modeli ve karşılaştırma metodlarından bir tanesi olan lojistik regresyon algoritması iyi sonuçlar vermiştir (Korkut ve diğ., 2018). Liu ve arkadaşları çalışmalarında elma yaprağının dört farklı hastalığı için sınıflandırma konusunda ESA tabanlı bir yöntem önermişlerdir. Oluşturdukları veri setini artırmak için elde ettikleri fotoğrafları 90 ile 270 derece arasında döndürerek üç kat artırmışlardır. Önerdikleri modelin sınıflandırma performansı farklı makine öğrenmesi ve derin öğrenme metodları ile karşılaştırılmıştır. Elde edilen performans değerlendirme sonuçları sınıflandırma konusunda önerilen derin öğrenme modelinin karşılaştırma metodlarından daha üstün olduğunu ortaya koymuştur (Liu ve diğ., 2018). Türkoğlu ve arkadaşları çalışmalarında çoğunlukla Malatya ili ve çevresinde rastlanan kayısı meyvelerinde bulunan hastalıkların sınıflandırılması amacıyla ESA tabanlı bir derin öğrenme metodu önermişlerdir. Kayısı meyvesinde yaygın olarak görüldüğü belirtilen dört farklı hastalık ile veri seti oluşturulmuştur. 18 katman ve çeşitli evrişim filtrelerinden oluşan önerilen ESA modeli ile deneysel sonuçlar alınmıştır. Ayrıca sınıflandırma problemleri konusunda yaygın olarak kullanılan AlexNet ve SqueezeNet gibi ESA temelli modeller karşılaştırma yöntemleri olarak kullanılmıştır. Elde edilen sonuçlar önerilen derin öğrenme modelinin

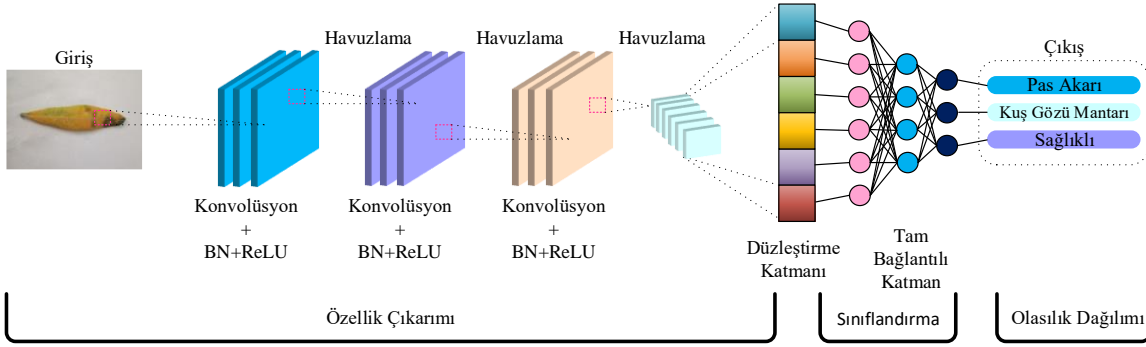
kayıp hastalıklarının sınıflandırılmasında daha üstün başarı sağladığı belirtilmiştir (Türkoğlu ve diğ., 2020). Geetharamani ve Pandian çalışmalarında domates, patates ve kiraz gibi 39 farklı bitkilerin hastalıklı ve sağlıklı yapraklarından elde ettikleri veri setinin sınıflandırılmasında dokuz katmanlı olarak geliştirdikleri ESA modelini önermişlerdir. Veri setinde görüntülerin artırılması için ise altı farklı yöntem uygulanmıştır. Yapılan çalışmada sağlıklı ve hastalıklı olmaz üzere iki sınıflandırma bulunmaktadır. Makine öğrenmesi temelli modeller karşılaştırma yöntemleri olarak kullanılmıştır. Deneysel sonuçlar veri artırma yönteminin sınıflandırma problemi sonuçlarına pozitif yönde etki ettiğini göstermiştir. Ayrıca önerilen modelin bu problemin çözümünde makine öğrenmesi temelli sınıflandırma yöntemlerinden çok daha üstün olduğunu göstermiştir (Geetharamani ve ArunPandian, 2019). Upadhyay ve Kumar çalışmalarında çeltik bitkisinin yapraklarında görülen hastalıkların sınıflandırılması amacıyla derin öğrenme tabanlı bir ESA yöntemi önerilmiştir. Veri seti olarak sağlıklı çeltik yaprakları ve üç ayrı hastalıklı yaprakların görüntüleri toplanmıştır. Dört ayrı sınıftan oluşan problemin çözümünde önerilen yöntemin başarılı olduğu performans metrik sonuçları ile ortaya konulmuştur (Upadhyay ve Kumar, 2021). Jadhav ve arkadaşları çalışmalarında bezelye bitkisinin yapraklarında görülen hastalıkların sınıflandırılmasında derin öğrenme tabanlı önceden eğitilmiş modeller olan AlexNet ve GoogleNet modellerini önermişlerdir. Üç farklı hastalık ile sağlıklı yaprak görüntülerinden oluşan veri seti toplanmıştır. Deneysel çalışmalar önerilen derin öğrenme modellerinin makine öğrenmesi modellerinden daha üstün sınıflandırma performansı gösterdiği belirtilmiştir (Jadhav ve diğ., 2021). Pawar ve arkadaşları çalışmalarında salatalık bitkisinin yapraklarında görülen hastalıklarında sınıflandırılmasında yapay sinir ağı (YSA) tabanlı bir yöntem önermişlerdir. Salatalık yapraklarında görülen iki farklı hastalık ile sağlıklı yapraklardan elde ettikleri görüntüler ile veri seti oluşturulmuştur. Görüntülere özellik çıkarma uygulanmıştır. Öncelikle önerilen modelin test aşamasında yaprağın hastalıklı veya sağlıklı olduğuna karar verdiği belirtilmiştir. Eğer yaprak sağlıklı değil ise hastalığının sınıflandırılmasının yapıldığı ikinci aşama bulunmaktadır. Performans değerlendirme sonuçlarına göre önerilen model salatalık yapraklarının sınıflandırılmasında %80.45 doğruluk başarıları göstermiştir (Pawar ve diğ., 2016).

