



Öz nitelik Seviyesinde Füzyon Yaklaşımının Kuruyemiş Tür Sınıflandırılmasında Performans Değerlendirmesi

Furkan Atban^{1*}, Hamza Osman İlhan²

^{1*} Sakarya Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, Sakarya, Türkiye, (ORCID: 0000-0002-1712-5155), furkanatban@subu.edu.tr

² Yıldız Teknik Üniversitesi, Elektrik-Elektronik Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul, Türkiye (ORCID: 0000-0002-1753-2703), hoilhan@yildiz.edu.tr

(1st International Conference on Scientific and Academic Research ICSAR 2022, December 10 - 13, 2022)

(DOI: 10.31590/ejosat.1217629)

ATIF/REFERENCE: Atban, F., & İlhan, H. O. (2022). Öz nitelik Seviyesinde Füzyon Yaklaşımının Kuruyemiş Tür Sınıflandırılmasında Performans Değerlendirmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (45), 48-52.

Öz

Önerilen çalışma, derin öğrenme ağ mimarilerinden ResNet50 ve DenseNet201 ağlarının öğrenme aktarımı kapsamında 11 sınıflı kuruyemiş görüntülerinden oluşan veri setinden anlamlı özelliklerin çıkarılmasında kullanılmasını ve elde edilen özellik kümeleri üzerinden karar destek makineleri ile ürünlerin yüksek doğrulukta sınıflandırılmasını araştırmaktadır. Ayrıca çalışma kapsamında özellik seviyesi füzyonu yaklaşımıyla, iki farklı ön eğitilmiş ağdan elde edilen özelliklerin birleştirilmesi ile oluşturulan yeni özellik veri kümesinin, sınıflandırılma performansına olan etkisi de incelenmiştir. Sonuçların validasyonu için deneyler 5 katlı çapraz doğrulama tekniği kapsamında gerçekleştirilmiştir. Sınıflandırma sonuçları incelendiğinde, ResNet50 ve DenseNet201, Füzyon mimarileri kullanılarak çıkarılan özelliklerin doğrusal çekirdekli karar destek makineleri ile sınıflandırılması neticesinde sırasıyla %97,86, %98,09 ve %98,68 sınıflandırma doğrulukları elde edilmiştir.

Anahtar Kelimeler: Kuruyemiş, Sınıflandırma, DenseNet201, ResNet50, Özellik Çıkarımı.

Performance Evaluation of the Decision Level Fusion in Dried-Nut Species Classification

Abstract

The proposed study investigates the use of ResNet50 and DenseNet201 networks, which are deep learning network architectures, to feature extraction from the dataset consisting of 11-class dried-nuts images within the scope of transfer learning and to classify products with high accuracy with support vector machines over the obtained feature sets. In addition, the effect of the new feature dataset created by combining the features obtained from two different pre-trained networks with the feature-level fusion approach on the classification performance was also examined within the scope of the study. For the validation of the results, the experiments were carried out under the 5-fold cross-validation technique. When the classification results are examined, classification accuracies of 97.86%, 98.09% and 98.68% were obtained, respectively, as a result of the classification of the extracted features using the ResNet50, DenseNet201 and Fusion architectures with linear core support vector machines. When the feature-level fusion approach was applied, it was observed that the classification accuracy increased to 98.68%.

Keywords: Dried-Nuts, Classification, DenseNet201, ResNet50, Feature Extraction.

