



Transfer Öğrenme Teknikleri Kullanarak Nohut Çeşidi Sınıflandırma

Chickpea Varietal Classification Using Transfer Learning Techniques

İbrahim Kılıç¹ , Nesibe Yalçın^{2*} 

¹Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Kayseri, Türkiye

²Erciyes Üniversitesi, Mühendislik Fakültesi, Kayseri, Türkiye

Öz

Tohum saflığı, tarım üretiminde verimi artırmak ve ürün kalite standartlarını karşılamak için oldukça önemlidir. Bu durum, tohum üreticilerinden dağıtıcılarına tarım endüstrisinin, tohum saflığına daha fazla önem vermesini gerektirmektedir. Bu da tohum çeşidi sınıflandırma ve ayırma yöntemlerine ihtiyacı artırmıştır. Çalışma kapsamında, dünyada en çok üretilen yemeklik baklagillerden biri olan nohudun çeşit sınıflandırması problemi ele alınmıştır. Sınıflandırma için 14 adet ön eğitilmiş derin öğrenme modeli kullanılmış ve model performansları karşılaştırılarak ilgili problem için en başarılı model(ler) tespit edilmeye çalışılmıştır. Başarımı en yüksek modeller VGG16 ve VGG19, sırasıyla %96.7 ve %97 test doğruluklarına sahiptir ve daha verimli, kaliteli ve sürdürülebilir tohum üretiminin sağlanması için önemli bir araç olabilirler.

Anahtar Kelimeler: Derin öğrenme, evrişimli sinir ağı, nohut sınıflandırma, transfer öğrenme.

Abstract

Seed purity is important for improving the efficiency of agricultural production and meeting product quality standards. This requires the agricultural seed industry, from producers to distributors/sellers, to focus more on the seed purity. Therefore, the need for seed variety identification and classification methods has increased. The seed variety classification of chickpeas, one of the most produced edible legumes in the world, is examined in this study. 14 pre-trained deep learning models have been used for classification and their performances have been compared to determine the most successful model(s) for the relevant problem. The most successful models, VGG16 and VGG19, have test accuracies of 96.7% and 97%, respectively. Thus, they can be an important tool for ensuring more efficient, high-quality, and sustainable seed production.

Keywords: Deep learning, convolutional neural network, chickpea classification, transfer learning.


1. Giriş


Tarım için tohum en önemli girdidir. Tohum saflığı, tekdüze (uniform) bir ürün güvencesi sağlamanın yanında optimum verim elde etmenin de ön koşuludur. Tohum çeşitliliğinin saflığının tehlikeye atılması, ekim uygulamalarını ve bitki büyümesini olumsuz etkilemektedir. Tohum sınıflandırması genellikle uzmanlar tarafından renk ve boyut gibi özelliklere bakılarak yapılmaktadır. Zaman alıcı bir süreç olmasının yanında çeşidin yanlış tanımlanmasına da neden olabilmek-

tedir (Abuhayi ve Bezabih 2023). Bu durum, tohum çeşit sınıflandırma problemi için otomatik sınıflandırma sistemi gibi daha hızlı ve verimli çözümlere olan ihtiyacı artırmaktadır.

Yapay zeka yaklaşımları hayatımızın her alanında uygulanabilir olmuşlardır. Tarım sektörü ve tarımsal üretimde bundan payını almıştır. Özellikle tohum çeşidinin tanımlanması ve otomatik sınıflandırılması üzerine giderek artan bir ilgi söz konusudur. Bununla birlikte çoklu tohum çeşitlerinin sınıflandırılmasına yönelik çalışma sayısı oldukça sınırlıdır (Başol ve Toklu 2021). Çetiner (2022), hint keneviri, mısır, pirinç, şeker kamışı, buğday bitkilerine ait görüntülerden oluşan bir veri setini kullanmıştır. Veri çoğaltma teknikleri uyguladığı veri setini, %80 eğitim ve %20 test amaçlı ikiye ayırmıştır. Sınıflandırma için MobileNetV2 tabanlı bir model önermiş ve temel MobileNetV2 modeli ve önerdiği model ile de-

*Sorumlu yazarın e-posta adresi: nesibeyalcin@erciyes.edu.tr

İbrahim Kılıç  orcid.org/0000-0001-5971-7928

Nesibe Yalçın  orcid.org/0000-0003-0324-9111



neyler gerçekleştirmiştir. Önerdiği model %98.75 doğruluk (accuracy) başarımına, temel model ise %72.67 başarıma sahiptir. Mısır tohumu görüntü örnekleri üzerinde çalışma gerçekleştiren Xu ve diğerleri (2021), görüntülerden 16 adet özellik çıkarmışlar ve daha sonra çeşitli makine öğrenmesi algoritmaları kullanarak çeşit sınıflandırması yapmışlardır. En iyi sonuçlara Destek Vektör Makinesi (%99.46) ve Çok Katmanlı Algılayıcı Ağları (%96.26) ile ulaşmışlardır. Aktaş (2022), geliştirdiği düzenek yardımı ile Antep fıstıklarına ait görüntüler elde etmiş ve veri setini dengeli hale getirmiştir. Farklı eğitim, doğrulama ve test veri seti bölümlenmeleri için gerçekleştirdiği deneyler sonucunda, %60-%20-%20 bölümlenmesi ile %98.44 doğruluk değerine ulaşmıştır. Yaşar (2023) çalışmasında, 5 ekmeklik buğday çeşidini (Ayten Abla, Hamitbey, Şanlı, Bayraktar 2000 ve Tosunbey) sınıflandırmıştır. Kullanılan görüntü veri seti, seyrek şekilde dizilmiş buğday tanesi görüntülerinden elde edilmiş 8354 adet görüntü içermektedir. InceptionV3, MobileNetV2 ve ResNet18 modelleri transfer edilmek suretiyle gerçekleştirilen sınıflandırma deneylerinde %97 ve üzeri doğruluk elde edilmiştir. 3 farklı karanfil türüne ait tohumların sınıflandırıldığı bir çalışmada (Tuğrul vd. 2022), DenseNet201, VGG16, MobileNet, InceptionV3 ve ResNet152V2 modellerine derin öğrenme teknikleri uygulanarak elde edilen versiyonları kullanılmıştır. Sınıflandırma sonucunda ResNet152V2 modelinin yeni versiyonu ile %99.45 doğruluk ve 0.9996 AuC değerine ulaşılmıştır. Singh ve diğerleri (2022), Siirt ve kırmızı Antep fıstığı tanelerine ilişkin görüntü seti üzerinde 3 ön eğitimli model ile deneyler yürütmüşler ve en yüksek doğruluk başarımını VGG16 ile elde etmişlerdir.