Bu çalışmada, zeytin yaprağındaki hastalıkların teşhisi ve sınıflandırılması için derin öğrenme algoritmalarının performansları incelenmiştir. Ağ yapıları için literatürde sıklıkla kullanılan ön eğitimli AlexNet, GoogleNet, ShuffleNet ve SqueezeNet ağları seçilmiştir. Çalışmalarda zeytin yaprağındaki hastalıkları kapsayan halka açık bir veri seti kullanılmıştır. Veri setindeki görüntü sayısının az olmasından dolayı ağ performanslarını artırmak için orijinal veri setinde veri çoğaltma işlemi gerçekleştirilmiştir. Daha sonra, deneysel çalışmalar için eğitim ve test verileri hazırlanmıştır. Ön eğitimli derin öğrenme yöntemlerinin her biri için deneysel çalışmalar yapılarak sonuçlar performans değerlendirme ölçütleri ile analiz edilmiştir. Elde edilen sonuçlar ışığında ön eğitimli derin öğrenme yöntemlerinin performansları değerlendirilmiş ve en iyi sınıflandırıcı ağ yapısı belirlenmiştir.

Çalışmanın diğer kısımları ise şu şekilde organize edilmiştir. Ön eğitimli derin öğrenme yöntemlerinin genel özellikleri 2. kısımda detaylı bir şekilde sunulmuştur. 3. kısımda veri çoğaltma işlemi hakkında genel bilgiler verilmiştir. 4. kısımda deneysel çalışmalar gerçekleştirilmiştir. Bu çalışmadan elde edilen sonuçlar ise 5. kısımda değerlendirilmiştir.

EVRIŞİMLİ SİNİR AĞLARININ ÖZELLİKLERİ (FEATURES OF CONVOLUTIONAL NEURAL NETWORKS)

Yapay zekânın alt kolu olarak görülen derin öğrenme günümüzde oldukça önemli bir yere sahiptir. Yapay zekâ kışı olarak adlandırılan ve yapay zekânın üzerindeki ilgisini kaybettiği dönemlerden sonra, gelişen teknoloji ve veri sayısının artmasıyla 2010'lu yılların başında tekrar oldukça popüler bir hal almaya başlamıştır (Floridi, 2020). Bu ilginin en büyük etkenlerinden biri ise oldukça başarılı performans sonuçları veren ESA modelleridir. ESA yapıları, en az bir katmanında matematiksel bir işlem olan konvolüsyonun kullanıldığı çok katmanlı bir YSA olarak ele alınabilir. Konvolüsyon katmanının dışında doğrusal olmayan, havuzlama, düzleştirme katmanları ve son olarak YSA ile aynı işleve sahip olan tam bağlantılı katman bulunmaktadır (Albawi ve diğ., 2017). Şekil 1'de örnek bir ESA yapısı gösterilmiştir.



Şekil 1: Evrişimli sinir ağına ait mimari

Figure 1: An architecture of convolutional neural network



Şekil 2: Ön-egitimli evrişimli sinir ağlarının katmanları

Figure 2: Layers of pre-trained convolutional neural network

Özellik çıkarımı için konvolüsyon ve havuzlama katmanları kullanılmaktadır. Bu kısımda kullanılan filtreler yardımıyla görüntüye ait önemli bilgiler içeren pikseller ön plana çıkarılarak görüntüdeki gereksiz bilgiler atılmaktadır. Seçilen filtrelerin giriş resmini yatayda ve dikeyde tamamen taraması sonucunda özellik haritası ortaya çıkmaktadır. Havuzlama katmanında da yine boyutsal bir azalma söz konusudur. Bu sayede parametre sayısı ve hesaplama maliyeti azaltılabilir. Maksimum havuzlama en sık tercih edilen havuzlama metodudur (O'Shea ve Nash, 2015).

