https://doi.org/10.30546/19023.978-9952-8573-5-1.2025.8988.
ISBN: 978-9952-8573-6-8

SELECTION OF THE MOST SUITABLE PARAMETERS FOR CLASSIFICATION OF HAZELNUT FRUIT USING SHUFFLENET DEEP LEARNING ALGORITHM

Özgür Tomak[1*], Mehmet Cem Dikbaş [2],Sercan Külcü [3]

[*1] Giresun University, Computer Engineering, Giresun, Türkiye
[2] Giresun University, Electrical and Electronics Engineering, Giresun, Türkiye
[3] Giresun University, Computer Engineering, Giresun, Türkiye
https://orcid.org/0000-0003-2993-6913
https://orcid.org/0000-0003-4525-7996
https://orcid.org/0000-0002-4871-709X

ABSTRACT

It may be possible to increase efficiency or improve quality control processes by using artificial intelligence to classify hazelnut fruits. Our aim in this study is to select the appropriate parameters in the classification of hazelnut fruits using the Shufflenet deep learning algorithm. ShuffleNet is a convolutional neural network designed for devices with limited processing power and uses fewer resources by reducing the number of parameters and computational load. In the data used, there is one hazelnut in each image. These hazelnuts are divided into three classes as good and bad hazelnuts and inner hazelnuts. A data set was created using 519 bad hazelnuts, 535 good hazelnuts and 523 inner hazelnuts. A total of 15770 images were obtained with 10 images taken from different angles from each hazelnut. As a result of the analysis, ShuffleNet with SGDM reached 99.79% accuracy in training and 99.94% in the test phase. ShuffleNet with ADAM reached 99.89% accuracy in training and 99.96% accuracy in the test phase. ShuffleNet with RMSprop reached 99.89% accuracy in training and 99.92% accuracy in the test phase. According to the complexity matrices, ShuffleNet with SGDM has 0.9997 precision, 0.9994 specificity, and 0.9997 F1-score. ShuffleNet with ADAM has 0.9997 precision, 1 specificity, and 0.9998 F1-score. With RMSprop, ShuffleNet has a sensitivity of 0.9997, a specificity of 0.9998, and an F1-score of 0.9997. Although the overall results are close, it has been observed that ShuffleNet algorithm with ADAM gives better performance.

Keywords: Hazelnut, Classification, Deep Learning, Shufflenet

https://doi.org/10.30546/19023.978-9952-8573-5-1.2025.8988.
ISBN: 978-9952-8573-6-8

SHUFFLENET DERİN ÖĞRENME ALGORİTMASI KULLANILARAK FINDIK MEYVELERİNİN SINIFLANDIRILMASI İÇİN EN UYGUN PARAMETRELERİN SEÇİMİ

Öz

Fındık meyvelerinin sınıflandırılmasında yapay zeka kullanılarak verimlilik artırılabilir veya kalite kontrol süreçleri iyileştirilebilir. Bu çalışmadaki amacımız Shufflenet derin öğrenme algoritmasını kullanarak fındık meyvelerinin sınıflandırılmasında uygun parametreleri seçmektir. ShuffleNet, parametre sayısını ve hesaplama yükünü azaltarak daha az kaynak kullanan ve işlem gücü sınırlı cihazlar için tasarlanmış bir evrişimli sinir ağıdır. Kullanılan verilerde her görüntüde bir adet fındık bulunmaktadır. Bu fındıklar iyi ve kötü fındıklar ile iç fındıklar olmak üzere üç sınıfa ayrılmıştır. 519 adet kötü fındık, 535 adet iyi fındık ve 523 adet iç fındık kullanılarak bir veri seti oluşturulmuştur. Her fındıktan farklı açılardan alınmış 10 görüntü ile toplam 15770 adet görüntü elde edilmiştir. Yapılan analizler sonucunda SGDM'li ShuffleNet eğitim aşamasında %99,79, test aşamasında ise %99,94 doğruluk oranına ulaşmıştır. ShuffleNet with ADAM eğitimde %99.89 doğruluk oranına, test aşamasında ise %99.96 doğruluk oranına ulaşmıştır. ShuffleNet with RMSprop eğitimde %99.89 doğruluk oranına, test aşamasında ise %99.92 doğruluk oranına ulaşmıştır. Karmaşıklık matrislerine göre, ShuffleNet with SGDM 0.9997 hassasiyete, 0.9994 özgüllüğe ve 0.9997 F1 puanına sahiptir. ShuffleNet with ADAM 0.9997 hassasiyete, 1 özgüllüğe ve 0.9998 F1 puanına sahiptir. RMSprop ile ShuffleNet 0.9997 duyarlılığa, 0.9998 özgüllüğe ve 0.9997 F1 puanına sahiptir. Genel sonuçlar yakın olsa da, ShuffleNet algoritmasının ADAM ile daha iyi performans verdiği görülmüştür.

