



Fındık Meyvesinin Sınıflandırılmasında Shufflenet ve Densenet Derin Öğrenme Algoritmalarının Performansının Karşılaştırılması

Comparison of The Performance of Shufflenet and Densenet Deep Learning Algorithms in The Classification of Hazelnut Fruit

Özgür TOMAK¹

¹Teknik Bilimler Meslek Yüksekokulu, Elektrik ve Enerji Bölümü, Giresun Üniversitesi, Giresun, TÜRKİYE

ozgur.tomak@giresun.edu.tr —ORCID> [0000-0003-2993-6913](https://orcid.org/0000-0003-2993-6913)

Makale Bilgisi / Article Information

Makale Türü / Article Types	Araştırma Makalesi / Research Article
Alınış Tarihi / Received	11 Haziran / June 2025
Kabul Tarihi / Accepted	01 Ekim / November 2025

Yıl / Year: 2025 | **Cilt / Volume:** 2 | **Sayı / Issue:** 2 | **Sayfa / Pages:** 96-102

Atıf Formatı / Cite as: Ö. Tomak, "Fındık meyvesinin sınıflandırılmasında ShuffleNet ve DenseNet derin öğrenme algoritmalarının performansının karşılaştırılması," *Hendese Journal of Technical Sciences and Engineering*, Vol. 2, No. 2, pp. 96–102, 2025, doi: 10.5281/zenodo.17474580.

Sorumlu Yazar / Corresponding Author: Özgür TOMAK

Fındık Meyvesinin Sınıflandırılmasında Shufflenet ve Densenet Derin Öğrenme Algoritmalarının Performansının Karşılaştırılması

Özgür TOMAK¹ 

¹Teknik Bilimler Meslek Yüksekokulu, Elektrik ve Enerji Bölümü, Giresun Üniversitesi, Giresun, TÜRKİYE

(Alınış / Received: 11.06.2025, Kabul / Accepted: 01.10.2025, Online Yayınlanma / Published Online: 30.10.2025)

Anahtar Kelimeler

Fındık,
Sınıflandırma,
Derin Öğrenme,
Shufflenet,
DenseNet

ÖZ

Yapay zekâ kullanımıyla fındık meyvesinin sınıflandırılması, verimliliğinin artırılması mümkün olabilir. Bu çalışmadaki amacımız fındık meyvesinin sınıflandırılmasında kullanılabilecek bir otomatik sınıflandırma sistemi için bir yöntem önermektir. Fındık meyvesinin sınıflandırılmasında derin öğrenme algoritmalarının kullanılması, tarım ve gıda endüstrisinde kalite kontrol, otomatik ayıklama ve verimlilik artırma gibi alanlarda önemli bir rol oynayabilir. Yapay zekânın fındık görüntülerini analiz etmesinde kullanılabilecek derin öğrenme algoritmaları incelenmiştir. Shufflenet ve DenseNet derin öğrenme algoritmalarının fındık meyvesine ait veri tabanında performansları karşılaştırılmıştır. Analizler sonucunda ShuffleNet eğitimde % 99.79, test aşamasında % 99.94 doğruluğa ulaşmıştır. DenseNet ise eğitimde % 99.98, test aşamasında % 99.95 doğruluğa ulaşmıştır. Fındık meyvesinin sınıflandırılmasında derin öğrenmenin, insan gözünden daha hızlı ve tutarlı sonuçlar verebileceği sonucuna ulaşabiliriz.

Comparison of The Performance of Shufflenet and Densenet Deep Learning Algorithms in The Classification of Hazelnut Fruit

Keywords

Hazelnut,
Classification,
Deep Learning,
Shufflenet,
DenseNet

ABSTRACT

It may be possible to increase the efficiency of hazelnut fruit classification by using artificial intelligence. Our aim in this study is to propose a method for an automatic classification system that can be used in the classification of hazelnut fruit. The use of deep learning algorithms in hazelnut fruit classification can play an important role in areas such as quality control, automatic sorting, and efficiency enhancement in the agricultural and food industry. Deep learning algorithms that can be used in the analysis of hazelnut images by artificial intelligence were examined. The performances of Shufflenet and DenseNet deep learning algorithms on the hazelnut fruit database were compared. As a result of the analysis, ShuffleNet achieved 99.79% accuracy in training and 99.94% in the test phase. DenseNet achieved 99.98% accuracy in training and 99.95% in the test phase. We can conclude that deep learning can provide faster and more consistent results than the human eye in the classification of hazelnut fruit.