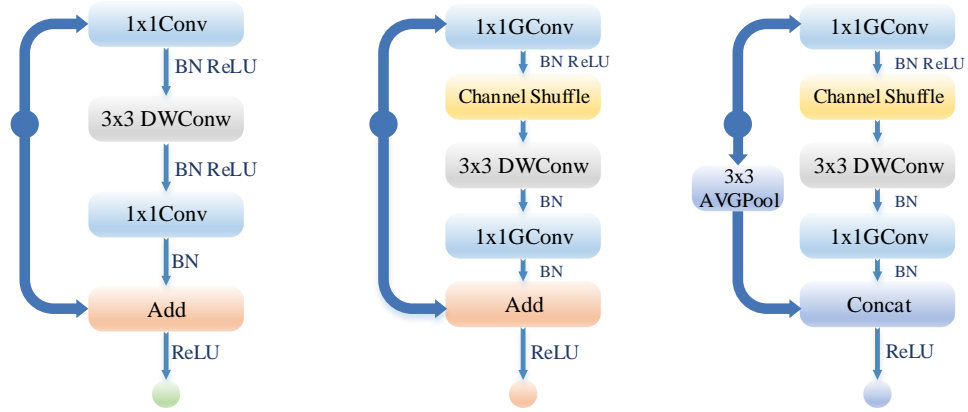
2006 yılında oluşturulan, yaklaşık 15 milyon yüksek çözünürlüklü görüntü ve 22 bin sınıf bulduran ImageNet veri seti ile ilk defa 2010'da düzenlenen ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'nda (ILSVRC) kullanılmıştır (Deng ve diğ.,2009). İlk iki yıl kullanılan makine öğrenmesi metodlarının ardından, 2012 yılında AlexNet derin öğrenme ağı kullanılmıştır. AlexNet ile hata oranını yüzde 26'dan yüzde 15'e düşürülmüştür. Bu başarının ardından derin öğrenme modelleri büyük bir ivme ile yükselişe geçmiştir ve ilerleyen yıllarda ShuffleNet, SqueezeNet ve GoogleNet gibi ağlar da yarışmada önemli derecelere elde etmiştir. Şekil 2'de bu çalışmada kullanılan ShuffleNet, SqueezeNet, AlexNet ve GoogleNet ağlarının katmanları görsel olarak sunulmuştur. Ayrıca, Çizelge 1'de çalışmada kullanılan derin öğrenme modellerinin ağ yapıları verilmiştir.

Çizelge 1: Çalışmada kullanılan ön eğitimli modellerin ağ yapıları

Table 1: Network structures of the pre-trained models used in this study

Method	Giriş Boyutu	Filtre Boyutu	Kaydırma Adımı	Katman Sayısı	Toplam Ağırlık
GoogleNet	224x224	1, 3, 5, 7	1,2	22	7M
ShuffleNet	224x224	3, 7	1,2	50	1.4M
SqueezeNet	227x227	1, 3, 7, 13	1,2	18	1.24M
AlexNet	227x227	3, 5, 11	1,4	8	61M

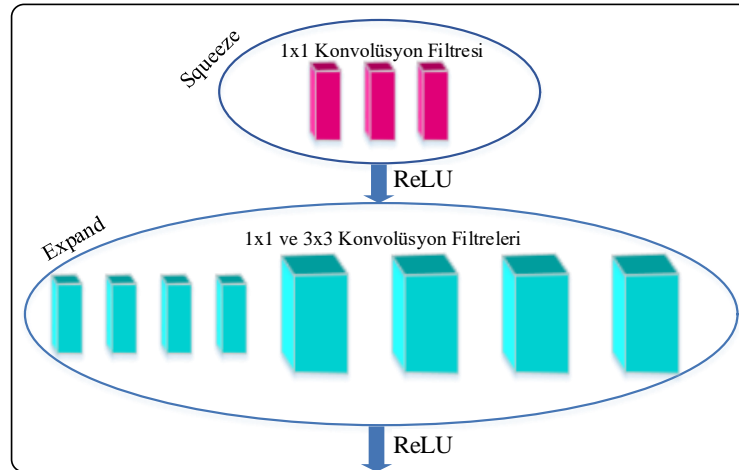
AlexNet, 2012 ILSVRC' de gösterdiği başarı ile ESA'nın yeniden popülerleşmesinde öncü bir rol üstlenmiştir. Bu ağın yapısında beşi konvolüsyon katmanı ve üçü tam bağlantılı katman olmak üzere toplam sekiz adet katman bulunmaktadır. Ayrıca tanh yerine ReLU fonksiyonu kullanarak daha hızlı bir model elde edilmiştir. Kullanılan düğüm seyreltme katmanı sayesinde aşırı öğrenmenin de önüne geçilmiştir. Modelde üç tane de havuzlama katmanı bulunmaktadır. Bu katman için maksimum havuzlama metodu kullanılmıştır (Krizhevsky ve diğ., 2012).



Şekil 3: ShuffleNet'in iç yapısı (Zhang ve diğ., 2018)

Figure 3: Internal structure of ShuffleNet

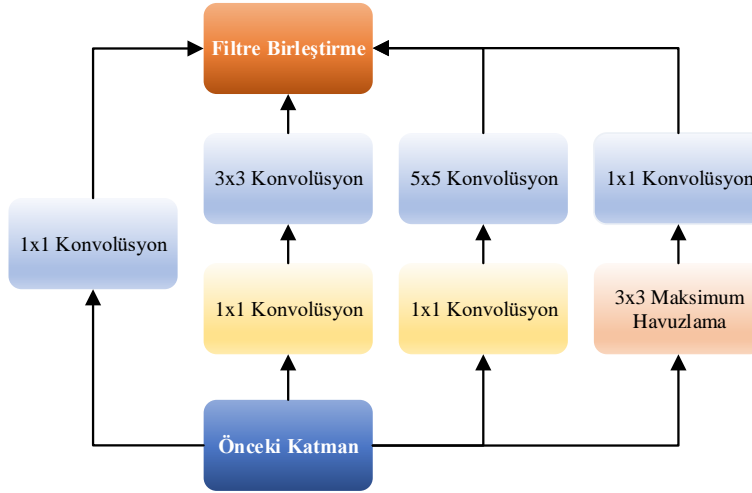
ShuffleNet 2017 yılında sunulmuştur. Bu model elli adet katman içeren dar boğaz yapısına sahip artık bir yapıdır. Diğer modellerle karşılaştırıldığında daha az parametre ve karmaşıklığa sahiptir. Bu sebeple daha çok düşük güçlü mobil cihazlar için de uygun bir model olarak düşünülebilir (Zhang ve diğ., 2018). Şekil 3'de ShuffleNet'in iç yapısı gösterilmiştir.