Anahtar Kelimeler: Fındık, Sınıflandırma, Derin Öğrenme, Shufflenet

Giriş

Yapay zekâ, fındıkların görüntülerini analiz ederek kalite, boyut ve renk gibi özelliklerine göre sınıflandırma yapabilir. Bu, elle yapılan sınıflandırmalara göre daha hızlı ve doğru sonuçlar elde edilmesini sağlayabilir. Makine öğrenimi algoritmaları kullanılarak ve fındık üretiminde toplanan veriler analiz edilerek, belirli koşullar altında yetişen en iyi ürünler belirlenebilir. Bu, üreticiye hangi tür fındıkların hangi koşullarda daha iyi yetiştiğine ilişkin bilgiler sunabilir. Bitki hastalıklarını erken tespit etmede yapay zekâ kullanılabilir. Fındık ağaçlarının sağlık durumunu izleyerek, hastalıkların yayılmasını önlemeye yardımcı olabilir. Fındık toplama ve işleme süreçlerinde otomasyon sağlamak için yapay zekâ destekli cihazlar kullanılabilir. Bu, iş gücünü azaltır ve maliyetleri düşürebilir.

Khosa ve Pasero 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

https://doi.org/10.30546/19023.978-9952-8573-5-1.2025.8988.
ISBN: 978-9952-8573-6-8

bulunmuştur. Bu veriler için seçilen bozuk fındıkların tespiti için anomali tespit algoritması kullanılmıştır. (Khosa ve Pasero, 2014)

Solak ve Altunışık 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-ortalamalar 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. (Solak ve Altunışık, 2018)

Caner ve ark. 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. (Caner ve ark., 2020)

Materyal ve Metot

Yapay zekânın fındık görüntülerini analiz etmesi sürecinde Shufflenet derin öğrenme algoritması kullanılmıştır..

Shufflenet

ShuffleNet, çok sınırlı işlem gücüne sahip mobil cihazlar için özel olarak tasarlanmış bir evrişimsel sinir ağıdır. ShuffleNet, parametre sayısını ve hesaplama yükünü azaltarak daha az kaynak kullanır. Bu, onu mobil uygulamalar için ideal kılar. Mimari, doğruluğu korurken hesaplama maliyetini azaltmak için iki yeni işlem olan nokta bazlı grup evrişimi ve kanal karıştırmayı kullanır. (Zhang ve ark., 2018) Temel yapı taşı olan ShuffleNet bloğu, derinlik yönlendirmeli ayrık (depthwise separable) konvolüsyonlar kullanır. Bu konvolüsyonlar, giriş özellik haritalarını daha küçük boyutlarda işler, böylece hesaplama verimliliğini artırır. Ağırlıkların karıştırılması (shuffle) işlemi, farklı özellik haritalarının bir araya getirilmesini sağlar. Bu, ağın daha iyi genel performans göstermesine yardımcı olur.