Published by Muş Alparslan University, Muş, Türkiye
This is an open access article under the CC BY-NC license

*Corresponding Author / Sorumlu Yazar: ozgur.tomak@giresun.edu.tr

Cilt / Volume: 2

Sayı / Issue: 2

Atıf Formatı/Cite as: Ö. Tomak, "Fındık meyvesinin sınıflandırılmasında ShuffleNet ve DenseNet derin öğrenme algoritmalarının performansının karşılaştırılması," *Hendese Journal of Technical Sciences and Engineering*, Vol. 2, No. 2, pp. 96–102, 2025, doi: 10.5281/zenodo.17474580.

Doi: 10.5281/zenodo.17474580

1. GİRİŞ

1.1. Sınıflandırma

Fındık meyvelerinin görüntülerinin yapay zekâ tarafından analiz edilmesiyle boyut, renk ve kalite gibi özelliklerine göre sınıflandırılabilir. Bu, insan gözüyle yapılan sınıflandırmaya göre daha doğru ve hızlı sonuçlar elde edilmesini sağlayabilir. Makine öğrenimi algoritmalarıyla ve toplanan veriler analiz edilerek, belirli koşullar altında yetişecek en iyi ürünler belirlenebilir. Fındık ağaçlarının sağlık durumunu gözlemlenerek, hastalıkların yayılmasını önlemeye mümkün olabilir. Fındık toplama ve işleme süreçlerinde otomasyon kullanımı için yapay zekâ destekli cihazlar tercih edilebilir. Bunun, iş gücünü azaltması ve maliyetleri düşürmesi mümkün olabilir.

1.2. Literatür Çalışmaları

Bu bölümde fındık meyvelerini sınıflandırma alanında yapılmış çalışmalar incelenmiştir.

Khosa, I., ve Eros P. [1] yaptıkları fındıklar için x-ışını görüntülerinde özellik çıkarma sınıflandırması ile fındık çeşitlerini sınıflandırmışlardır. Veriler X-ışını görüntüleri ile elde edilen 748 adet sağlıklı görüntü içermektedir. Fındık ürünlerinde, 20 adet hasarlı fındık ve 20 adet enfekte fındık görüntüsü kullanılmıştır. Örneklerin %95'i sadece "iyi" kategorisine aittir. %5'lik bir örnek "kötü" kategorisinde bulunmuştur. Bu veriler için seçilen bozuk fındıkların tespiti için anomali tespit algoritması kullanılmıştır.

Bayrakdar ve ark. [2], çalışmalarında görüntüler aracılığıyla 3 farklı fındık türünü (Tombul, sivri ve badem tipi) sınıflandırmışlardır. Tombul, sivri ve badem tipi fındık çeşitlerine ait görüntülerden çap, yarıçap, alan gibi şekil ve boyut özelliklerini kullanarak %84'lük bir doğruluk oranına ulaşmışlardır.

Caner, K. O. C ve ark. [3] çalışmalarında fındık meyvesini fotoğrafları aracılığıyla kabuğuyla birlikte sınıflandıran bir sistem geliştirmişlerdir. Tombul sivri ve kara fındık çeşitlerini makine öğrenmesi ve derin öğrenme yöntemlerini kullanarak sınıflandırmışlardır. Çalışmalarında Bagging yöntemi (Rastgele orman) kullanarak %83 ve DL4J (Derin öğrenme algoritması) kullanarak %71 sınıflandırma doğruluğu elde etmiştir.

Solak S. ve Altunışık U. [4] çalışmalarında 25 fındık ürününe ait görselleri kullanmış ve bu fındıkları büyük, orta ve küçük olmak üzere sınıflandırmışlardır. Söz konusu görüntüler Ubuntu 12.04 çalıştıran bir bilgisayarda işlenmiştir. Görüntülerin işlenmesi ve sınıflandırılmasında OpenCV Kütüphanesi ve Weka yazılımı kullanılmıştır. Ortalama taban ve K-ortalama kümeleme yöntemleri kullanılarak fındık meyveleri küçük, orta ve büyük olmak üzere sınıflandırılmıştır. Bu çalışmada iki algoritmanın ve sınıflandırmanın %90 ile %100 arasında benzerlik gösterdiği belirlenmiştir.