Şekil 4: SqueezeNet'in fire bölümlerinin genel gösterimi (Iandola ve diğ., 2016)

Figure 4: General view of Fire parts of SqueezeNet

SqueezeNet modeli ise 2016 yılında ortaya çıkmıştır. Bu ağ toplam on sekiz adet katman içermektedir. İlk ve son tabakası konvolüsyon katmanırken sekiz adet de ateşleme (fire) katmanı içermektedir. AlexNet'e kıyasla 50 kat daha küçük toplam ağırlık sayısına ve 31 kat daha yüksek hıza sahiptir. Bu yapı ile küçük ağı modelleri oluşturulabildiğinden, mobil ya da gömülü sistemlere kolaylıkla entegre edilebilmektedir (Iandola ve diğ., 2016). Şekil 4'de, "fire" olarak belirtilen SqueezeNet modelinin içyapısı verilmiştir.



Şekil 5: Başlangıç modülünün içyapısı (Szegedy ve diğ., 2015)


















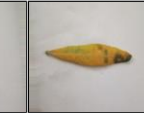
Figure 5: The internal structure of inception module

Çalışmada kullanılan diğer bir ön eğitilmiş derin öğrenme ağı GoogleNet, yirmi iki adet katmana sahiptir. Bu modelde bulunan başlangıç modülleri sebebiyle karmaşık sayılabilecek bir mimariye sahiptir. Başlangıç modülleri sayesinde art arda konvolüsyon ve havuzlama katmanları sıralanıp, onlara filtre uygulanmamıştır. Bunun yerine ağırlıklı olarak birbirine paralel bağlı birkaç katman grubundan oluşmaktadır. Bu sayede hesaplama ve bellek maliyeti aşağı çekilmiştir ve aşırı öğrenmenin de önüne geçilmiştir. 2014 yılında %5,7 hata oranı ile ILSVRC'de oldukça iyi sonuçlar elde etmiştir (Szegedy ve diğ., 2015). Başlangıç modüllerine ait yapı ise Şekil 5'de gösterilmiştir.

VERİ ÇOĞALTMA YAKLAŞIMI (DATA AUGMENTATION APPROACH)

Oluşturulan herhangi bir derin öğrenme modelinin iyi eğitilmesi, bu algoritmalar için oldukça kritik bir öneme sahiptir. Eğitim aşamasının başarılı bir biçimde gerçekleşebilmesi için veri setinin yeterince zengin örneklerle sahip olması gerekmektedir. Veri setindeki görüntü sayısı arttıkça geliştirilen ağ modeli daha iyi eğitilebilecek ve test aşamasında daha yüksek performans sonuçları elde edebilecektir. Öte yandan, veri setindeki sınıflarda eşit sayıda görüntü bulunması genelde mümkün olmamaktadır ve sınıfların sahip olduğu görüntü sayılarında miktar bakımından dengesizlikler olabilir. Ancak, model eğitilirken her sınıf için eşit miktarda görüntü kullanılması da ağın performansını artıran unsurlardan biridir (Buda ve diğ., 2018). Bu sebeple, veri setindeki sınıflar arasındaki dengesizliği gidermek ve daha fazla görüntü verisi elde etmek için veri çoğaltma yöntemi kullanmak oldukça etkili sonuçlar verebilir (Bloice ve diğ., 2017). Bu metod, çevrim içi ya da çevrim dışı olmak üzere iki şekilde uygulanabilmektedir. Çevrim içi olarak uygulandığında elde edilen görüntüler diske kaydedilmezken, çevrim dışı olarak uygulandığında ortaya çıkan görüntüler diske kaydedilmektedir. Ayrıca, çevrim içi veri artırma modeli kullanıldığında, her döngüde farklı görüntüler görülecektir. Çevrim dışında ise, elde edilen görüntüler eğitim setinin bir parçası olacaktır. Bu yüzden görüntüler döngü sayısına bağlı olarak ağ tarafından birçok kez görüntülenecektir (Shorten ve Khoshgoftaar, 2019).

Bu çalışmada çevrim dışı veri çoğaltma metodu kullanılmıştır. Gerçekleştirilen deneysel çalışmalarda, halka açık bir veri seti kullanılmıştır (https://github.com/sinanuguz/CNN_olive_dataset). Orijinal veri setindeki görüntülere; aynalama/yansıtma, bulanıklaştırma, döndürme, kesme-kaydırma işlemleri uygulanarak veri setinin genişletilmesi amacıyla veri çoğaltma yöntemi uygulanmıştır. Bu yöntem kullanılarak veri setindeki her bir görüntü için beş adet yapay görüntü daha elde edilmiştir. Böylece, başlangıçta 3300 olan görüntü sayısı 16500 adet artırılarak 19800'e çıkarılmıştır. Şekil 6'da her bir sınıftan seçilen örnek görüntü ile çoğaltma yöntemi sonucunda artırılmış görüntüler sunulmuştur.