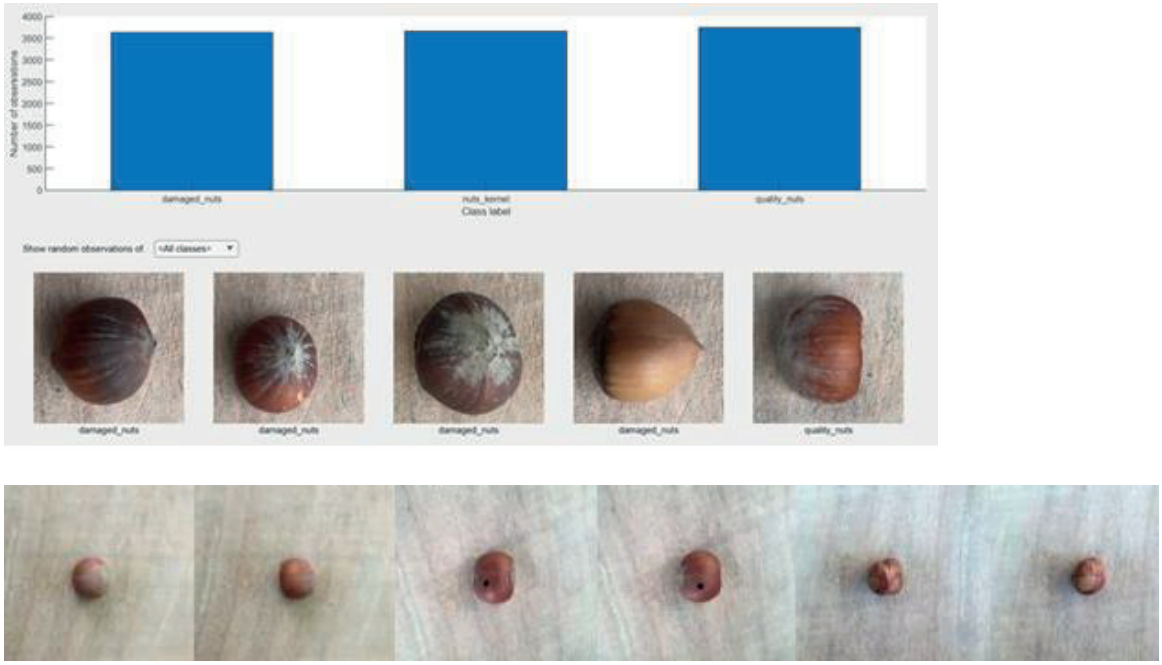
ShuffleNet biriminde ilk ve ikinci 1×1 evrişimler grup evrişimleriyle değiştirilir. İlk 1×1 evrişimden sonra bir kanal karıştırması uygulanır. Adım sayısı=2 ile ShuffleNet biriminde kısayol yoluna 3×3 ortalama havuzlama eklenir. Ayrıca, eleman bazında ekleme, kanal boyutunu çok az ek hesaplama maliyetiyle genişletmeyi kolaylaştıran kanal birleştirme ile değiştirilir. ShuffleNet daha geniş özellik haritaları kullanabilir. Bu küçük ağlar için önemlidir, çünkü küçük ağlar genellikle bilgileri işlemek için yeterli sayıda kanala sahip değildir.

https://doi.org/10.30546/19023.978-9952-8573-5-1.2025.8988.
ISBN: 978-9952-8573-6-8

Veri Seti

Kullanılan veriler, 12 megapiksel çözünürlüğe sahip arka kamera ile elde edilmiştir. Görüntüler platform yardımıyla 3024 x 3024 piksel çözünürlükte çekilmiştir. 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. Kullanılan fındıklardan bazılarına ait görüntüler Şekil 1'de verilmiştir.(Güneş, 2022)