* Corresponding Author: furkanatban@subu.edu.tr

1. Giriş

Bilgisayar destekli ürün tanıma sistemlerinin geliştirilmesi, üretimi gerçekleştiren firmalarının sektörel bazlı faaliyetlerini ve tüketicilerin günlük yaşantılarını kolaylaştırmakta ve ihtiyaçların giderilmesi noktasında önemli bir yer tutmaktadır. Derin öğrenme ağlarının zaman içerisindeki gelişimi sayesinde ürün tanıma sistemlerinin ürün tespit ve sınıflandırma çıktıları yüksek doğrulukta elde edilebilmektedir [1]. Bu ağlar kullanılarak farklı çözümler için çalışmalar yapılmış ve birçok sektörde alınan başarılı performans çıktılarının nihai ürün olarak entegrasyonu sağlanmıştır. Yiyeceklerin bilgisayar destekli sınıflandırılması da perakende sektörüne getireceği hız, zaman, maliyet ve güvenilirlik açısından önemli bir ihtiyaçtır. Ayrıca tüketiciler için de günlük hayatlarındaki ürün tedarik sürecini kolaylaştırması açısından faydalı bir hizmet sunmaktadır. Bu anlamda, yiyeceklerin sınıflandırılması özelinde literatür de yapılmış farklı çalışmalar mevcuttur.

Vidyarthi, S. K. vd. yaptıkları çalışmada derin Evrişimli Sinir Ağlarını (ESA) kullanarak kaju çekirdeklerini, beş farklı sınıf etiketi üzerinden sınıflandırmayı önermişlerdir. Kendi önerdikleri özel ESA modelleri dışında, üç farklı transfer öğrenme ağını kullanarak elde ettikleri başarı çıktılarına bakıldığında, Inceptionv3 ve ResNet50 ağlarının %98,4'lük sınıflandırma doğruluğuna ulaştığı raporlanmıştır [2]. Dheir, I. M. vd. ise yaptıkları çalışmada geniş bir kuruyemiş yelpazesini barındıran veri kümesi ile çalışmışlardır. Sınıflandırma için geliştirdikleri özel ESA kullanarak, 2868 görüntü ve 5 sınıftan oluşan veri kümelerinde %98'lik doğruluk değeri elde etmişlerdir [3]. Costa, L. vd. yaptıkları çalışma ile cevizler üzerinde kabuk ve alan tahmininin yapılabilmesi için Mask-RCNN algoritmasını kullanarak nesne tespiti ve semantik segmentasyonu sağlamışlardır. Çalışma sonucundan kullanılan ağ ile modeller üzerinde %95,3 F1 skoru elde edilmiştir [4]. Wang, B. vd. ise yaptıkları çalışmada kültür tahmini yapabilmek için soya fasulyesi bitkilerinin farklı bölümlerinden elde edilen derin öğrenme özelliklerini mesafe ve sınıflandırıcı füzyonu olmak üzere iki yöntem ile birleştirmişlerdir. Daha sonra bu özellikler ile eğitilen SVM sınıflandırıcı, sağladığı %83,55'lik doğruluk değeri ile yöntemin uygulanabilirliğini göstermiştir [5]. Jan, R. vd. dört farklı kuru meyve sınıfından oluşan, görüntü işleme adımları ile gürültüden arındırılmış ve ilgili bölgelerin belirlendiği görüntüleri içeren veri kümesi üzerinde önerdikleri ESA modeli ile %94 doğruluk çıktısı elde etmişlerdir [6]. Villacres, J. F. vd. çalışmalarında kiraz mahsulü tahminini gerçekleştirmişlerdir. Manuel olarak yapılan tahminlerdeki hatayı azaltmak için taşınabilir yapay bir görme sistemi ile derin sinirsel tabanlı bir yaklaşım önermişlerdir. Önerdikleri yaklaşım ile %85'e kadar ürün sınıflandırma da doğruluk değeri raporlamışlardır [7].