		VERİ ÇOĞALTMA YÖNTEMLERİ					
		Orijinal Görüntü	Aynalama	Bulanıklaştırma	Döndürme	Soldan Kesme	Sağdan Kesme
HASTALIK	Sağlıklı						
	Pas Akarı						
	Kuş Gözü Mantarı						

Şekil 6: Veri çoğaltma örnekleri

Figure 6: Examples of data augmentation

Sonuç olarak ham veri setine veri çoğaltma işleminin uygulanmasıyla birlikte, miktar olarak altı kat daha büyük bir veri seti elde edilmiştir. Kullanılan modellerin performans sonuçları her iki veri seti için de ayrı ayrı elde edilmiş ve sonuçlar devam eden bölümde sunulmuştur.

DENEYSEL ÇALIŞMALAR (EXPERIMENTAL STUDIES)

Bu bölümde, ön eğitimli ağların, zeytin yaprağındaki hastalıkların teşhisindeki sınıflandırma performanslarını analiz edebilmek için kıyaslama çalışmaları gerçekleştirilmiştir. Bunun için doğruluk, duyarlılık, kesinlik, özgüllük ve F1-Skor gibi değerlendirme ölçütleri hata matrisi yardımıyla elde edilmiştir. Doğruluk, doğru tahmin edilen örneklem sayısının veri setindeki tüm örneklem sayısına oranıdır. Duyarlılık, doğru tahmin edilen hastalıklı örneklem sayısının gerçekte hastalıklı olan tüm örneklem sayısına oranıdır. Kesinlik, doğru tahmin edilen hastalıklı örneklem sayısının hastalıklı olarak tahmin edilen toplam örneklem sayısına oranıdır. Özgüllük, doğru tahmin edilen hastalık olmayan örneklem sayısının gerçekte hastalık olmayan tüm örneklem sayısına oranıdır. F1-Skor ise duyarlılık ve kesinlik parametrelerinin ağırlıklı ortalamasıdır. Eğer veri setini oluşturan örneklem dengersiz dağılmış ise tercih edilmektedir. Belirtilen bu değerlendirme ölçütleri aşağıdaki formüllerle ifade edilebilir (Darwish ve diğ., 2019; Deepak ve Ameer,2019).

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (1)$$


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

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

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (4)$$

$$F1 - \text{Skor} = 2 * \frac{\text{Duyarlılık} * \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (5)$$

Yukarıda verilen denklemlerde doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif DP, DN, YP ve YN olarak simgelenmiştir. DP, gerçekte pozitif sınıfta yer alan ve doğru tahmin edilen sayısı ifade etmektedir. DN, gerçekte negatif sınıfta yer alan ve doğru tahmin edilen sayısı ifade etmektedir. YN, gerçekte pozitif sınıfta yer alan ve yanlış tahmin edilen sayısı ifade etmektedir. YP, gerçekte negatif sınıfta yer alan ve yanlış tahmin edilen sayısı ifade etmektedir.



Şekil 7: Eğitim ve kayıp eğrileri

Figure 7: Training and loss graphs


DeneySEL çalışmalar, Intel (R) i7-10750H CPU @2.60 GHz, NVIDIA Quadro P620 GPU ve 16 GB RAM belleğe sahip bir iş istasyonu kullanılarak Matlab R2020a ortamında gerçekleştirilmiştir. Sonuçlar, ham veri seti ile çoğaltılmış veri seti analizleri olmak üzere iki kısma ayrılmıştır. İlk olarak ham veri seti üzerinde karşılaştırmalar yapılmıştır. Ham veri setinde pas akarı, kuş gözü mantarı ve sağlıklı olarak sınıflandırılan örneklerden sırasıyla 890, 950 ve 1460 görüntü bulunmaktadır. Veri setini dengeli bir hale getirmek için en az sayıdaki görüntüden oluşan pas akarı sınıfındaki örnek sayısına diğer sınıfların sayısı eşitlenmiştir.

Şekil 7’de her bir derin öğrenme modeli için eğitim ve kayıp eğrileri verilmiştir. Eğitim sonucunda AlexNet, GoogLeNet, ShuffleNet ve SqueezeNet için kayıp değerleri sırasıyla $3.51e-5$, $9.61e-7$, $1.2e-5$ ve $1.16e-7$ değerlerine ulaşmıştır. Çizelge 2’de ise her bir modelin eğitim ve test süreleri verilmiştir. Burada, SqueezeNet en 115.44dk ile en düşük eğitim süresine sahip iken GoogLeNet 257.85dk ile en yüksek eğitim süresini vermiştir. Ayrıca, AlexNet bir görüntü için 0.00309sn ile en hızlı test performansını sağlamıştır.