Kamilaris ve Prenafeta-Boldú [5], derin öğrenmenin tarımda kullanımı üzerine yaptıkları kapsamlı derlemede, CNN modellerinin bitki hastalıklarını tespit etmede ve ürün

sınıflandırmasında oldukça başarılı olduğunu göstermiştir. Transfer öğrenme yöntemlerinin özellikle küçük veri setlerinde etkinliği vurgulanmıştır.

Ferentinos [6], bitki hastalıklarının teşhisinde 58.000'den fazla görüntü üzerinde 5 farklı CNN mimarisini karşılaştırmıştır. VGGNet, AlexNet, GoogLeNet ve benzeri ağlar %99'a varan doğruluklar sunmuştur. Bu çalışma, fındık gibi nispeten az görüntü içeren veri setlerinde ön eğitilmiş model kullanımının önemini ortaya koymaktadır.

Keles ve Taner [7], çalışmalarında fındık çeşitlerini kategorize etmek için yapay sinir ağları ve ayırıcı analiz kullandılar. 11 fındık çeşidinin fiziksel, mekanik ve görsel özelliklerinin üç ana eksenini belirlendi. Fındık çeşitleri bağımlı değişkenler olarak ve fiziksel, mekanik ve optik özellik parametreleri bağımsız değişkenler olarak dahil edildi. Çok sayıda fındık çeşidini kategorize etmek için üç eksenin her biri için modeller yapıldı. Diskriminant Analizi ve Yapay Sinir Ağları sırayla X ekseninde %92,7 ile %89,1 ve Y ekseninde %92,7 ile %92,7 son olarak Z ekseninde %88,7 ile %86,8 sınıflandırma başarı oranına sahiptir.

2. MATERYAL VE METOT

Yapay zekânın fındık görüntülerini analiz etmesi sürecinde derin öğrenme yöntemleri incelenmiştir, Shufflenet ve Densenet derin öğrenme algoritmalarının fındık meyvesine ait veri tabanında performansları karşılaştırılmıştır.

2.1. Shufflenet

ShuffleNet, parametre sayısını ve hesaplama yükünü azaltır. Doğruluğu korurken hesaplama maliyetini azaltmada iki yeni işlem olan nokta temelli grup evrişimi ve kanal karıştırmayı kullanır [8]. Temel yapı taşı olan ShuffleNet bloğu, derinlik yönlendirmeli ayrık (depthwise separable) konvolüsyonlar kullanır. Bu konvolüsyonlar, giriş özellik haritalarını daha küçük boyutlarda işlemekte, böylece hesaplama verimliliğini artırmaktadır. Ağırlıkların karıştırılması (shuffle) işlemiyle, farklı özellik haritalarının bir araya getirilmesi sağlanır. Bu, ağırlık daha iyi genel performans göstermesine yardımcı olmaktadır. ShuffleNet biriminde ilk ve ikinci 1×1 evrişimler grup evrişimleriyle değiştirilmekte ve ilk 1×1 evrişimden sonra bir kanal karışırması uygulanmaktadır. Adım sayısı=2 ile ShuffleNet biriminde kısayol yoluna 3×3 ortalama havuzlama eklenir ve eleman bazında ekleme, kanal boyutunu çok az ek hesaplama maliyetiyle genişletmeyi kolaylaştıran kanal birleştirme ile değiştirilir.

ShuffleNet'teki "kanal karıştırma" işlemi, modelin hafif ve verimli olmasını sağlamak için kullanılan kritik bir mekanizmadır. Özellikle düşük hesaplama kapasitesine sahip cihazlarda yüksek performans sunmayı hedefleyen ShuffleNet, bu işlem sayesinde bilgi akışını çeşitlendirirken ekstra parametre maliyeti eklemeyi. ShuffleNet, grup evrişimleri (group convolutions) kullanarak hesaplama maliyetini azaltır. Ancak grup evrişimlerinin bir dezavantajı vardır: Her grup yalnızca kendi alt kümesi içinde işlem yapar, bu da gruplar arasında bilgi akışını engeller. Bu durum, modelin öğrenme kapasitesini düşürür.