Bir diğer çalışmada Mao, S. vd. bir salatalık bölgesi algılama yöntemi önermişlerdir. Önerdikleri yöntem, renk bileşeni seçimi ve destek vektör makineleri ile çok yönlü evrişimli sinir ağına dayalı bir yaklaşım olarak gösterilmiştir. Çalışmada ilgili özelliklerin ağırlık bilgileri I-Relief kullanılarak analiz edilmiştir. Sonuçlar analiz edildiğinde önerilen yöntemin %90'dan fazla doğrulukla sınıflandırma işlemini gerçekleştirdiği raporlanmıştır [8]. Han, Y. vd. yaptıkları çalışma ile kuruyemiş kalitesinin hızlı bir şekilde değerlendirilmesini sağlamayı amaçlamışlardır. Üç farklı ESA modeli ile sınıflandırma işlemini gerçekleştirerek %93,48'lik doğruluk değeri raporlamışlardır.

Aynı zamanda çalışmada en iyi sonucu veren model üzerinde temel bileşen analizi uygulamışlardır [9]. Wang, Z. vd. yaptıkları çalışma ile meyvelerin paketlenme işlemleri sırasındaki konumunun belirlenmesi için meyve sapı ve pozisyonuna dayalı bir yaklaşım önermişlerdir. Elmanın sapının gerçek zamanlı olarak belirlenmesi için Yolo-v5 algoritmasını kullanmışlardır. Çalışmada %93,89 doğruluk değeri elde edilmiştir [10]. Bir başka özellik çıkarımı için ağ kullanımı üzerine yapılan çalışmada, Varshni, D vd. transfer öğrenme yaklaşımlarının anlamlı özelliklerin çıkarılmasındaki başarısını ortaya koydukları görülmektedir. DenseNet ve ResNet mimarileri üzerine kurulu çalışmalarında, çıkarılan özelliklerin karar destek makineleri ile ardışık kullanımı sonucunda başarı çıktıları elde edilmiştir. Alınan %77,49 (ResNet50) ve %80,02 (DenseNet201) doğruluk değerleri, çalışmanın sonucu olarak raporlanmıştır [11].

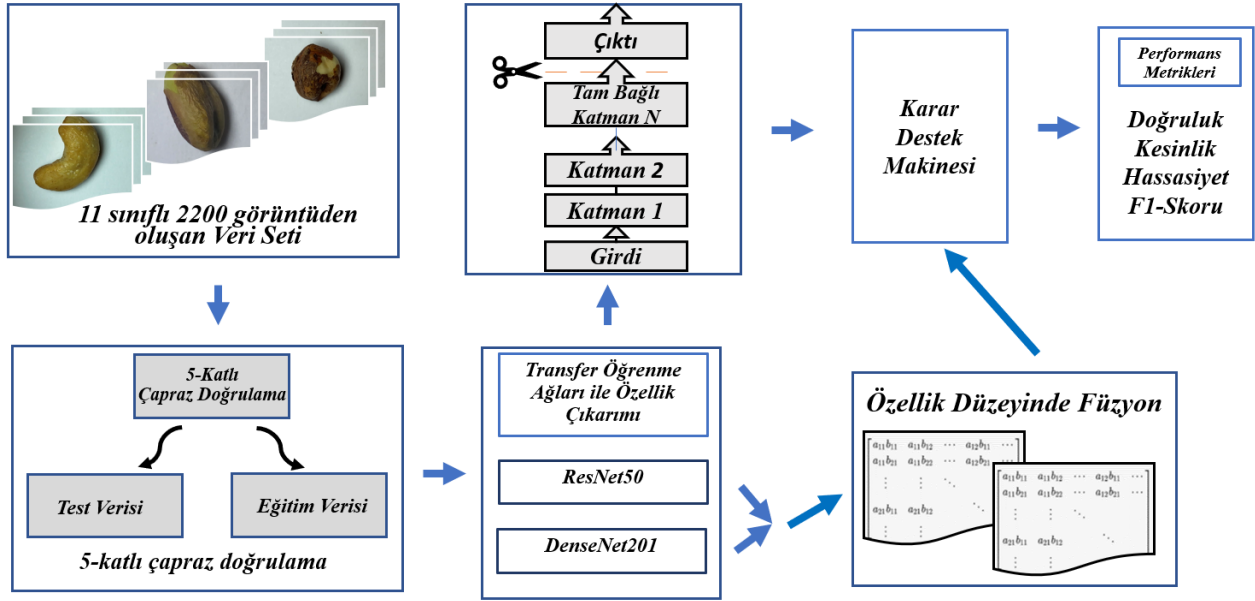
Literatür incelendiğinde, ResNet50 ve DenseNet201 mimarileri ürün tanıma ve sınıflandırma kapsamında başarılı sonuçlar veren transfer öğrenme ağları olduğu gözlemlenmiş ve sunulan çalışmada bu nedenle tercih edilmişlerdir. Ayrıca literatür araştırmasında da belirtildiği üzere pek çok farklı ürün tanıma problemlerinde derin öğrenme ağlarının özellik çıkarımı noktasında kullanıldığı görülmektedir. Önerilen çalışmada, özelliklerin çıkarımı bu ağların kullanımıyla gerçekleştirilmiştir. Çalışmanın akışı sırasıyla, bölüm II' materyal ve yöntem, deneysel sonuçlar, tartışma ve sonuçlar şeklinde oluşturulmuştur.