Nohut, zengin besin içeriği nedeniyle dünyada en çok üretilen ve tüketilen baklagillerden biridir ve birçok çeşidi bulunmaktadır. Üretim verimliliği tohum kalitesinden (saflığından) etkilenmektedir ve bu nedenle tohum sınıflandırması üretim açısından oldukça önemlidir. Kalite derecelerine (üstün, kabul edilebilir ve kusurlu) göre nohut sınıflandırmanın amaçlandığı bir çalışmada (Çakmak ve Boyacı 2011), nohut numuneleri ayrı ayrı yerinde tutabilen küçük bölmeli bir tabla tasarlanmıştır. Tohumlar bu bölmelere yerleştirilmiş ve tarayıcı ile görüntüler elde edilmiştir. Bilgisayarlı bir görme sistemine entegre Yapay Sinir Ağları ile yapılan sınıflandırma sonucunda en düşük doğruluk %87.6 ve olarak hesaplanmıştır. Nohut ve fasulye çeşit sınıflandırması üzerine yapılan bir çalışmada (Kaya vd. 2022), ResNet50 modeli kullanılmış ve sınıflandırma sonucunda %83.23 (nohut) ve %87.16 (fasulye) kesinlik (precision) elde edilmiştir. Makine öğrenmesi tabanlı nohut sınıflandırma üzerine yapılan bir

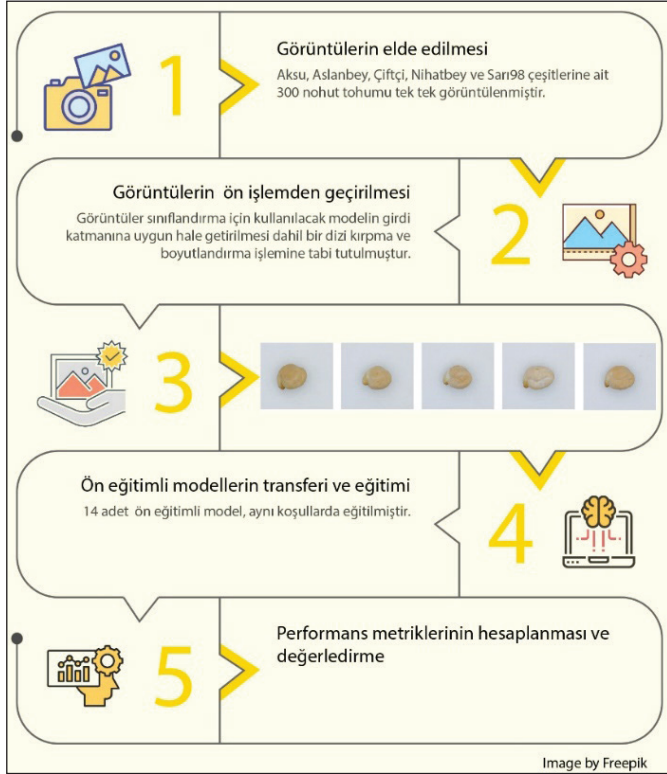
çalışmada (Ayele ve Tamiru 2020), 8 özellik ve toplam 8303 kayıt içeren bir veri seti kullanılmıştır. Ön işleme ile deneylere hazır hale getirilen veri seti, %80'i eğitim ve %20'si test amaçlı ikiye ayrılmıştır. Deneyler sonucunda %97.5 doğruluk oranı ile Karar Ağacı en iyi performansı göstermiştir. Makine öğrenmesi yöntemleri kullanılarak yapılan bir başka çalışmada (Karadağ ve Keskinbıçak 2023), nohut bitkisinin özellikleri (hacim, ağırlık, renk, kabuk şekli gibi) kullanılmıştır. Ham veri seti ve daha sonra sentetik veriler kullanılarak deneyler yapılmış ve sadece ham verilerin kullanıldığı deneyler sonucunda en yüksek başarı oranı %90.6 olarak hesaplanmıştır. Saha ve Manickavasagan (2022), nohut sınıflandırma üzerine 7 ön eğitimli model ile gerçekleştirdikleri deneylerde en iyi doğrulukları MobilNetV2: %100, ResNet: %100 ve GoogleNet: %99.4 olarak belirlemişlerdir. Nohut tohumunun morfolojik özellikleri dikkate alınarak yapılan bir sınıflandırma çalışmasında (Saha vd. 2023), NasNet-A, MobileNetV3 ve EfficientNetB0 modelleri ile sırasıyla %97, %99 ve %98 doğruluk elde edilmiştir. 4 nohut çeşidine ilişkin yapılan bir sınıflandırma çalışmasında (Taheri-Garavand vd. 2021), değiştirilmiş VGG16 modeli ile %94 üzeri ortalama doğruluk hesaplanmıştır. 6 sertifikalı nohut çeşidi (Atabey, Aydoğan, Göktürk, Badır, Karlı ve Tunç) sınıflandırması üzerine yapılan bir başka çalışmada (Golcuk vd. 2023), hibrit bir sınıflandırma modeli (MobilNetV2 + LSTM) ile %92.97 kesinlik elde edilmiştir. İncelenen çalışmalar transfer öğrenme tekniklerinin tohum sınıflandırma-daki potansiyelini ortaya koymaktadır.

Bu çalışmada, nohut tohumu çeşit sınıflandırması amaçlanmıştır. Sınıflandırmada yüksek doğruluk elde etmek amacıyla 14 adet transfer öğrenme tekniği kullanılmıştır. Öğrenme modellerinin belirsizliğini ve tahmin verimliliğini değerlendirmek için 5 katlı çapraz doğrulama (cross validation) yapılmıştır. Bütün modellerde %90 ve üzeri test doğruluğuna ulaşılmıştır. Çalışmanın literatüre ana katkıları aşağıda listelenmiştir:

- Çalışma kapsamında "TRCS_5_SET" isimli özgün bir veri seti oluşturulmuş ve araştırmacıların kullanımına sunulmuştur.
- Çoklu tohum sınıflandırma problemi için transfer öğrenme teknikleri, başarı ile uygulanmıştır.
- VGG16 ve VGG19 modelleri ile sırasıyla %96.7 ve %97 test doğruluklarına ulaşılmıştır.
- Nohut açısından tarımda verimliliği artırmak ve tohum saflığına katkıda bulunmak için yüksek doğrulukla tohum sınıflandırma işlemi gerçekleştirilmiştir.