Şekil 1. Fındık veri tabanı

Çalışma ve Bulgular

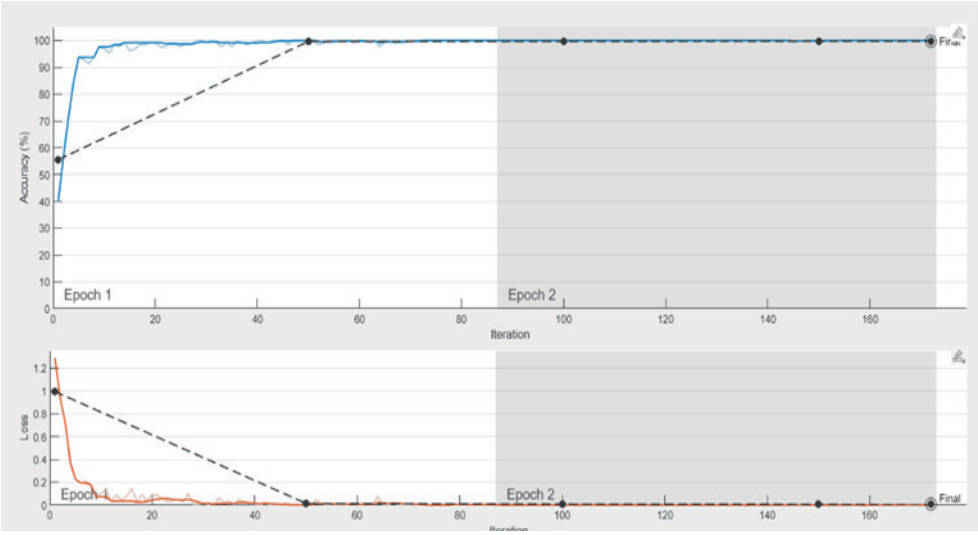
Veri tabanı üç farklı sınıfa sahiptir ve toplamda 15770 adet görüntüye sahiptir. Çalışmada derin öğrenme algoritmalarından ShuffleNet kullanılmıştır. Çalışma ortamı olarak MATLAB kullanılmıştır. Veri seti rastgele karıştırılarak % 30'u eğitim kalan kısım test amacıyla kullanılmıştır. Algoritmaların fındık meyvesi veri tabanındaki eğitim ve test doğrulukları karşılaştırılmıştır. İlk olarak Stochastic Gradient Descent with Momentum (SGDM) kullanılmıştır. Bu yöntem, standart stokastik gradyan iniş algoritmasının hızını ve verimliliğini artırmak için geliştirilmiştir. Momentum, geçmiş gradyan güncellemelerini dikkate alarak öğrenme sürecini hızlandırır. Bu, modelin daha pürüzsüz bir şekilde öğrenmesini sağlar ve yerel minimumlara takılma olasılığını azaltır. Temel olarak, gradyan

https://doi.org/10.30546/19023.978-9952-8573-5-1.2025.8988.
ISBN: 978-9952-8573-6-8

güncellemesi, önceki güncellemelerin bir kombinasyonu ile birleştirilir. Momentum, gradyan inişinin daha hızlı ve kararlı bir şekilde ilerlemesini sağlar. Özellikle, karmaşık yüzeylerde veya sığ minimumlarda daha etkili bir performans gösterir. Güncelleme adımı ve ağırlık güncellemesi sırasıyla Denklem 1 ve 2'de verilmiştir. Burada v_t momentum terimi, β momentum katsayısı (genellikle 0.9 civarında), $\nabla L(\theta_t)$ kayıp fonksiyonunun gradyanı ve α öğrenme oranıdır. SGDM ile ShuffleNet eğitimde % 99.79, test aşamasında % 99.94 doğruluğa ulaşmıştır. Şekil 2'de doğruluk grafiği verilmiştir.