2. Materyal ve Metot

Günümüzde, perakende sektörü ve sosyal yaşamımızda, yiyeceklerin otomatik tanıma ihtiyacı giderek artmaktadır. Manuel tanı aşamasında ortaya çıkabilecek problemlerin önüne geçilebilmesi için farklı derin öğrenme yaklaşımları literatürde mevcuttur. Bu çalışmalar, başarılı doğruluk çıktıları verse de çalışmalarda kullanılan veri setinin dengesiz dağılımı, modellerin aşırı öğrenme, hız, maliyet gibi problemleri ve düşük boyutlu veri kümeleri ile elde edilen başarı çıktıları, çalışmaların uygulanabilirliği noktasında karşılaşılan problemler olarak ortaya çıkmaktadır. Önerilen çalışmada, geniş bir kuruyemiş yelpazesine sahip veri setinin sınıflandırılmasında, ön eğitilmiş ağların sağladığı anlamlı özelliklerin çıkarılması avantajından yararlanarak, özellik seviyesi füzyonu ile yüksek doğrulukta sonuçların elde edilmesi hedeflenmektedir. Çalışmanın akış şeması Şekil 1'de gösterilmiştir.

2.1. Veri Seti Bilgisi

Çalışmada, her biri 200 adet görüntü içeren toplam 11 sınıflı açık kaynaklı kuruyemiş veri seti kullanılmıştır. Veri seti An, R. vd. tarafından yapılan çalışma için oluşturulmuştur [12]. Veri seti oluşturulurken her bir sınıf için 10 numune kuruyemiş alınmış, 20 farklı açıdan görüntü elde edilerek bir sınıf etiketi için toplamda 200 görüntü elde edilmiştir. Veri kümesindeki her bir sınıf, kuruyemiş tipine göre adlandırılmıştır. Sınıf bazında örnek görüntüler Şekil 2'de verilmiştir.




Şekil 1. Önerilen çalışmanın akış diyagramı.