Avantajlarına bakarsak ilk olarak hesaplama verimliliğinden bahsedebiliriz. Grup Konvolüsyonları ve kanal karıştırma kullanarak parametre sayısını ve FLOPs'u (floating point operations) azaltır.

Düşük hesaplama gücü gerektiren cihazlar (mobil cihazlar, gömülü sistemler) için uygundur. Standart CNN'lere (ör. ResNet) göre daha az bellek kullanır. Gerçek zamanlı uygulamalarda (örn. nesne tanıma, yüz tanıma) yüksek hız sağlar. Kanal karıştırma, gruplar arasında bilgi akışını artırarak özellik öğrenimini iyileştirir.

Dezavantajlarına bakarsak Parametrelerin azaltılması, bazen daha büyük modellere kıyasla doğrulukta düşüşe neden olabilir. Kanal karıştırma mekanizması, modelin anlaşılabilirliğini ve uygulanabilirliğini zorlaştırabilir. Çok derin versiyonlarında performans artışı sınırlı olabilir.

2.2. DenseNet

DenseNet, derin öğrenme alanında kullanılan bir konvolüsyonel sinir ağı (CNN) mimarisidir. DenseNet, her katmanın çıktısını, onu takip eden tüm katmanlara besleyerek yoğun bağlantılar oluşturur. Bu sayede, her katman önceki tüm katmanların özelliklerine erişebilir. Yoğun bağlantılar, daha az parametre ile daha derin ağlar oluşturulmasını sağlar. Bu, modelin öğrenme kapasitesini artırırken, aşırı öğrenme riskini azaltır. ℓ . Katman, önceki tüm katmanların özellik haritalarını, $x_0, \dots, x_{\ell-1}$, girdi olarak alır. Denklem 1'de verilen $H_\ell(\cdot)$, Toplu Normalizasyon gibi işlemlerin bileşik bir fonksiyonu olabilir.

$$x_\ell = H_\ell([x_0, \dots, x_{\ell-1}]) \quad (1)$$

DenseNet'teki "Yoğun Bağlantılar" kavramı, geleneksel evrişimli ağların (CNN) aksine, bir katmanın çıktısının yalnızca sonraki katmana değil, ilerideki tüm katmanlara doğrudan bağlanmasını sağlayan bir mimari özelliktir. Bu yapı, bilgi akışını maksimize ederek gradient kaybını (vanishing gradient) önler ve özelliklerin yeniden kullanımını artırır. DenseNet'te her katman, kendinden önceki tüm katmanların özellik haritalarını girdi olarak alır ve kendi çıktısını tüm sonraki katmanlara iletir. Bu, katmanlar arasında tam bir "bağlılık grafiği" oluşturur. Her katman, önceki tüm katmanların çıktılarını kanal ekseninde birleştirir. Yoğun bağlantılar kanal sayısını katlanarak artırabileceğinden, DenseNet 1x1 evrişimlerle kanal sayısını kontrol eder (bottleneck). Bloklar arasında ortalama havuzlama (average pooling) ve 1x1 evrişimle boyut küçültme yapılır.

Avantajlarına bakarsak (yoğun bağlantılar), önceki tüm katmanlardan gelen özellik haritalarını birleştirerek gradient kaybını (vanishing gradient) azaltır. Derin ağlarda bile yüksek doğruluk sağlar. Katmanlar arası bilgi akışı sayesinde daha az parametreyle yüksek performans elde eder. Her katman

doğrudan loss fonksiyonuna erişebildiğinden, eğitim süreci daha karardır.

Dezavantajlarına bakarsak Katman çıktılarının birleştirilmesi, bellek kullanımını artırır (özellikle derin ağlarda). Gerçek zamanlı uygulamalarda ShuffleNet'e göre daha yavaş çalışabilir. Çok sayıda concatenation işlemi, FLOPs'u artırabilir. Büyük modellerin eğitimi için yüksek GPU belleği gerekir.