2. Gereç ve Yöntem

Çalışma kapsamında Türkiye’de üretilen 5 farklı nohut tohumu çeşidine ilişkin bir görüntü veri seti oluşturulmuş ve önışlemden geçirilerek transfer öğrenme modellerinin eğitim ve test edilmesinde kullanılmıştır. Nohut çeşidi sınıflandırma için önerilen mimari Şekil 1’de sunulmuştur. Her bir adıma ilişkin ayrıntılara bu bölümde yer verilmiştir.



Şekil 1. Nohut sınıflandırma akış diyagramı.

2.1. Veri Seti

Çalışmada kullanılan veri seti (Kılıç ve Yalçın 2023), dengeli bir dağılıma sahiptir ve Nihatbey, Sarı98, Aksu, Çiftçi ve Aslanbey nohut çeşitlerine ait görüntüler içermektedir. Çeşit başına 300 olmak üzere toplamda 1500 görüntü veri setinde yer almaktadır (Çizelge 1). Veri seti nohut çeşitlerine ilişkin birer örnek görüntü Şekil 2’de sunulmuştur.




Şekil 2. Veri setinden örnek görüntüler.

Çizelge 1. Veri seti özeti.

Çeşit	Görüntü Adeti	Oran (%)	Toplam
Nihatbey	300	20	1500
Sarı98	300	20	
Aksu	300	20	
Çiftçi	300	20	
Aslanbey	300	20	

Nohut tohumu görüntüleri, Arducam Hawk-Eye kamera ile 1050 kandela ışık şiddetine sahip beyaz bir LED ışık kaynağı altında 15 cm yükseklikten çekilmiştir (Şekil 3). 9152×6944 çözünürlüğe sahip nohut görüntüleri, sınıflandırma işlemi öncesi ön işlemden geçirilmiştir. Görüntüler nohut tanesini içerecek şekilde kırılarak önce 1200×1100 piksel çözünürlüğe yeniden boyutlandırılmış, daha sonra ilgili ön eğitilmiş modelin eğitimi için girdi katmanının gerektirdiği çözünürlüğe indirgenmiştir. Çalışma kapsamında hazırlanan görüntü veri seti, “TRCS_5_SET” olarak isimlendirilmiş ve GitHub’ta paylaşılmıştır (Kılıç 2024).



Şekil 3. Görüntülerin elde edilmesi için kullanılan sistem.

2.2. Derin Öğrenme ve Transferi

Derin öğrenme, makinenin birden fazla gizli katmana sahip çok katmanlı yapay sinir ağları (derin ağlar) aracılığıyla öğrenmesini ifade etmektedir. Derin öğrenme modelleri, başlangıç sinir hücresi (nöron) değerlerini ve sinir hücreleri arası bağlantı ağırlıklarını denetimsiz olarak belirlemekte, geri yayılım gibi farklı algoritmalar ile parametre optimizasyonunu gerçekleştirmekte ve eğitim sırasında çok küçük hata oranlarına kısa sürede ulaşabilmektedir (Altan 2019). Evrişimli Sinir Ağı (Convolutional Neural Network, CNN), özellikle görüntü sınıflandırma ve nesne tespiti görevlerinde başarılı bir derin öğrenme mimarisidir. Herhangi bir öznelik çıkarımına ihtiyaç duymadan canlıların görsel algılama

şeklini taklit eden evrişim işlemi, CNN’i popüler hale getirmiştir.

CNN, temel olarak evrişim (convolution), havuzlama (pooling) ve tam bağlı (fully-connected) katmanlardan oluşmaktadır (Narin vd. 2021). Evrişim katmanı, görüntüden özelliklerin çıkarılmasından sorumludur. Bir filtre matrisi yardımı ile görüntü matrisinden özellik haritası (feature map) çıkarılır. Çıkarılan özellik haritasının boyutu; görüntü girişi, filtre çekirdeği ve adım değerine (stride) bağlıdır. Her evrişim işlemi ile birlikte ağırlık eğitiminin hesaplama maliyeti artmaktadır. Havuzlama katmanı, özellik haritasında boyut azaltımı gerçekleştirerek hesaplama maliyetini düşürmektedir. Bilgi kaybına rağmen bir piksele komşu piksellerde yer alan bilgileri istatistiksel olarak özetlediği için önemli bilgileri içermes, daha az hesaplama yükü sağlama, ezberlemeyi önleme gibi avantajları nedeniyle CNN modellerinde sıklıkla kullanılmaktadır (Narin vd. 2021, LeChun vd. 2015, Srivastava vd. 2014). Tam bağlı katman, bütün sinir hücrelerinin bir önceki katmanın çıkışları ile bağlantılı olduğu katmandır ve bir çeşit çok katmanlı algılayıcıdır (Narin vd. 2021).

Transfer öğrenme, özellikle küçük veri setleri ile derin öğrenme çalışmalarında sıklıkla tercih edilmektedir. Transfer öğrenmenin özünü büyük veri setleri üzerinde başarısını kanıtlamış olan eğitilmiş modellerin, yeni öğrenme problemlerinde kullanılması oluşturmaktadır. Bu çalışmada, VGG16, VGG19, DenseNet201, ResNet18, ResNet50, ResNet101, InceptionResNetv2, GoogleNet, Xception, AlexNet, MobileNetV2, NasNetMobile, EfficientNet ve ShuffleNet ön eğitilmiş modelleri kullanılmıştır.

AlexNet, CNN’nin kendi kendisine çıkardığı öznetelikler ile ulaşılan öğrenme başarımının, klasik yöntemlerle çıkarılmış öznetelikler kullanılarak yapılan öğrenmenin başarımını geçebileceğini gösteren ilk modeldir. ILSVRC 2012’yi büyük bir farkla kazanmıştır. Derin öğrenmenin gücünü ve potansiyelini göstermesi bakımından bir dönüm noktası olarak kabul edilen AlexNet, yeni derin öğrenme modellerinin geliştirilmesine ilham kaynağı olmanın yanında bilgisayarla görmenin alışılmış kalıpların ötesine geçebilmesine de öncülük etmiştir. 8 katmanlı bir yapıya sahip olan AlexNet mimarisi, ilerleyen katmanlar boyunca boyutları azalan evrişim filtrelerine sahiptir. Aktivasyon fonksiyonu olarak ReLU kullanılmış ve böylece LeNet’te var olan gradyan kaybı sorunu çözüme ulaştırılmıştır (Zhang vd. 2023).