$$v_t = \beta v_{t-1} - 1 + (1-\beta)\nabla L(\theta_t) \quad (1)$$

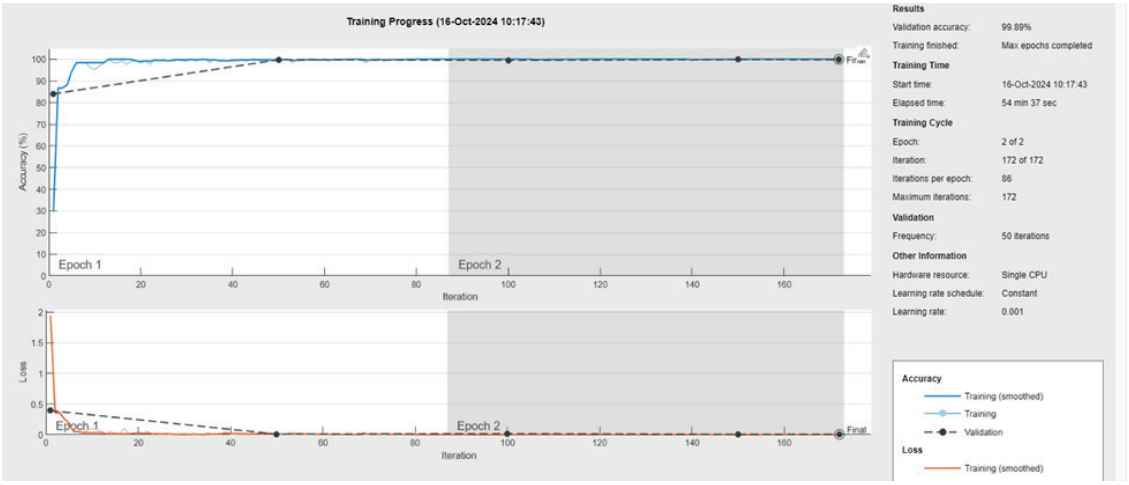
$$\theta_{t+1} = \theta_t - \alpha v_t \quad (2)$$



Şekil 2. SGDM ile ShuffleNet Doğruluk grafiği

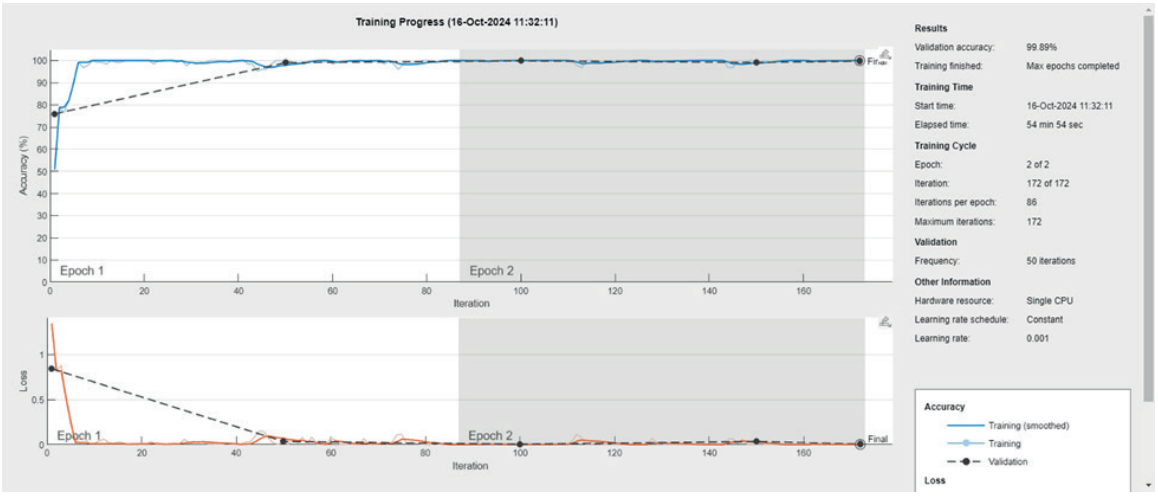
İkinci olarak Adaptive Moment Estimation (ADAM) kullanılmıştır. Adam, öğrenme oranını dinamik olarak ayarlayarak ve momentum terimleri kullanarak, özellikle büyük veri setleri ve yüksek boyutlu parametreler için etkili bir şekilde çalışır. Adam, her bir parametre için anlık gradyanların ortalamasını (momentum) ve bu gradyanların karelerinin ortalamasını (varyans) takip eder. Bu ortalamaları kullanarak, her parametre için ayrı bir öğrenme oranı hesaplar. Bu, bazı parametrelerin daha hızlı veya daha yavaş güncellenmesine olanak tanır. Adam, farklı öğrenme oranları ve diğer hiperparametreler (örneğin beta değerleri) ile özelleştirilebilir, bu da onu farklı problemler için esnek bir seçenek haline getirir. Adam, genellikle hızlı ve etkili bir şekilde yakınsama sağladığı için, birçok derin öğrenme uygulamasında tercih edilen bir optimizasyon yöntemidir. ADAM ile ShuffleNet eğitimde % 99.89, test aşamasında % 99.96 doğruluğa ulaşmıştır. Şekil 3'de doğruluk grafiği verilmiştir.