DenseNet, ağ, özellikleri yeniden kullanarak bilgi kaybını en aza indirir. Bu, modelin daha verimli öğrenmesini sağlar. DenseNet, çeşitli derinliklerde mevcut olup, bu sayede farklı görevler için uygun hale getirilebilir. DenseNet'in bu özellikleri, derin öğrenme uygulamalarında popüler hale gelmesini sağlamıştır. Özellikle görüntü sınıflandırma, nesne algılama ve segmentasyon gibi alanlarda etkili bir şekilde kullanılır.

ShuffleNet, düşük kaynaklı ortamlarda (IoT, mobil) tercih edilir. DenseNet, yüksek doğruluk gerektiren ve kaynağın bol olduğu (sunucu, bulut) senaryolarda üstündür. Model seçimi, hesaplama kısıtları, doğruluk gereksinimi ve donanım kapasitesine bağlıdır. Tablo 1'de ShuffleNet ve DenseNet Karşılaştırma Özeti verilmiştir.

Endüstriyel uygulanabilirlik açısından gerçek zamanlı sınıflandırma gerektiren ortamlarda, ShuffleNet mimarisi düşük hesaplama maliyeti ve hızlı tahmin süresi ile öne çıkmaktadır. Bu nedenle yerleşik sistemler (embedded systems), mobil tarım robotları veya otomatik ayıklama makineleri için uygundur. DenseNet ise daha fazla hesaplama gücü gerektirdiğinden, bu mimari ancak sunucu tabanlı sistemlerde veya yüksek donanımlı cihazlarda uygulanabilir. Görsel kalite kontrol yazılımları için daha uygun olabilir.

Tablo 1. ShuffleNet ve DenseNet karşılaştırma özeti.

Özellik	ShuffleNet	DenseNet
Hız	Daha hızlı (mobil uyumlu)	Göreceli olarak yavaş
Doğruluk	Sınırlı (küçük modellerde)	Yüksek (özellikle büyük modellerde)
Bellek Kullanımı	Düşük	Yüksek
Ölçeklenebilirlik	Derin ağlarda sınırlı	Derin ağlarda başarılı
Kullanım Alanı	Mobil cihazlar, edge AI	Sunucu tabanlı yüksek performans



Şekil 1. DenseNet mimarisinin şematik gösterimi [9].

*Bu yapı, katmanlar arası yoğun bağlantılar sayesinde bilgi kaybını azaltır ve daha iyi özellik öğrenimi sağlar.

2.3. Veri Seti

Görüntüler 3024 x 3024 piksel çözünürlükte çekilmiştir. Bir platform yardımıyla, telefonun kamerası dikey olarak aşağıya bakacak şekilde 10 cm ile 8 cm arasında bir yükseklikten manuel olarak fotoğraflar çekilmiştir. Çalışma için gerekli veriler, Aralık ayında beş günlük bir süre içerisinde gündüz saatlerinde çekilmiş fındık meyvesi fotoğraflarından elde edilmiştir. Bu veriler elde edilirken, cep telefonunun arka yüzündeki ana kamera kullanılmıştır. Kullanılan kameranın çözünürlüğü 12 megapikseldir. Her görüntüde bir tane fındık bulunur. Bu fındıklar, bir uzman tarafından kötü fındıklar, iyi fındıklar, iç fındıklar şeklinde üç sınıfa ayrılmıştır. 519 adet kötü fındık, 535 adet iyi fındık ve 523 adet iç fındık kullanılarak bir veri seti oluşturulmuştur. Her bir fındıktan alınan farklı açılarda 10 görüntü ile toplam 15770 adet görüntü elde edilmiştir. Görüntüler önce işlenerek önce 1000 x 1000 piksel boyutuna kırpılmış sonra 224 x 224 piksele yeniden boyutlandırılmıştır. İlgili internet adresinden verilere ulaşılabilir. <https://data.mendeley.com/datasets/dvxx6kst3f/2> Kullanılan fındıklardan bazılarına ait görüntüler Şekil 2’de verilmiştir [10]. Tablo II’de fındıklardan alınan görüntü sayısı dağılımı verilmiştir.

Tablo II. Fındıklardan alınan görüntü sayısı.