VGG, ConvNet olarak da bilinen bir CNN çeşididir. 13 evrişim katmanı ve 3 tane tam bağlı katmandan oluşmaktadır. Oxford Üniversitesi Görsel Geometri Grup (Visual Geo-

metry Group, VGG) Laboratuvarı çalışanlarından Karen Simonyan ve Andrew Zisserman tarafından 2015 yılında “Very Deep Convolutional Networks for Large-Scale Image Recognition” başlıklı makalede önerilmiştir. VGG, ImageNet üzerinde %92.7 başarımla elde etmiştir (Simonyan ve Zisserman 2015). Katman yapısı ve geliştirildiği laboratuvar nedeniyle VGG16 olarak anılmaktadır. AlexNet mimarisine göre kernel boyutları azaltılmıştır. VGG19 mimarisi ise VGG16 mimarisine 3 adet evrişim katmanı eklenerek geliştirilmiş versiyonudur.

GoogleNet, diğer adı ile Inception, 2014 yılında duyurulmuştur ve 22 katmana sahiptir. Mimarisinin ana fikrini, geleneksel evrişimli ağlarda sıralı bazı işlemlerin paralel olarak aynı anda gerçekleştirilmesi oluşturmaktadır. “Inception modülü” adı verilen bu yaklaşım, eğitilebilir parametre sayısını artırmaktadır. Parametre sayısındaki artışın getirdiği hesaplama maliyeti, 1×1 evrişim filtresi ve düzeltilmiş doğrusal aktivasyon içeren boyut azaltım modülü ile çözülmüştür. Böylece, önemli bir performans kaybı yaşanmadan ağırlık derinliği ve genişliği de artırılabilmiştir (Szegedy vd. 2015).

ResNet, 2015 yılında ILSVRC yarışmasını kazanan bir derin öğrenme modelidir. Derin sinir ağlarında karşılaşılabilen gradyan kaybı problemini azaltmak ve ağırlık öğrenmesini kolaylaştırmak için evrişim bloğu girişini bir veya daha fazla katman sonrası çıkış aktivasyonu öncesine aktaran artık (residual) bağlantılar kullanılmaktadır (He vd. 2016). Ağırlık daha etkili ve hızlı öğrenmesine yardımcı olan bu bağlantılar ile gerçekleştirilen öğrenme yaklaşımına, artık öğrenme (residual learning) denir (Géron 2019). Inception-ResNet (Szegedy vd. 2017), Inception ve ResNet mimarilerini birleştiren bir CNN mimarisidir. Böylece, her iki mimarinin avantajlarından yararlanılarak daha etkili ve verimli bir öğrenme modelinin sunulması amaçlanmıştır.

Xception, 2016 yılında “Xception: Deep Learning with Depthwise Separable Convolutions” başlıklı makale ile tanıtılmıştır (Chollet 2017). Inception ve ResNet mimarilerinin yaklaşımlarını benimseyen Xception’ın ana fikri, Inception modülleri yerine derinlemesine ayrılabilir (depthwise separable) evrişim katmanı kullanmaktır. Ayrılabilir evrişimsel katmanlar, daha az bellek ve hesaplama maliyeti ile daha iyi bir performans vaatmektedir. Xception, aynı sayıda parametreye sahip olduğu InceptionV3’e göre model parametrelerini daha verimli kullanması nedeniyle iyi bir performans sergilemiştir (Géron 2019).

DenseNet, ağ performansını artırmak amacıyla evrişimsel katmanlar arası yoğun bağlantılar içeren derin öğrenme

modelidir. Modelin tasarımı, yoğun blok (DenseBlock) adı verilen alt birimlerde yer alan katmanların her birinin çıkışının ardı sıra gelen diğer katmanlara bağlanması fikrine dayanmaktadır. Dolayısıyla yoğun blokta yer alan her katman, kendisinden önceki bütün katmanların çıkışını giriş olarak almaktadır. Yoğun bağlantılar, hesaplama ve bellek maliyeti artışını da beraberinde getirmiştir. Hesaplama ve bellek kullanım verimliliği için evrişim işlemi öncesi darboğaz katmanları (bottleneck layers) kullanılabilirliği ifade edilmiştir (Huang vd. 2017). DenseNet121 ve DenseNet201 gibi mimari üyelerinin adındaki rakamsal tanımlamalar, model derinliğini başka bir ifadeyle katman sayısını ifade etmektedir.

MobileNet, sınırlı sistem kaynaklarına sahip mobil cihazlar ve gömülü sistemlerde bilgisayarlı görme uygulamaları için tasarlanmış CNN mimarisidir. Derinlemesine ayrılabilir filtreler temel alınarak geliştirilen model, probleme daha iyi adapte olabilmelerini sağlayan hiper parametrelere sahiptir. Bu parametreler sayesinde, probleme uygun olarak performansı optimize etmek için modelin boyutu ve karmaşıklığı ayarlanabilmektedir (Howard vd. 2017).

NasNetMobile, belirli bir veri seti ve görev için en iyi performansı sunacak bir sinir ağı mimarisinin keşfedilmesini hedeflemektedir. Bu bağlamda, genel mimarisi başlangıçta belirlenmiş bir ağ üzerinde Sinir Mimarisi Araması (Neural Architecture Search, NAS) yönteminden (Zoph ve Le 2017) yararlanarak göreve en uygun ağ mimarisi otomatik olarak aranır. NAS yöntemi, alt ağların eğitiminden elde edilen doğruluklar ile kendisini güncelleyen bir denetleyiciye sahiptir. Denetleyicinin doğruluklar çerçevesinde güncellenmesinin nedeni zaman içerisinde daha iyi mimariye ulaşabilmektir. Ölçeklenebilir bir mimari için ağ, hücrelerden oluşmaktadır. Basit bir ifade ile denetleyici, arama uzayında ağı oluşturan bu hücrelerin yapılarını aramakta ve ağın ölçeklenmesini sağlamaktadır (Zoph vd. 2018).