https://doi.org/10.30546/19023.978-9952-8573-5-1.2025.8988.
ISBN: 978-9952-8573-6-8



Şekil 3. ADAM ile ShuffleNet Doğruluk grafiği

Son olarak Root Mean Square Propagation (RMSprop) kullanılmıştır. RMSprop, özellikle sık dalgalanan veya değişken gradyanlara sahip olan problemler için etkilidir. RMSprop, her bir parametre için ayrı bir öğrenme oranı hesaplar. Gradyanların karelerinin ortalamasını (varyans) takip ederek, her adımda öğrenme oranını ayarlar. Bu sayede, sık değişen gradyanlar için daha düşük bir öğrenme oranı kullanırken, daha az değişken olanlar için daha yüksek bir öğrenme oranı kullanır. RMSprop, geçmiş gradyan bilgilerini hafızada tutmak için bir "unutma faktörü" kullanır. Bu faktör, eski gradyanların etkisini zamanla azaltır, böylece algoritma daha güncel verilere odaklanır. RMSprop, genellikle hızlı bir yakınsama sağlar ve bu da onu özellikle büyük veri setleri ve derin ağlar için etkili kılar Şekil 4'de doğruluk grafiği verilmiştir.



Şekil 4. RMSprop ile ShuffleNet Doğruluk grafiği

https://doi.org/10.30546/19023.978-9952-8573-5-1.2025.8988.
ISBN: 978-9952-8573-6-8

Çalışmada algoritmaların performansını ölçmekte karmaşıklık matrisi (Confusion Matrix) kullanılmıştır ve doğruluk, hassaslık, özgünlük, F1 skor gibi ölçütlere ulaşılmıştır. 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. (Tomak, 2019) Karmaşıklık matrisi Tablo 1'de ve doğruluk, hassaslık, özgünlük, F1-skor matematiksel ifadeleri Denklem 3-6'da verilmiştir.

Tablo 1. Karmaşıklık matrisi.

		Tahmini durum	
		Pozitif	Negatif
Gerçek Durum	Pozitif	TP, Gerçek Pozitif	FN, Yanlış Negatif
	Negatif	FP, Yanlış Pozitif	TN, Gerçek Negatif