2.2. Önerilen Yaklaşım

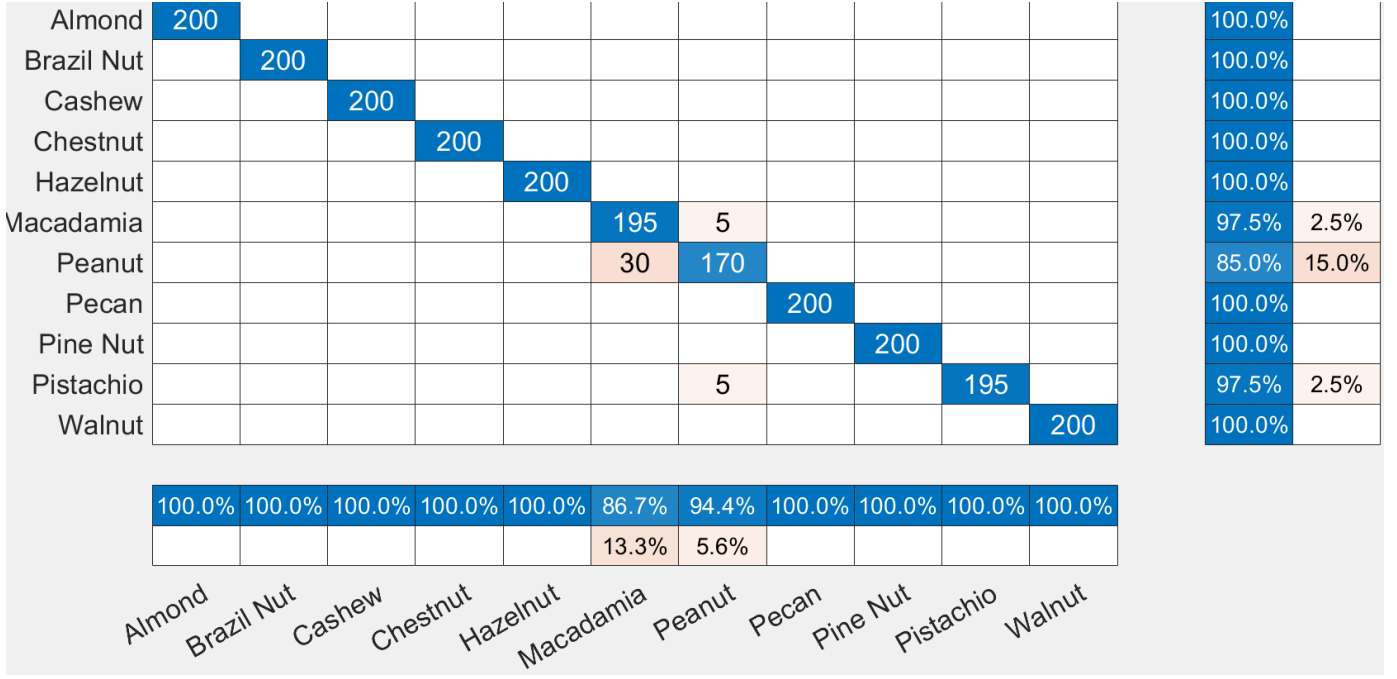
Sunulan çalışmada, performans metrikleri kapsamında yüksek başarımlı kuruyemiş ürünlerinin sınıflandırılmasını sağlayacak derin öğrenme tabanlı yaklaşımların kıyaslamalarının yapılması hedeflenmiştir. Ön eğitilmiş ağlar, belirli bir problemin çözümü için bir veri kümesi üzerinde eğitilerek başarımlı kanıtlanmış ağ mimarileridir. Bu kapsamda, ResNet50 ve DenseNet201 ön eğitilmiş ağları, anlamlı özelliklerin çıkarılması için sunulan çalışmada kullanılmıştır. Anlamlı özelliklerin çıkarılması, var olan görüntülerin farklı yöntemlerle işlenebilmesi için sayısal özelliklerin elde edilmesini sağlar. Bu sayede sınıflandırma işlemlerinde gerekli olan iş yükü azaltılabilir. Özellik çıkarma işlemi, transfer öğrenme ağlarının uzamsal ve frekans alanları hesaplamaları yapması sonucunda başarılı bir çıktı sunar [13].