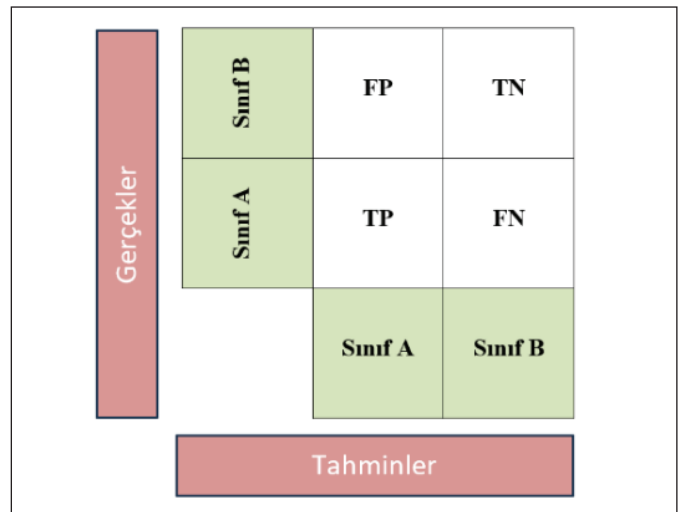
ShuffleNet, sistem kaynakları ve bilgi işlem gücü sınırlı cihazlar için tasarlanmıştır. Derinlemesine ayrılabilir evrişim kullanan mimarilerin noktasal evrişimden yeterli düzeyde faydalanamadığı ana fikri çerçevesinde, noktasal grup evrişimi (pointwise group convolution) ve kanal karıştırma (channel shuffle) kullanmıştır. Bu yöntem, hesaplama maliyetini azaltırken doğruluğun korunabilmesini sağlamıştır. Noktasal grup evrişimi, kanal karıştırma ve dar boğaz (bottle-neck) işlemlerinin bileşimini içeren karıştırma birimlerinden oluşmaktadır. Diğer bazı modellere kıyasla daha az işlem yükü ile düşük sınıflandırma hatası sunmaktadır (Zhang vd. 2018).

Evrişimli sinir ağlarının ölçeklendirilmesi problemi temelinde geliştirilen EfficientNet, yüksek doğruluk elde etmek için genişlik, derinlik ve çözünürlük bileşenlerinin bileşik bir katsayı vasıtasıyla sezgisel olarak ölçeklenmesi ilkesini benimsemiştir (Tan ve Le 2019). Klasik yöntemleri kullanan modellere kıyasla daha fazla nesne ayrıntısına sahip daha ilgili bölgelere odaklanma eğilimindedir. Bu sayede, hesaplama maliyeti açısından verimlidir ve kaynak kısıtlı cihazlar için idealdir.

2.3. Performans Değerlendirme Metrikleri

Ön eğitilmiş modellerin sınıflandırma performanslarının değerlendirilebilmesi için doğruluk, kesinlik ve karakteristik eğrisi altında kalan alan (AuC) metrikleri kullanılmıştır. İlgili metrikler, her ön eğitilmiş modelin çalıştırılması sonucu elde edilen karmaşıklık matrislerine (confusion matrix) göre hesaplanmıştır. Karmaşıklık matrisi, modelin sınıflar için verdiği doğru ve yanlış tahminleri, gerçek etiketleri ile birlikte gösteren tablodur. Şekil 4'te ikili (A ve B sınıfı) bir sınıflandırma problemi için karmaşıklık matrisi verilmiştir. TP (True Positive, Doğru Pozitif), gerçekte A sınıfına (pozitif) ait olan ve doğru bir şekilde tahmin edilen örneklerin sayısını ve TN (True Negative, Doğru Negatif) ise gerçekte B sınıfından (negatif) olan ve doğru tahminlenen örneklerin sayısını ifade etmektedir. B sınıfı olarak yanlış tahmin edilen ve gerçekte A sınıfından olan örneklerin sayısı, FN (False Negative, Yanlış Negatif) ve yanlış bir şekilde A olarak tahmin edilen B sınıfı örneklerin sayısı ise FP (False Positive, Yanlış Pozitif) ile belirtilmiştir.

Karmaşıklık matrisi; doğruluk, özgünlük ve duyarlılık (recall) gibi performans metriklerinin hesaplanmasına yardım-



Şekil 4. Karmaşıklık matrisi örneği.

cı olmaktadır. Çalışmada kapsamında transfer öğrenme modellerinin başarısının değerlendirilmesinde doğruluk metriği kullanılmıştır. Doğruluk, doğru olarak sınıflandırılan örneklerin tüm örnekler oranını ifade eder ve (1) denklemi yardımı ile hesaplanır.

$$\begin{aligned} \text{Doğruluk} &= \frac{\text{Doğru tahmin edilen pozitif ve negatif örneklerin sayısı}}{\text{Veri setindeki toplam örnek sayısı}} \\ &= \frac{TP + TN}{TP + TN + FP + FN} \end{aligned} \quad (1)$$

Kesinlik, model seçiminde önemli bir metriklerden biridir. Pozitif olarak tahmin edilen örneklerin gerçekte ne kadarının pozitif olduğunu gösterir. Denklem (2) kullanılarak hesaplanır.

$$\begin{aligned} \text{Kesinlik} &= \frac{\text{Doğru tahmin edilen pozitif örneklerin sayısı}}{\text{Pozitif tahmin edilen toplam örnek sayısı}} \\ &= \frac{TP}{TP + FP} \end{aligned} \quad (2)$$

Sınıflandırma modellerinin performansını ölçmek için kullanılan metriklerden biri de AuC (Area under Curve)'dir. Bu metrik, gerçek pozitifler ile gerçek negatiflerin oranları arasındaki ilişkiyi betimleyen Alıcı İşlem Karakteristik (Receiver Operating Characteristic, ROC) eğrisi altında kalan alanı göstermektedir. AuC, 0 ile 1 arasında bir değer alır ve bu değer 1'e yakın olması sınıflandırma modelinin iyi bir performans gösterdiği ve daha doğru tahminde bulunduğu anlamına gelmektedir.

3. Bulgular ve Tartışma

Nohut sınıflandırma problemi için 5 çeşide sahip görüntü veri seti üzerinde, 14 ön eğitilmiş model (DenseNet201, ResNet18, ResNet50, ResNet101, InceptionResNetv2, VGG16, VGG19, GoogleNet, Xception, AlexNet, MobileNetV2, NasnetMobile, EfficientNet ve ShuffleNet), transfer öğrenme yaklaşımıyla kullanılmıştır. Veri seti, modelleri eğitmek ve test etmek için 80:20 oranında (Ayele ve Tami-ru 2020) eğitim ve test setlerine ayrılmıştır. Eğitim ve test işlemleri, Intel Core I5 10400F 2.9 GHz işlemci, 16 GB DDR4 RAM bellek ve 6 GB GTX1660 GPU donanımına sahip masaüstü bir bilgisayarda Matlab R2022b programı ile gerçekleştirilmiştir. 5 katlı çapraz doğrulama yapılmış ve bütün ön eğitilmiş modeller için Çizelge 2'de verilen model eğitim parametreleri kullanılmıştır.

Çizelge 2. Eğitim parametreleri.