Çizelge 2: Derin öğrenme modellerinin eğitim ve test süreleri

Table 3: Training and test times of the deep learning models

Model	Eğitim Süresi (dk)	Test Süresi (sn)
AlexNet	120.61	0.00309
SqueezeNet	115.44	0.00374
ShuffleNet	231.68	0.00524
GoogleNet	257.85	0.00670



Şekil 8: Ham veri setinden elde edilen hata matrisi

Figure 8: Confusion matrix obtained from raw dataset

DeneySEL çalışmalarından elde edilen hata matrisi her bir model için ayrı ayrı Şekil 8’de sunulmuştur. Ayrıca, performans değerlendirme ölçütlerinin sayısal değerleri Çizelge 3’de verilmiştir. Çizelge 3’den de görüleceği üzere ShuffleNet tüm performans metriklerinde en iyi sonuçları sağlamaktadır. ShuffleNet’ in ortalama doğruluk, duyarlılık, özgüllük, kesinlik ve F1-Skor ölçütlerindeki değerleri sırasıyla %98.51, %98.51, %99.25, %98.52 ve %98.51 olarak hesaplanmıştır. İkinci en iyi sonuçları ise kuş gözü mantarında doğruluk için %99.25, duyarlılık için %99.25, özgüllük için %99.25, kesinlik için %98.51 ve F1-Skor için %98.88 değerlere sahip GoogleNet sağlamıştır. GoogleNet diğer sınıflarda da yine en iyi ikinci performansı göstermiştir. Bu dENEYSel çalışmada tüm performans değerlendirme ölçütlerinde en düşük sınıflandırma sonuçlarını AlexNet göstermiştir. AlexNet’ in sırasıyla doğruluk, duyarlılık, özgüllük, kesinlik ve F1-Skor ölçütlerindeki ortalama değerleri ise %92.04, %92.04, %96.02, %92.12 ve %92.05’dir.

Çizelge 3: Ham veri setinden elde edilen değerlendirme ölçütlerinin karşılaştırılması*Table 3: Comparison of performance metric results obtained from the raw dataset*

Model	Hastalık	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1-Skor
AlexNet	Kuş Gözü Mantarı	0.9402	0.9402	0.97014	0.94029	0.94029
	Sağlıklı	0.9253	0.9253	0.94029	0.88571	0.90510
	Pas Akarı	0.8955	0.8955	0.97014	0.93750	0.91603
	Ortalama	0.9204	0.9204	0.9602	0.9212	0.9205
GoogleNet	Kuş Gözü Mantarı	0.9925	0.9925	0.9925	0.9851	0.9888
	Sağlıklı	0.9701	0.9701	0.9962	0.9923	0.9811
	Pas Akarı	0.9776	0.9776	0.9813	0.9632	0.9703
	Ortalama	0.9801	0.9801	0.9900	0.9803	0.9801
ShuffleNet	Kuş Gözü Mantarı	0.9925	0.9925	0.9888	0.9779	0.9851
	Sağlıklı	0.9925	0.9925	0.9925	0.9851	0.9888
	Pas Akarı	0.9701	0.9701	0.9962	0.9923	0.9811
	Ortalama	0.9851	0.9851	0.9925	0.9852	0.9851
SqueezeNet	Kuş Gözü Mantarı	0.9477	0.9477	0.9776	0.9548	0.9513
	Sağlıklı	0.9776	0.9776	0.9776	0.9562	0.9667
	Pas Akarı	0.9552	0.9552	0.9850	0.9696	0.9624
	Ortalama	0.9602	0.9602	0.9801	0.9603	0.9602

**Şekil 9:** Çoğaltılmış veri setinden elde edilen hata matrisi*Figure 9: Error matrix from the augmented dataset*

İkinci aşamada, her bir hastalık türündeki örnekler için veri çoğaltma işlemi gerçekleştirilmiştir. Her hastalıktaki bir görüntüye aynalama/yansıtma, bulanıklaştırma, döndürme, kesme-kaydırma işlemleri uygulanarak örnek sayısı artırılmıştır. Böylece veri setindeki toplam görüntü 19800 olarak elde edilmiştir. Deneysel çalışmalardan elde edilen hata matrisi her bir model için Şekil 9'da sunulmuştur.

Çizelge 4: Çoğaltılmış veri setinden elde edilen değerlendirme ölçütlerinin karşılaştırılması

Table 4: Comparison of performance metric results obtained from the augmented dataset

Model	Hastalık	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1-Skor
AlexNet	Kuş Gözü Mantarı	0.9925	0.9925	0.9950	0.9900	0.99127
	Sağlıklı	0.9887	0.9887	0.9943	0.9887	0.98876
	Pas Akarı	0.9887	0.9887	0.9956	0.9912	0.99000
	Ortalama	0.9900	0.9900	0.9950	0.9900	0.9900
GoogleNet	Kuş Gözü Mantarı	0.9975	0.9975	0.9988	0.9975	0.9975
	Sağlıklı	0.9988	0.9988	0.9988	0.9975	0.9981
	Pas Akarı	0.9963	0.9963	0.9988	0.9975	0.9969
	Ortalama	0.9975	0.9975	0.9988	0.9975	0.9975
ShuffleNet	Kuş Gözü Mantarı	0.9975	0.9975	0.9988	0.9975	0.9975
	Sağlıklı	0.9963	0.9963	0.9988	0.9975	0.9969
	Pas Akarı	0.9988	0.9988	0.9988	0.9975	0.9981
	Ortalama	0.9975	0.9975	0.9988	0.9975	0.9975
SqueezeNet	Kuş Gözü Mantarı	1	1	0.9993	0.9987	0.9993
	Sağlıklı	0.9962	0.9962	0.9993	0.9987	0.9975
	Pas Akarı	0.9987	0.9987	0.9987	0.9975	0.9981
	Ortalama	0.9983	0.9983	0.9992	0.9983	0.9983