$$Doğruluk = \frac{TP+TN}{TP+FP+FN+TN} \quad (3)$$

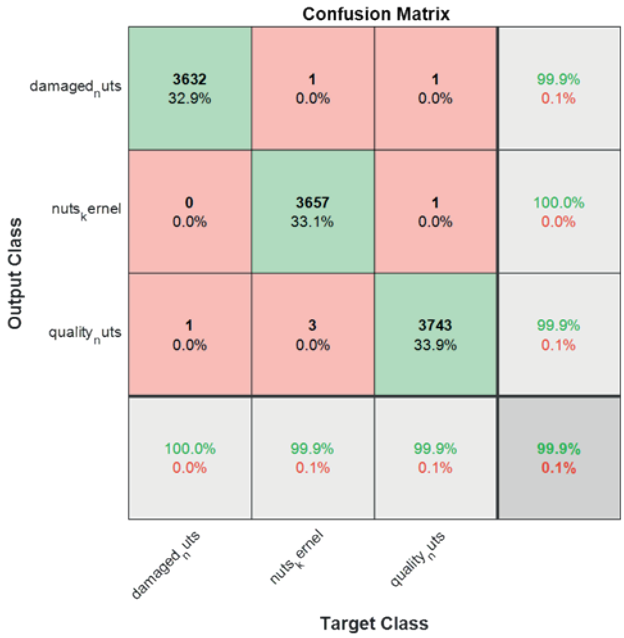
$$Hassaslık = \frac{TP}{TP+FN} \quad (4)$$

$$Özgünlük = \frac{TN}{TN+FP} \quad (5)$$

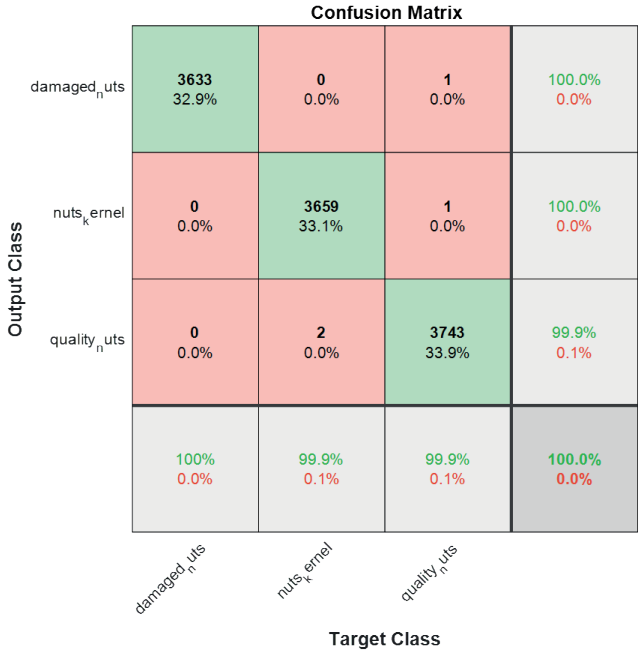
$$F1\ skor = 2 * \frac{Hassaslık * Özgünlük}{Hassaslık + Özgünlük} \quad (6)$$

Şekil 5'de SGDM ile ShuffleNet'e ait karmaşıklık matrisi verilmiştir. Karmaşıklık matrisine göre 0.9997 hassaslık, 0.9994 özgünlük, 0.9997 F1-skor değerine sahiptir. Şekil 6'da ADAM ile ShuffleNet'e ait karmaşıklık matrisi verilmiştir. Karmaşıklık matrisine göre 0.9997 hassaslık, 1 özgünlük, 0.9998 F1-skor değerine sahiptir. Şekil 7'de RMSprop ile ShuffleNet'e ait karmaşıklık matrisi verilmiştir. Karmaşıklık matrisine göre 0.9997 hassaslık, 0.9998 özgünlük, 0.9997 F1-skor değerine sahiptir.

https://doi.org/10.30546/19023.978-9952-8573-5-1.2025.8988.
ISBN: 978-9952-8573-6-8