Parametre	Değer
Optimizasyon algoritması	sgdm
Maksimum devir sayısı (epoch)	20
Veri seti karıştırma	Her devir
Öğrenme oranı	1e-4
Mini yığın büyüklüğü	16
Doğrulama frekansı	10

Ön eğitilmiş modeller ile yürütülen deneyler sonucunda Çizelge 3'te sunulan eğitim ve test veri setlerine ilişkin doğruluk oranları ve AuC değerleri elde edilmiştir. Sonuçlar, bütün modellerin yaklaşık %90 ve üzeri eğitim ve test doğruluklarına ulaştığını göstermiştir. VGG19, çalışma kapsamında elde edilen en yüksek test doğruluğu %97 ile nohut çeşitlerini başarılı ve doğru bir şekilde sınıflandırmıştır. En yüksek eğitim doğruluk değerleri ise sırasıyla VGG16 (%97.2), DenseNet201 (%97.2) ve VGG19 (%96.3) modelleri ile elde edilmiştir. En düşük eğitim doğruluğu ise %89.7 ile NasNetMobile modeline aittir. Modellerin AuC değerleri ise 0.9935 ve üzeridir.

VGG16 ve VGG19 modelleri ile test veri seti için elde edilen karmaşıklık matrisleri, sırasıyla Şekil 5 ve Şekil 6'da verilmiştir. Aslanbey nohut örneklerinin VGG19 ve VGG16 modelleri ile %100 duyarlılık ile sınıflandırıldığı görülmektedir. Ayrıca çiftçi nohut örnekleri de her iki model ile yüksek duyarlılıkla (%98.3) sınıflandırılmıştır. VGG19 modeli için Aslanbey, Aksu ve Sarı98 çeşitleri %100 kesinlik değerine sahiptir. En düşük duyarlılık değerleri, VGG19 modeli ile Sarı98 çeşidi için %93.3 ve VGG16 ile Nihatbey çeşidi için %90 olarak elde edilmiştir.

Modellerin nohut çeşitlerini sınıflandırmada aldığı kararlara ilişkin görsel açıklamalar üretmek için Grad-CAM (Selvaraju vd. 2017) tekniğinden yararlanılmıştır. Diğer modellere kıyasla daha başarılı olan VGG16 modeli burada dikkate alınmıştır. Şekil 7'de her bir sınıfa ilişkin rastgele seçilen iki orijinal nohut görüntüsü ve Grad-CAM ile elde edilen görselleştirmeleri sunulmuştur. Koyu kırmızı renkli olan bölgeler, modelin sınıflandırma kararında en etkili olan özellikleri başka bir ifade ile yüksek aktivasyon değerine sahip alanları göstermektedir.

Aynı veri seti üzerine yapılan bir çalışmada (Kılıç ve Yalçın 2023), CNN modelleri (CNN-1 ve CNN-2) ile sınıflandırma gerçekleştirilmiştir. Sınıflandırma sonucunda elde edilen eğitim-test doğrulukları ve AuC değerleri, CNN-1 modeli için sırasıyla 0.912-0.94 ve 0.9945; CNN-2 için 0.969-0.98 ve 0.9990'dır. Ön eğitilmiş model sonuçları ile karşılaştırıldı-

Çizelge 3. Ön eğitilmiş modellerin eğitim ve test sonuçları.

Model	Eğitim Doğruluğu	Test Doğruluğu	AuC
DenseNet201	0.972	0.930	0.9969
ResNet50	0.939	0.957	0.9979
VGG16	0.972	0.967	0.9991
InceptionResNetv2	0.955	0.957	0.9935
GoogLeNet	0.912	0.927	0.9967
Xception	0.919	0.940	0.9949
AlexNet	0.943	0.960	0.9987
MobileNetV2	0.954	0.923	0.9957
ResNet18	0.959	0.950	0.9982
ResNet101	0.948	0.927	0.9968
VGG19	0.963	0.970	0.9987
NasNetMobile	0.897	0.907	0.9936
EfficientNet	0.923	0.900	0.9961
ShuffleNet	0.940	0.917	0.9955

		Karmaşıklık Matrisi(Test): Vgg19					
Tahmin Edilen Sınıf	aksu	59 19.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	aslanbey	0 0.0%	60 20.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	çiftçi	1 0.3%	0 0.0%	59 19.7%	3 1.0%	0 0.0%	93.7% 6.3%
	nihatbey	0 0.0%	0 0.0%	1 0.3%	57 19.0%	4 1.3%	91.9% 8.1%
	sarı98	0 0.0%	0 0.0%	0 0.0%	0 0.0%	56 18.7%	100% 0.0%
		98.3% 1.7%	100% 0.0%	98.3% 1.7%	95.0% 5.0%	93.3% 6.7%	97.0% 3.0%
		Gerçek Sınıf					
		aksu	aslanbey	çiftçi	nihatbey	sarı98	

Şekil 5. VGG19 - test karmaşıklık matrisi.


gında CNN-2 modeli daha yüksek test başarımına sahiptir. Test doğruluk değerlerinin karşılaştırması Şekil 8'de verilmiştir. Bütün modeller ile %90 ve üzeri doğruluk sağlanmıştır. En yüksek test doğrulukları ise sırasıyla CNN-1 (%98) ve VGG19 (%97) modelleri ile elde edilmiştir.

Test veri seti üzerinde sınıf bazında elde edilen kesinlik değerleri, Çizelge 4'te verilmiştir. Bütün modeller Aslanbey nohut çeşidi sınıflandırmasında, diğer çeşit sınıflandırma-


		Karmaşıklık Matrisi(Test): Vgg16					
Tahmin Edilen Sınıf	aksu	60 20.0%	0 0.0%	0 0.0%	2 0.7%	0 0.0%	96.8% 3.2%
	aslanbey	0 0.0%	60 20.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	çiftçi	0 0.0%	0 0.0%	59 19.7%	3 1.0%	0 0.0%	95.2% 4.8%
	nihatbey	0 0.0%	0 0.0%	1 0.3%	54 18.0%	3 1.0%	93.1% 6.9%
	sarı98	0 0.0%	0 0.0%	0 0.0%	1 0.3%	57 19.0%	98.3% 1.7%
		100% 0.0%	100% 0.0%	98.3% 1.7%	90.0% 10.0%	95.0% 5.0%	96.7% 3.3%
		Gerçek Sınıf					
		aksu	aslanbey	çiftçi	nihatbey	sarı98	

Şekil 6. VGG16 - test karmaşıklık matrisi.

larından daha başarılı bir performans göstermiştir. Aslanbey için elde edilen en düşük kesinlik değeri ise 0.983'tür. Diğer nohut çeşitleri için elde edilen en yüksek kesinlik değerleri Nihatbey sınıfı için 0.98 (AlexNet), Çiftçi için 0.966 (ResNet18), Sarı98 ve Aksu için 1.0 (VGG19)'dir. CNN-1 ve CNN-2 modelleri ile ön eğitilmiş model sonuçları karşılaştırıldığında, Nihatbey ve Çiftçi nohut çeşitleri için CNN-2 modeli daha yüksek başarımlar sağlamıştır.