Aşırı öğrenme, derin öğrenme yaklaşımlarında sıklıkla karşılaşılan bir problemdir. Modelin eğitim verisini ezberlemesi ile ortaya çıkan problemin çözümü için, veri kümesinin boyutunun artırılması önemli bir çözüm oluşturmaktadır. Bu noktada bir diğer çözüm ise model eğitimlerinin K-Katlamalı Çapraz Doğrulama (K-Fold Cross Validation) tekniği ile gerçekleştirilmesidir. Böylece modelin görmediği veriler üzerinde de performansı test edilir. Bu noktada en önemli çözümlerden birisi de ön eğitilmiş ağların özellik çıkarmında kullanılmasıdır. Çalışmada ilk olarak, veri seti 5 katlama mimarisine uygun hale getirilerek, katlama bazında farklı test setleri oluşturulmuş, böylelikle modellerin bütün örnekler üzerindeki performansının değerlendirilmesi sağlanmıştır. Ardından, ResNet50 ve DenseNet201 mimarileri özellik çıkarmı için kullanılarak, ham verilerden anlamlı özelliklerin elde edilmesi sağlanmıştır. Bu sayede klasik özellik çıkarmı yöntemlerine göre daha anlamlı özelliklerin elde edilmesi amaçlanmıştır. Çıkarılan özellikler ile lineer çekirdekli destek vektör makineleri (Linear SVM) beslenerek eğitimler gerçekleştirilmiş ve sınıflandırma başarımlı ölçülmüştür.

Karar destek makineleri sınıflandırma görevleri için tercih edilen çekirdek fonksiyonlarını kullanarak doğrusal olmayan sınıflandırma görevlerinde de başarılı çıktılar veren gözetimli bir makine öğrenmesi algoritmasıdır. Çalışmanın bir diğer analizinde farklı iki ağ tarafından çıkarılan öznelikler, özellik düzeyinde füzyon yaklaşımı ile tek öznelik matrisi olarak birleştirilmiştir. Bu aşamadaki amaç, farklı algoritmalar tarafından ortaya çıkarılan sayısal özellik değerlerinin bir bütün olarak saptanması ve böylece tanıma doğruluğunu arttıracak yoğun bir özellik kümesinin elde edilmesidir. Özellik düzeyinde füzyon ile birleştirilen özneliklerin, K katlamalı çapraz doğrulama yapısına bağlı kalarak, lineer çekirdekli karar destek makinesini beslemesi ile sınıflandırma işlemi gerçekleştirilmiştir. Elde edilen tüm sonuçlar farklı performans metrikleri ile değerlendirilmiştir.



Şekil 2. Sınıflara ait örnek görüntüler



Şekil 3. Özellik seviyesi füzyonu ve karar destek makinesinin ardışık kullanımı ile elde edilen karmaşıklık matrisi.

3. Deneysel Sonuçlar

Önerilen çalışmada, kuruyemiş tabanlı ürünlerin tanınması noktasında kullanılabilir, derin öğrenme tabanlı bir sınıflandırma yöntemi sunulmaktadır. Çalışmada, 11 farklı kuruyemışten alınan 10 adet mahsulün 20 farklı açıdan çekimleri ile elde edilen her bir sınıfa ait 220 görüntüyü barındıran kuruyemiş veri seti kullanılmıştır. Literatürde yer alan iki farklı popüler evrişimsel sinir ağı mimarisi seçilerek, bu mimarilerin özellik çıkarımı için kullanılması çalışmanın ana çıkış noktası olmuştur. Her bir görüntü ön işleme kapsamında ağların girdi boyutu olan 224x224x3 boyutuna getirilmiştir.