	Fındık sayısı	Her bir fındığın görüntü sayısı	Toplam görüntü sayısı
İyi fındık	535	10	5350
Kötü fındık	519	10	5190
İç fındık	523	10	5230

3. Çalışma ve Bulgular

Veri tabanı üç farklı sınıfa sahiptir ve toplamda 15770 adet görüntüye sahiptir. Çalışmada derin öğrenme algoritmalarından DenseNet ve ShuffNet kullanılmıştır. Çalışma ortamı olarak MATLAB kullanılmıştır. Veri seti rastgele karıştırılarak % 30’u eğitim kalan kısım test amacıyla kullanılmıştır. Algoritmaların fındık meyvesi veri tabanındaki eğitim ve test doğrulukları karşılaştırılmıştır. ShuffNet ve DenseNet ile yapılan analizlerde Stochastic Gradient Descent with Momentum (SGDM) kullanılmıştır. Bu yöntemde momentum, geçmiş gradyan güncellemelerini dikkate alarak öğrenme sürecini hızlandırır. Böylece pürüzsüz bir şekilde öğrenme sağlanır ve yerel minimumlara takılma olasılığı azalır. Temel olarak, gradyan güncellemesi, önceki güncellemelerin bir kombinasyonu ile birleştirilir. Sonuçlara bakarsak ShuffNet


eğitimde % 99.79, test aşamasında % 99.94 doğruluğa ulaşmıştır. Şekil 3’de doğruluk grafiği verilmiştir. DenseNet eğitimde % 99.98, test aşamasında % 99.95 doğruluğa ulaşmıştır. Şekil 4’de doğruluk grafiği verilmiştir.

Algoritmaların performansını ölçmek için karmaşıklık matrisi (Confusion Matrix) kullanılmıştır ve doğruluk, hassaslık, özgünlük, F1 skor ölçütlerine ulaşılmıştır. Karmaşıklık matrisi, bir sınıflandırma modelinin performansını değerlendirmek için kullanılan temel bir araçtır. Gerçek ve tahmin edilen sınıflar arasındaki ilişkiyi gösterir. Performans ölçütleri ise bu matris üzerinden hesaplanarak modelin başarısını niceler. Doğruluk, modelin tüm örneklerdeki doğru tahmin oranıdır. Hassaslık, pozitif tahminlerin ne kadarının doğru olduğunu gösterir. Özgünlük, gerçek negatiflerin ne kadarının doğru tanımlandığını gösterir. F1-Skoru, harmonik ortalama değerini verir. Burada TP (True Positive) gerçek pozitif değeri, FP (False positive) yanlış pozitif değeri, TN (True negative) gerçek negatif değeri ve FN (False negative) yanlış negatif değeri ifade etmektedir [7]. Karmaşıklık matrisi Tablo III’de ve doğruluk, hassaslık, özgünlük, F1-skor matematiksel ifadeleri Denklem 2-5’de verilmiştir. Şekil 5’de ShuffNet’e ait karmaşıklık matrisi verilmiştir. Şekil 6’da DenseNet’e ait karmaşıklık matrisi verilmiştir.

Karmaşıklık matrisine göre Shufflenet 0.9997 hassaslık, 0.9994 özgünlük, 0.9997 F1-skor değerine ve DenseNet, 0.9989 hassaslık, 1 özgünlük, 0.9994 F1-skor değerine sahiptir.


Tablo III. Karmaşıklık matrisi [11].

		Tahmini durum	
		Pozitif	Negatif
Gerçek Durum	Pozitif	TP (Gerçek Pozitif)	FN (Yanlış Negatif)
	Negatif	FP (Yanlış Pozitif)	TN (Gerçek Negatif)




Şekil 2. Kullanılan fındık veri tabanından örnek görüntüler [10].

*Görseller, farklı açılardan çekilmiş iyi, kötü ve iç fındıkları temsil etmektedir.



Şekil 3. ShuffleNet eğitim ve test doğruluk grafiği.

*Modelin hızlı öğrenme eğrisi ve yüksek doğruluğu gözlemlenmektedir.



Şekil 4. Densenet eğitim ve test doğruluk grafiği.

*Derin bağlantıların etkisiyle yüksek performanslı sonuçlar elde edilmiştir.