Şekil 7. Her bir sınıf için orijinal nohut görüntüleri ve Grad-CAM görselleştirmeleri.



Şekil 8. Modellerin test doğrulukları.

Literatürdeki transfer öğrenme tabanlı nohut tohumu sınıflandırma çalışmaları ile karşılaştırıldığında (Çizelge 5) çalışma sonuçları umut vericidir. Taheri-Garavand ve diğerleri (2021), 4 katman ekleyerek değiştirdikleri VGG16 modeli ile %94 sınıflandırma doğruluğu elde etmiştir. Bu çalışmada ise VGG16 modeli ile %96.7 test doğruluğu sağlanmıştır. Saha ve Manickavasagan (2022), MobilNetV2 ve

ResNet modelleri ile %100, GoogLeNet ile %99.4 doğruluk oranına ulaşılırken bu çalışma kapsamında, MobileNetV2, ResNet101 ve VGG19 modelleri ile Aslanbey çeşidi %100 doğrulukla sınıflandırılmıştır. Ayrıca VGG16, VGG19 ve AlexNet modelleri ile ulaşılan sonuçların daha yüksek olduğu çizelgede görülebilir.

Çizelge 4. Çeşit bazlı test sonuçlarının karşılaştırması.

Model	Kesinlik				
	Nihatbey	Sarı98	Aksu	Çiftçi	Aslanbey
DenseNet201	0.978	0.833	0.922	0.965	0.984
ResNet50	0.887	0.968	0.983	0.946	1.000
VGG16	0.931	0.983	0.968	0.952	1.000
InceptionResNetv2	0.891	0.967	0.983	0.964	0.984
GoogleNet	0.862	0.982	0.983	0.838	0.983
Xception	0.862	0.982	0.922	0.946	1.000
AlexNet	0.980	0.984	0.938	0.908	1.000
MobileNetV2	0.882	0.855	0.967	0.915	1.000
ResNet18	0.873	0.966	0.966	0.966	0.984
ResNet101	0.781	0.982	0.983	0.922	1.000
VGG19	0.919	1.000	1.000	0.937	1.000
NasNetMobile	0.882	0.894	0.857	0.925	0.983
EfficientNet	0.872	0.843	0.932	0.862	1.000
ShuffleNet	0.976	0.882	0.921	0.848	0.984
CNN-1	0.960	0.919	0.951	0.881	1.000
CNN-2	0.983	0.984	0.983	0.967	0.984

Çizelge 5. Literatür karşılaştırması.

Çalışma	Model	Doğruluk (%)
(Taheri-Garavand vd. 2021)	Değiştirilmiş VGG16	>94 (ortalama)
(Saha ve Manickavasagan 2022)	MobilNetV2	100 (genel/overall)
	ResNet50	100
	GoogleNet	99.4
	VGG16	78
	VGG19	72
	AlexNet	50
Bu çalışma	VGG19	97.0 (test)
	VGG16	96.7
	AlexNet	96

4. Sonuç ve Öneriler

Bu çalışmada, nohut çeşitlerinin sınıflandırılmasında transfer öğrenme tekniklerinin potansiyeli araştırılmıştır ve ön eğitimli 14 modelin doğruluğunu ve etkinliğini değerlendirmek için çeşitli deneyler yürütülmüştür. Deneyler sonucunda elde edilen test sonuçlarına göre bütün modeller yaklaşık %90 ve üzeri doğruluk başarımları göstermiştir. Bu bağlamda, bütün modeller ilgili sınıflandırma probleminde kullanılabilir özellikte olup VGG16 ve VGG19 ön eğitimli modelleri, en başarılı modeller olarak nohut tohumu çeşit sınıflandırması için önerilmiştir. Elde edilen sonuçlar, nohut tohumu açısından tarım üretim zincirindeki temel problemlerinden

biri olan tohum saflığının korunmasına katkı sağlayabilir.

Çeşitli görüntü işleme tekniklerinin önerilen ön eğitimli modeller ile entegre edilmesi, nohut tohumu çeşit sınıflandırması çalışmalarının pratikte uygulanabilmesini daha mümkün kılacaktır. Yine toplu örnekler içerisinde farklı nohut tohumlarının varlığının tespiti için kullanılabilmesini sağlamak adına nohut tanelerinin tek bir açıdan değil farklı açılardan görüntülerinin elde edilerek görüntü setinin oluşturulması önemlidir. Gelecekte ilgili modellerin daha fazla nohut çeşidiyle (farklı açılardan görüntülere sahip) test edilmesi planlanmaktadır.

5. Teşekkür

T.C. Tarım ve Orman Bakanlığı Geçit Kuşağı Tarımsal Araştırmalar Enstitüsü Müdürlüğüne, Doğu Akdeniz Geçit Kuşağı Tarımsal Araştırmalar Enstitüsü Müdürlüğüne, Kahramanmaraş İl Tarım ve Orman Müdürlüğüne ve Kayseri Develi İlçe Tarım ve Orman Müdürlüğüne, nohut tohumlarının temini için teşekkür ederiz.

Yazar katkısı

İbrahim Kılıç: Görüntüleme sistemini kurmuş, veri setini hazırlamış, deneyleri gerçekleştirmiş, sonuçları analiz etmiş ve makaleyi yazmıştır, Nesibe Yalçın: Çalışmanın denetimini gerçekleştirmiş, sonuçları analiz etmiş, makaleyi yazmış ve düzenlemiştir.