Çalışmanın ilk aşamasında ResNet50 ve DenseNet201 mimarileri, katmanlı yapıları incelenerek, tam bağlı katmanlarından kesilmiş ve özellik çıkarımı için kullanılmıştır. Özellik çıkarımı ile her bir ağ için 1000 adet özellik elde edilmiş ve model eğitimi aşamasında 5 katlama mimarisine uygun şekilde, %80 eğitim ve %20 test veri ayırımı gerçekleştirilmiştir. Böylece, her bir katlama için eğitim verisi 1760x1000 ve test verisi 440x1000 boyutunda olmuştur. Çalışmada 5 katlı çapraz doğrulama tekniği ile her bir örneğin test edilmesi ve aşırı öğrenme probleminin önüne geçilmesi hedeflenmiştir. Özellik çıkarımı neticesinde, her bir ağdan çıkarılan özelliklerin lineer çekirdekli karar destek makinelerine beslenmesi ile sınıflandırma performansları elde edilmiştir. ResNet ve DenseNet mimarileri için elde edilen doğruluk değerleri sırası ile %97,86 ve %98,09 olarak ölçülmüştür. Çalışmada uygulanan yöntemler sonucunda, her bir katlama için alınan doğruluk değerleri Tablo 1'de gösterilmiştir. Çalışmanın bir diğer aşamasında ise özelliklerin birleştirilmesi mantığı ile füzyon model oluşturulması sağlanmıştır. Özellik düzeyinde füzyon ile her bir ağdan elde edilen özellikler tek bir özellik matrisi olarak tanımlanmıştır. Bu işlemin ardından elde edilen 2000 özelliği barındıran yeni matrisin, ardışık olarak lineer çekirdekli karar destek makinesini beslemesi ile sınıflandırma işlemi gerçekleştirilmiştir.

Bu yöntemle, elde edilen %98,68 doğruluk değeri yöntemin uygulanabilirliğini göstermiştir. Çalışmadan füzyon yaklaşımı ile elde edilen karmaşıklık matrisi Şekil 3'te gösterilmiştir. Şekil 3'de x eksenini hassasiyet değerlerini, y eksenini ise kesinlik değerlerini ifade etmektedir.

Tablo 1. Sınıflandırma doğruluk değerleri.

Katlama	Doğruluk %		
	ResNet50	DenseNet201	Füzyon Model
1	96.59	97.50	98.86
2	99.09	98.41	99.09
3	99.55	99.09	99.77
4	97.73	98.18	97.95
5	96,36	97.27	97.73
Ort.	97,86	98,09	98,68

4. Tartışma

Her geçen gün derin öğrenme ağlarının gelişimi ile otomatik tanı sistemlerine olan ihtiyaç birçok sektörde artmaktadır. Günlük hayatta en çok karşılaşılan problemlerden biri de ürünlerin hızlı ve doğru sınıflandırılma ihtiyacıdır.

Bu ihtiyaç özellikle perakende sektöründe ve bireysel tedarik süreçlerinin takibinde yiyeceklerin sınıflandırılması önemli bir yer tutmaktadır. Bu doğrultuda literatürde yapılan çalışmaların, düşük boyutlu veri kümelerinin kullanılması, aşırı öğrenme problemi, hız ve zaman verimliliği açısından eksik yönleri tespit edilmiştir.

Yapılan çalışma ile ön eğitilmiş ağların kullanımı ve füzyon yapısının oluşturulması ile başarılı performans çıktıları elde edilmiştir. Alınan sonuçlar, çalışmanın sektörel bazı sorunların çözümünde ve tüketicilerin ürün tedarik süreçlerinde kullanılabilecek bir çözüm üretebileceğini göstermektedir. Perakende sektöründe, artan işlem hacmi ve artan kameralı tartı platformu entegrasyonları otomatik tanıyı gerekli kılmaktadır. Poşetli ve toplu halde bulunan ürünlerin tespiti de perakende sektörüne hız, zaman ve güvenilirlik açısından önemli derecede katkı sağlayacaktır. Sunulan çalışma gelecekte yapılacak bu tarz yaklaşımlar için fikrin uygulanabilirliğini göstermiştir.

Gelecek çalışmalarda, şeffaf poşetli yiyeceklerin sınıflandırılması üzerine yöntemin denenmesi ve daha geniş sınıflı veri yelpazesine sahip veri setinin oluşturularak, yöntemlerin bu veri setlerinde test edilmesi amaçlanmaktadır.