Çizelge 5: Ön eğitimli ağların iyileştirme sonuçları

Table 5: Improvement results of pre-trained networks

Model	Performans Ölçütü	İyileştirme Oranı (%)
AlexNet	Doğruluk	7,56
	Duyarlılık	7,56
	Özgüllük	3,62
	Kesinlik	7,47
	F1-Skor	7,55
GoogleNet	Doğruluk	1,78
	Duyarlılık	1,78
	Özgüllük	0,88
	Kesinlik	1,75
	F1-Skor	1,78
ShuffleNet	Doğruluk	1,26
	Duyarlılık	1,26
	Özgüllük	0,63
	Kesinlik	1,25
	F1-Skor	1,26
SqueezeNet	Doğruluk	3,97
	Duyarlılık	3,97
	Özgüllük	1,95
	Kesinlik	3,96
	F1-Skor	3,97

Veri çoğalta sonucu elde edilen performans değerlendirme ölçütlerinin sayısal değerleri Çizelge 4’de verilmiştir. Çizelge 4’de görüldüğü üzere veri çoğaltma işleminin ardından en iyi performans sonucu SqueezeNet ile elde edilmiştir. SqueezeNet’in ortalama doğruluk, duyarlılık, özgüllük, kesinlik ve F1-Skor ölçütlerindeki değerleri sırasıyla %99.83, %99.83, %99.92, %99.83 ve %99.83 olarak hesaplanmıştır. GoogleNet ve ShuffleNet birbirine oldukça yakın sonuçlar vermiştir. GoogleNet’in pas akarı sınıfındaki doğruluk, duyarlılık, özgüllük, kesinlik ve F1-Skor ölçütlerindeki değerleri sırasıyla %99.63, %99.63, %99.88, %99.75 ve %99.69 iken, ShuffleNet için bu değerler sırasıyla %99.88, %99.88, %99.88, %99.75 ve

%99.81'dir. AlexNet veri çoğaltma işleminden sonra ortalama doğruluk, duyarlılık, özgüllük, kesinlik ve F1-Skor değerleri sırasıyla %99.00, %99.00, %99.50, %99.00, %99.00 olarak elde edilmiştir.

Yapılan veri artırma işleminden sonra derin öğrenme modelleri daha fazla görüntü ile eğitilmiştir. Bunun sonucunda, her bir model yönteminin performans metrik ölçütlerindeki sayısal değerlerde iyileşme olduğu görülmüştür. Bu iyileştirme sonuçları Çizelge 5'de detaylıca sunulmuştur. Çizelge 5'e göre veri artırma işlemi ile AlexNet'in değerlendirme ölçütlerinde doğruluk için %7.56, duyarlılık için %7.56, özgüllük için %3.62, kesinlik %7.47 ve F1-Skor için %7.55'lik bir artışın olduğu görülmektedir. Bu değerler GoogleNet için sırasıyla %1.78, %1.78, %0.88, %1.75 ve %1.78 olarak elde edilmiştir. ShuffleNet ve SqueezeNet için ise doğrulukta %1.26-%3.97, duyarlılıkta %1.26-%3.97, özgüllükte %0.63-%1.95, kesinlikte %1.25-%3.96 ve F1-Skorda %1.26-%3.97 olarak iyileştirme yüzdeleri hesaplanmıştır

SONUÇLAR (RESULTS)

Bu çalışmada, zeytin yaprağındaki hastalıkların teşhisi ve sınıflandırılması gerçekleştirilmiştir. Veri setinde bulunan her hastalık sınıfındaki örnekler veri çoğaltma yöntemi ile artırılmıştır. Böylece daha fazla sayıda örnekten oluşan bir veri seti hazırlanarak derin öğrenme modellerinin başarımlarının artırılması amaçlanmıştır. Veri seti dengelenerek oluşturulan eğitim örnekleri en çok kullanılan AlexNet, GoogleNet, ShuffleNet ve SqueezeNet gibi ön eğitilmiş modellere uygulanmıştır. Çalışmada kullanılan her bir derin öğrenme modeli için deneysel çalışmalar gerçekleştirilmiş ve elde edilen sonuçlar değerlendirme ölçütlerine göre analiz edilmiştir. Zeytin yaprağındaki hastalıkların teşhisi için ham veri setinde en iyi sonuçları doğruluk için %98.51, duyarlılık için %98.51, özgüllük için %99.25, kesinlik için %98.52 ve F1-Skor için %98.51 değerleri ile ShuffleNet sağlamıştır. Artırılmış veri setinde ise en iyi sonuçları SqueezeNet göstermiştir. Ayrıca, artırılmış veri seti sayesinde ham veri setindeki sonuçlar AlexNet için %3.62 ile %7.56, GoogleNet için %0.88 ile %1.78, ShuffleNet için %0.63 ile %1.26 ve SqueezeNet için %1.95 ile %3.97 arasında iyileştirilmiştir.

İleriki çalışmalarda ise farklı ESA yapıları geliştirilip özellik seçim ve çıkarım işlemleri ile kombine edilerek daha doğru ve güvenilir sınıflandırma sonuçlarının elde edilebileceği düşünülmektedir.