Confusion Matrix				
Output Class	damaged _n uts	nuts _k emel	quality _n uts	
	3632 32.9%	1 0.0%	1 0.0%	99.9% 0.1%
	0 0.0%	3657 33.1%	1 0.0%	100.0% 0.0%
	1 0.0%	3 0.0%	3743 33.9%	99.9% 0.1%
				Target Class
				damaged _n uts
				nuts _k emel
				quality _n uts

Şekil 5. ShuffleNet için karmaşıklık matrisi.

*Üç sınıf için sınıflandırma başarıları oldukça yüksektir.

Confusion Matrix				
Output Class	damaged _n uts	nuts _k emel	quality _n uts	
	3633 32.9%	0 0.0%	4 0.0%	99.9% 0.1%
	0 0.0%	3660 33.2%	0 0.0%	100% 0.0%
	0 0.0%	1 0.0%	3741 33.9%	100.0% 0.0%
				Target Class
				damaged _n uts
				nuts _k emel
				quality _n uts

Şekil 6. Densenet için karmaşıklık matrisi.

*Modelin sınıflandırma doğruluğu oldukça yüksektir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+FP+FN+TN} \quad (2)$$

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

$$\text{Özgünlük} = \frac{TN}{TN+FP} \quad (4)$$

$$\text{F1 skor} = 2 * \frac{\text{Hassaslık} * \text{Özgünlük}}{\text{Hassaslık} + \text{Özgünlük}} \quad (5)$$

Analizler sırasında kullanılan Matlab içerisindeki ShuffleNet, ImageNet veritabanından bir milyondan fazla görüntü üzerinde eğitilmiş bir evrişimli sinir ağıdır. Ağ, görüntüleri klavye, fare, kalem ve birçok hayvan gibi 1000 nesne kategorisine ayırabilir. Sonuç olarak, ağ çok çeşitli görüntüler için zengin özellik temsilleri öğrenmiştir. Ağın görüntü girişi boyutu 224x224'tür. Eğitilmiş modele erişim için [net, classes] = imagePretrainedNetwork ("shufflenet"); komutu kullanılmaktadır. Matlab içerisindeki DenseNet, aynı şekilde ImageNet veritabanından bir milyondan fazla görüntü üzerinde eğitilmiştir. Sonuç olarak, ağ çok çeşitli görüntüler için zengin özellik temsilleri öğrenmiştir. Ağın görüntü girişi boyutu aynı şekilde 224x224'tür. Eğitilmiş modele erişim için yine benzer [net, classes] = imagePretrainedNetwork ("densenet201"); komutu kullanılmaktadır.

4. SONUÇ

Fındık meyvesi depolama aşamasından önce ayrıştırılmalıdır. Ayrıştırma sürecinde kötü fındık veya iç fındık bulunursa ayrılmalıdır. Kötü fındık ayrılmazsa randıman düşük gelecektir. İç fındık temizlenmezse depolama aşamasında bu fındıklar bozulabilir. Bu işlem için kullanılabilirliği muhtemel iki derin öğrenme algoritması DenseNet ve Shufflenet karşılaştırılmıştır. Analizler sonucunda ShuffleNet eğitimde % 99.79, test aşamasında % 99.94 doğruluğa ulaşmıştır. DenseNet eğitimde % 99.98, test aşamasında % 99.95 doğruluğa ulaşmıştır. Karmaşıklık matrislerine bakarsak göre Shufflenet 0.9997 hassaslık, 0.9994 özgünlük, 0.9997 F1-skor değerine ve DenseNet, 0.9989 hassaslık, 1 özgünlük, 0.9994 F1-skor değerine sahiptir. Yöntemin diğer çalışmalarla karşılaştırılması çizelge 4'de verilmiştir. DenseNet bu analizlerde ufak bir farkla da olsa daha iyi sonuçlar verdi. Ama ShuffleNet derin öğrenme algoritmasının, DenseNet derin öğrenme algoritmasına göre daha hızlı olduğunu görüldü. ShuffleNet, özellikle mobil cihazlarda ve gömülü sistemlerde kullanılabilirliği açısından avantaj sağlarken; DenseNet, derinlik ve parametre verimliliği sayesinde sınıflandırma görevlerinde üstün başarı sağlamaktadır.

Tablo IV. Yöntemin karşılaştırılması.