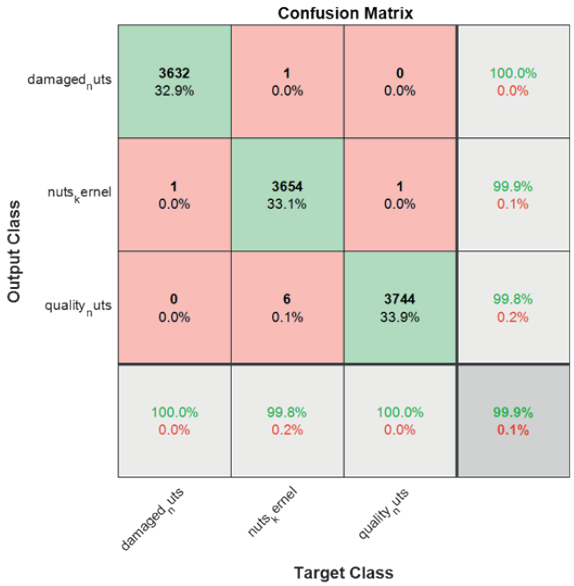


Şekil 5. SGDM ile Shufflenet karmaşıklık matrisi



Şekil 6. ADAM ile Shufflenet karmaşıklık matrisi

https://doi.org/10.30546/19023.978-9952-8573-5-1.2025.8988.
ISBN: 978-9952-8573-6-8



Şekil 7. RMSprop ile Shufflenet karmaşıklık matrisi

Sonuçlar ve Öneriler

Fındık meyvesinin depolaması sürecinden önce fındıklar temizlenmelidir. Temizleme sürecinde kötü fındık veya iç fındık bulunursa ayrılmalıdır. Kötü fındık ayrılmazsa randımanı düşük gelir. İç fındık temizlenmezse depolama süresinde bu fındıklar bozulabilir. Analizler sonucunda SGDM ile ShuffleNet eğitimde % 99.79, test aşamasında % 99.94 doğruluğa ulaşmıştır. ADAM ile ShuffleNet eğitimde % 99.89, test aşamasında % 99.96 doğruluğa ulaşmıştır. RMSprop ile ShuffleNet eğitimde % 99.89, test aşamasında % 99.92 doğruluğa ulaşmıştır. Karmaşıklık matrislerine bakarsak göre SGDM ile ShuffleNet 0.9997 hassaslık, 0.9994 özgünlük, 0.9997 F1-skor değerine sahiptir. ADAM ile ShuffleNet'e 0.9997 hassaslık, 1 özgünlük, 0.9998 F1-skor değerine sahiptir. RMSprop ile ShuffleNet'e 0.9997 hassaslık, 0.9998 özgünlük, 0.9997 F1-skor değerine sahiptir. Genel sonuçlar yakın da olsa ADAM ile ShuffleNet algoritmasının daha iyi performans verdiği görülmüştür.

REFERENCES

Caner, K. O. C., Gerdan, D., Eminoğlu, M. B., Yegül, U., Bulent, K. O. C., & Vatandaş, M. (2020). Classification of hazelnut cultivars: comparison of DL4J and ensemble learning algorithms. Notulae Botanicae Horti Agrobotanici Cluj-Napoca, 48(4), 2316-2327.

Güneş, Engin (2022), "Hazelnuts", Mendeley Data, V2, doi: 10.17632/dvvx6kst3f.2

Khosa, I. Pasero, E., Feature extraction in X-ray images for hazelnuts classification. In: 2014 International Joint Conference on Neural Networks (IJCNN). IEEE, 2014. p. 2354-2360.

Solak, S., & Altınışık, U. (2018). Detection and classification of hazelnut fruit by using image processing techniques and clustering methods. Sakarya University Journal of Science, 22(1), 56-65. ImageNet. http://www.image-net.org.

https://doi.org/10.30546/19023.978-9952-8573-5-1.2025.8988.
ISBN: 978-9952-8573-6-8

Tomak, Ö. (2019). Elektrokardiyografi Sinyallerinde Deneysel Mod Ayrıştırma Ve Geliştirilmiş Karar Ağaçları Kullanarak Aritmi Tespiti. Karadeniz Fen Bilimleri Dergisi, 9(1), 103-110.

URL-1: ImageNet. http://www.image-net.org. (Erişim Tarihi: 7 Ekim 2024).

Zhang, X., Zhou, X., Lin, M., & Sun, J. (2018). Shufflenet: An extremely efficient convolutional neural network for mobile devices. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 6848-6856).