6. Kaynaklar

- Abuhayi, B.M., Bezabih, YA. 2023.** Chickpea disease classification using hybrid method. *Smart Agricultural Technology*, 6:100371. Doi: 10.1016/j.atech.2023.100371
- Aktaş, H. 2022.** Antep fıstığının derin öğrenme ile dış kabuk rengine göre sınıflandırılması. *NÖHÜ Müh. Bilim. Derg.*, 11(3):461-466.
- Altan, G. 2019.** DeepGraphNet: grafiklerin sınıflandırılmasında derin öğrenme modelleri. *EJOSAT*, 319-327. Doi: 10.31590/ejosat.638256
- Ayale, N.A., Tamiru, H.K. 2020.** Developing classification model for chickpea types using machine learning algorithms. *International Journal of Innovative Technology and Exploring Engineering (IJITEE)*, 10(1): 5-11. Doi: 10.35940/ijitee.A8057.1110120
- Başol, Y., Toklu, S. 2021.** A deep learning-based seed classification with mobile application. *Turk. J. Math. Comput. Sci.*, 13(1): 192-203. Doi: 10.47000/tjmc.897631
- Chollet, F. 2017.** Xception: deep learning with depthwise separable convolutions. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, 1800-1807. Doi: 10.1109/CVPR.2017.195
- Çakmak, Y.S., Boyacı, İ.H. 2011.** Quality evaluation of chickpeas using an artificial neural network integrated computer vision system. *Int. J. Food Sci. Technol.*, 46(1): 194-200.
- Çetiner, H. 2022.** Classification of plant species with transfer learning-based methods. *EasyChair Preprint no. 8447*.
- Géron A. 2019.** Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow, 2nd Edition. *Scikit-Learn, Keras ve TensorFlow ile Uygulamalı Makine Öğrenmesi*. 1. Baskı. Çevirenler: Aksoy B., Özgür K., Buzdağı Yayınevi, İstanbul.
- Golcuk, A., Yasar, A., Saritas, M.M., Erharman, A. 2023.** Classification of cicer arietinum varieties using MobileNetV2 and LSTM. *Eur. Food Res. Technol.*, 249:1343-1350. Doi: 10.1007/s00217-023-04217-w
- He, K., Zhang, X., Ren, S., Sun, J. 2016.** Deep residual learning for image recognition. *IEEE Conference on Computer Vision and Pattern Recognition*, 770-778.
- Howard, A.G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., Adam, H. 2017.** MobileNets: Efficient convolutional neural networks for mobile vision applications. *arXiv Prepr.*, arXiv:1704.04861
- Huang, G., Liu, Z., Van Der Maaten, L., Weinberger, K.Q. 2017.** Densely connected convolutional networks. *IEEE Conference on Computer Vision and Pattern Recognition*, 4700-4708.
- Karadağ, K., Keskinbıçak, F. 2023.** Estimation chickpea species and productivity per decare with synthetic data generation methods. *C. R. Acad. Bulg. Sci.*, 76(1): 146-155.
- Kaya, A., Çelik, A., Özkaya, U., Yigit, E. 2022.** Derin öğrenme ile tahıl ayıklama, 1st International Conference on Engineering and Applied Natural Sciences (ICAENS 2022), Konya, Türkiye, 2501-2508.
- Kılıç, İ. 2024.** TRCS_5_SET. https://github.com/ibrahimkilig/TRCS_5_SET
- Kılıç, İ., Yalçın, N. 2023.** Evrimsel sinir ağları tabanlı nohut çeşitleri sınıflandırması. *Innovations in Intelligent Systems and Applications Conference (ASYU 2023)*, Sivas, Türkiye. IEEE. Doi: 10.1109/ASYU58738.2023.10296680
- LeCun, Y., Bengio, Y., Hinton, G. 2015.** Deep learning. *Nature*, 521: 436-444. Doi: 10.1038/nature14539
- Narin, A., Kaya, C., Pamuk, Z. 2021.** Automatic detection of coronavirus disease (COVID-19) using X-ray images and deep convolutional neural networks. *Pattern Anal. Applic.*, 24: 1207-1220. Doi: 10.1007/s10044-021-00984-y
- Saha, D., Manickavasagan, A. 2022.** Chickpea varietal classification using deep convolutional neural networks with transfer learning. *J. Food Process Eng.*, 45(3): e13975. Doi: 10.1111/jfpe.13975
- Saha, D., Mangukia, M.P., Manickavasagan, A. 2023.** Real-time deployment of MobileNetV3 model in edge computing devices using RGB color images for varietal classification of chickpea. *Appl. Sci.*, 13(3): 7804. Doi: 10.3390/app13137804
- Selvaraju, R.R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., Batra, D. 2017.** Grad-CAM: visual explanations from deep networks via gradient-based localization. *IEEE International Conference on Computer Vision*, 618-626.
- Singh, D., Taspınar, Y.S., Kursun, R., Cinar, I., Koklu, M., Ozkan, İ.A., Lee, H.N. 2022.** Classification and analysis of pistachio species with pre-trained deep learning models. *Electronics*, 11: 981. Doi: 10.3390/electronics11070981

- Simonyan, K., Zisserman, A. 2015.** Very deep convolutional networks for large-scale image recognition. International Conference on Learning Representations, 1-14.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. 2014.** Dropout: a simple way to prevent neural networks from overfitting. *J. Mach. Learn. Res.*, 15: 1929-1958.
- Szegedy, C., Ioffe, S., Vanhoucke, V., Alemi, AA. 2017.** Inception-v4, inception-ResNet and the impact of residual connections on learning. AAAI Conference On Artificial Intelligence, San Francisco, California, USA, 4278-4284.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A. 2015.** Going deeper with convolutions. IEEE Conference on Computer Vision and Pattern Recognition, 1-9.
- Taheri-Garavand, A., Nasiri, A., Fanourakis, D., Fatahi, S., Omid, M., Nikoloudakis, N. 2021.** Automated in situ seed variety identification via deep learning: a case study in Chickpea. *Plants*, 10(7): 1406. Doi: 10.3390/plants10071406
- Tan, M., Le, QV. 2019.** EfficientNet: rethinking model scaling for convolutional neural networks. International Conference on Machine Learning, 6105-6114.
- Tuğrul, B., Sivari, E., Akca, S., Eryigit, R. 2022.** Classification of dianthus seed species with deep transfer learning. SSRN. Doi: 10.2139/ssrn.4173707
- Xu, P., Yang, R., Zeng, T., Zhang, J., Zhang, Y., Tan, Q. 2021.** Varietal classification of maize seeds using computer vision and machine learning techniques. *J. Food Process Eng.*, 44(11): e13846. Doi: 10.1111/jfpe.13846
- Yaşar, A. 2023.** Benchmarking analysis of CNN models for bread wheat varieties. *Eur. Food Res. Technol.*, 249: 749-758. Doi: 10.1007/s00217-022-04172-y
- Zhang, A., Lipton, ZC., Li, M., Smola, AJ. 2023.** Dive into deep learning. Cambridge University Press.
- Zhang, X., Zhou, X., Lin, M., Sun, J. 2018.** ShuffleNet: an extremely efficient convolutional neural network for mobile devices. IEEE Conference on Computer Vision and Pattern Recognition, 6848-6856.
- Zoph, B., Le, QV. 2017.** Neural architecture search with reinforcement learning. International Conference on Learning Representations.
- Zoph, B., Vasudevan, V., Shlens, J., Le, QV. 2018.** Learning transferable architectures for scalable image recognition. IEEE Conference on Computer Vision and Pattern Recognition, 8697-8710.