Referans	Ürün	Yöntem	Doğruluk (%)
[1]	Fındık	Anomali Tespiti	%95
[2]	Fındık	Şekil ve boyut özellikleri	%84
[3]	Fındık	Bagging/ DL4J	%83 (Bagging), %71 (DL4J)

Referans	Ürün	Yöntem	Doğruluk (%)
[4]	Fındık	Kümeleme (OpenCV + Weka)	%90-100
[6]	Bitki hastalıkları	CNN	%99
[7]	Fındık	Diskriminant Analizi ve Yapay Sinir Ağları	%86-93
Bu Çalışma	Fındık	ShuffleNet/DenseNet	%99.94 / %99.95

KAYNAKLAR

- [1] I. Khosa and E. Pasero, "Feature extraction in X-ray images for hazelnuts classification," in *Proc. 2014 International Joint Conference on Neural Networks (IJCNN)*, Beijing, China, 2014, pp. 2354–2360, doi: [10.1109/IJCNN.2014.6889661](https://doi.org/10.1109/IJCNN.2014.6889661).
- [2] S. Bayrakdar, B. Çomak, D. Başol, and İ. Yücedağ, "Determination of type and quality of hazelnut using image processing techniques," in *Proc. 2015 23rd Signal Processing and Communications Applications Conference (SIU)*, Malatya, Turkey, 2015, pp. 616–619, doi: [10.1109/SIU.2015.7129899](https://doi.org/10.1109/SIU.2015.7129899).
- [3] C. Koç, D. Gerdan, M. B. Eminoglu, U. Yegül, B. Koç, and M. Vatandaş, "Classification of hazelnut cultivars: comparison of DL4J and ensemble learning algorithms," *Notulae Botanicae Horti Agrobotanici Cluj-Napoca*, vol. 48, no. 4, pp. 2316–2327, Dec. 2020, doi: [10.15835/nbha48412041](https://doi.org/10.15835/nbha48412041).
- [4] S. Solak and U. Altınışık, "Detection and classification of hazelnut fruit by using image processing techniques and clustering methods," *Sakarya University Journal of Science*, vol. 22, no. 1, pp. 56–65, Feb. 2018, doi: [10.16984/sofenbilder.303850](https://doi.org/10.16984/sofenbilder.303850).
- [5] A. Kamilaris and F. X. Prenafeta-Boldú, "Deep learning in agriculture: A survey," *Computers and Electronics in Agriculture*, vol. 147, pp. 70–90, Apr. 2018, doi: [10.1016/j.compag.2018.02.016](https://doi.org/10.1016/j.compag.2018.02.016).
- [6] K. P. Ferentinos, "Deep learning models for plant disease detection and diagnosis," *Computers and Electronics in Agriculture*, vol. 145, pp. 311–318, Feb. 2018, doi: [10.1016/j.compag.2018.01.009](https://doi.org/10.1016/j.compag.2018.01.009).
- [7] O. Keles and A. Taner, "Classification of hazelnut varieties by using artificial neural network and discriminant analysis," *Spanish Journal of Agricultural Research*, vol. 19, no. 4, e0211, 2021, doi: [10.5424/sjar/2021194-18056](https://doi.org/10.5424/sjar/2021194-18056).
- [8] X. Zhang, X. Zhou, M. Lin, and J. Sun, "ShuffleNet: An extremely efficient convolutional neural network for mobile devices," *arXiv preprint*, arXiv:1707.01083, Dec. 2017, doi: [10.48550/arXiv.1707.01083](https://doi.org/10.48550/arXiv.1707.01083).
- [9] G. Huang, Z. Liu, L. van der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," *arXiv preprint*, arXiv:1608.06993, Jan. 2018, doi: [10.48550/arXiv.1608.06993](https://doi.org/10.48550/arXiv.1608.06993).
- [10] E. Güneş, *Hazelnuts Dataset (Version 2)*, Marmara University, Jun. 2022. [Online]. Available: <https://doi.org/10.17632/dvnx6kst3f.2>.
- [11] Ö. Tomak, "Elektrokardiyografi sinyallerinde deneysel mod ayrıştırma ve geliştirilmiş karar ağaçları kullanarak aritmi tespiti," *Karadeniz Fen Bilimleri Dergisi*, vol. 9, no. 1, pp. 103–110, 2019.