KAYNAKLAR (REFERENCES)

- Albawi S., Mohammed T. A., Al-Zawi S., 2017, "Understanding of a convolutional neural network", *International Conference on Engineering and Technology (ICET)*, ss. 1-6.
- Bloice M. D., Christof S., Andreas H., 2017, "Augmentor: an image augmentation library for machine learning", çevrimiçi, <https://arxiv.org/abs/1708.04680>.
- Buda M., Maki A., Mazurowski M. A., 2018, "A systematic study of the class imbalance problem in convolutional neural networks", *Neural Networks*, Cilt 106, ss. 249-259.
- Darwish A., Ezzat D., Hassanien A. E., 2020, "An optimized model based on convolutional neural networks and orthogonal learning particle swarm optimization algorithm for plant diseases diagnosis", *Swarm and evolutionary computation*, Cilt 52, Sayı 100616, ss. 1-12.
- Deepak S., Ameer, P. M., 2019, "Brain tumor classification using deep CNN features via transfer learning", *Computers in biology and medicine*, Cilt 111, ss. Sayı 103345, ss. 1-7.
- Deng J., Dong W., Socher R., Li L. J., Li K., Fei-Fei L., 2009, "ImageNet: A large-scale hierarchical image database", *2009 IEEE Conference on Computer Vision and Pattern Recognition*, ss. 248-255.
- Erilmez S., Erkan S., 2014, "The identification of virus diseases in olive trees in Aydin, Balıkesir and İzmir provinces and the determination of their present status" *Plant Protection Bulletin*, Cilt 54, Sayı 1, ss. 45-67.
- Floridi L., 2020, "AI and Its New Winter: from Myths to Realities", *Philosophy & Technology*, Cilt 33, ss. 1-3.
- GeethaRamani R., ArunPandian J., 2019, "Identification of plant leaf diseases using a nine-layer deep convolutional neural network", *Comput. Electr. Eng.*, Cilt 76, ss. 323-338.

- Iandola F. N., Han S., Moskewicz M. W., Ashraf K., Dally W. J., Keutzer K., 2016, "SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size", International Conference on Learning Representations (ICLR), çevrimiçi, <https://arxiv.org/abs/1602.07360>, ss. 1-13.
- Jadhav S. B., Udipi V. R., Patil S. B., 2021, " Identification of plant diseases using convolutional neural networks", *Int. j. inf. tecnol*, Cilt 13, ss. 2461–2470.
- Korkut U. B., Göktürk Ö. B., Yıldız O., 2018, "Detection of plant diseases by machine learning" *26th Signal Processing and Communications Applications Conference (SIU)*, ss. 1-4.
- Krizhevsky A., Sutskever I., Hinton, G. E., 2012, "Imagenet classification with deep convolutional neural networks" *Advances in neural information processing systems*, Cilt 25, ss. 1-9.
- Liu B., Zhang Y., He D., Li Y., 2018, "Identification of Apple Leaf Diseases Based on Deep Convolutional Neural Networks" *Symmetry*, Cilt 10, Sayı 11, ss. 1-16.
- Mohanty P. S., Hughes P. D., Salathé M., 2016, "Using deep learning for image-based plant disease detection", *Frontiers in Plant Science*, Cilt 7, Sayı 1419, ss. 1-10.
- O'Shea K., Nash R., 2015, "An introduction to convolutional neural networks", çevrimiçi, <https://arxiv.org/abs/1511.08458>, ss. 1-11.
- Pawar P., Turkar V., Patil P., 2016, "Cucumber disease detection using artificial neural network", *International Conference on Inventive Computation Technologies (ICICT)*, Cilt 3, ss. 1-5.
- Shorten C., Khoshgoftaar T. M., 2019, "Shorten, Connor, and Taghi M. Khoshgoftaar. "A survey on image data augmentation for deep learning", *Journal of big data*, Cilt 6, Sayı 1, ss. 1-48.
- Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., Erhan D., Vanhoucke V., Rabinovich A., 2015, "Going Deeper With Convolutions", *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, ss. 1-9.
- Türkoğlu M., Hanbay K., Saraç Sivrikaya I., Hanbay D., 2020, "Derin Evrişimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması", *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, Cilt 9, Sayı 1, ss. 334-345.
- Uğuz S., *CNN_olive_Dataset*, https://github.com/sinanuguz/CNN_olive_dataset, ziyaret tarihi: 23.02.2022.
- Uğuz S., Uysal N., 2021, "Classification of olive leaf diseases using deep convolutional neural networks", *Neural Comput & Applic*, Cilt 33 Sayı 9, ss. 4133–4149.
- Upadhyay S. K., Kumar A., 2021, "Early-stage brown spot disease recognition in paddy using image processing and deep learning techniques", *International Information and Engineering Technology Association*, Cilt 38, Sayı 6, ss. 1755-1766.
- Uysal N., 2020 *Zeytin yaprağındaki hastalıkların derin öğrenme teknikleri kullanılarak sınıflandırılması*, Yüksek Lisans Tezi, Isparta Uygulamalı Bilimler Üniversitesi, Lisansüstü Eğitim Enstitüsü, Isparta.
- Zhang X., Zhou X., Lin M. Sun J., 2018, "ShuffleNet: an extremely efficient convolutional neural network for mobile devices" *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, ss. 6848-6856.