5. Sonuçlar

Sunulan çalışma ile kuruyemiş sınıflandırması için yüksek doğruluk değerine sahip başarı çıktıları elde edilmiştir. Çalışmada uygulanan, özellik vektörü birleştirme yaklaşımının başarıyı arttırdığı gözlemlenmiştir. Füzyon yaklaşımı ile elde edilen %98,68'lik doğruluk değeri incelendiğinde, yaklaşımın Cashew (Kaju), Chestnut (Kestane), Pecan (Pekan Cevizi), Pine Nut (Çam Fıstığı) için hatasız tahmin yaptığını diğer sınıflarda ise hatasız yakın sonuçlar verdiğini göstermiştir. Çalışmadan çıkarılan bu sonuçlar, kullanılan yöntemin farklı problemlerin çözümü için de katkı sağlayacağına işaret etmektedir.

Kaynakça

- [1] Ecemiş, İ. N., & İlhan, H. O. (2023). The performance comparison of pre-trained networks with the proposed lightweight convolutional neural network for disease detection in tomato leaves. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 38(2), 693-705.
- [2] Vidyarthi, S. K., Singh, S. K., Tiwari, R., Xiao, H. W., & Rai, R. (2020). Classification of first quality fancy cashew kernels using four deep convolutional neural network models. *Journal of Food Process Engineering*, 43(12), e13552.
- [3] Dheir, I. M., Mettleq, A. S. A., Elsharif, A. A., & Abu-Naser, S. S. (2020). Classifying nuts types using convolutional neural network. *International Journal of Academic Information Systems Research (IJASIR)*, 3(12).
- [4] Costa, L., Ampatzidis, Y., Rohla, C., Maness, N., Cheary, B., & Zhang, L. (2021). Measuring pecan nut growth utilizing machine vision and deep learning for the better understanding of the fruit growth curve. *Computers and Electronics in Agriculture*, 181, 105964.
- [5] Wang, B., Li, H., You, J., Chen, X., Yuan, X., & Feng, X. (2022). Fusing deep learning features of triplet leaf image patterns to boost soybean cultivar identification. *Computers and Electronics in Agriculture*, 197, 106914.
- [6] Jan, R., Kour, H., Manhas, J., & Sharma, V. Recognition of Dry Fruits using Deep Convolutional Neural Network.
- [7] Villacrés, J. F., & Auat Cheein, F. (2020). Detection and characterization of cherries: A deep learning usability case study in Chile. *Agronomy*, 10(6), 835.

- [8] Mao, S., Li, Y., Ma, Y., Zhang, B., Zhou, J., & Wang, K. (2020). Automatic cucumber recognition algorithm for harvesting robots in the natural environment using deep learning and multi-feature fusion. *Computers and Electronics in Agriculture*, 170, 105254.
- [9] Han, Y., Liu, Z., Khoshelham, K., & Bai, S. H. (2021). Quality estimation of nuts using deep learning classification of hyperspectral imagery. *Computers and Electronics in Agriculture*, 180, 105868.
- [10] Wang, Z., Jin, L., Wang, S., & Xu, H. (2022). Apple stem/calyx real-time recognition using YOLO-v5 algorithm for fruit automatic loading system. *Postharvest Biology and Technology*, 185, 111808.
- [11] Varshni, D., Thakral, K., Agarwal, L., Nijhawan, R., & Mittal, A. (2019, February). Pneumonia detection using CNN based feature extraction. In *2019 IEEE international conference on electrical, computer and communication technologies (ICECCT)* (pp. 1-7). IEEE.
- [12] An, R., Perez-Cruet, J., & Wang, J. (2022). We got nuts! use deep neural networks to classify images of common edible nuts. *Nutrition and Health*, 02601060221113928.
- [13] Özkaya, U., Öztürk, Ş., & Barstugan, M. (2020). Coronavirus (COVID-19) classification using deep features fusion and ranking technique. In *Big Data Analytics and Artificial Intelligence Against COVID-19: Innovation Vision and Approach* (pp. 281-295). Springer, Cham.