

Siirt Fıstığının Derin Öğrenme Yöntemleriyle Sınıflandırılması

Mesut Erdoğan^{1*}, Abdulkirim Öztekin²

^{1,2}Bilgi Teknolojileri ABD/Lisansüstü Eğitim Enstitüsü, Batman Üniversitesi, Türkiye

*(merdogan.1907@gmail.com)

(Received: 05 March 2025, Accepted: 07 March 2025)

(4th International Conference on Recent Academic Studies ICRAS 2025, March 04-05, 2025)

ATIF/REFERENCE: Erdoğan, M. & Öztekin, A. (2025). Siirt Fıstığının Derin Öğrenme Yöntemleriyle Sınıflandırılması. *International Journal of Advanced Natural Sciences and Engineering Researches*, 9(3), 219-225.

Özet – Tarım sektörü, kalite kontrol ve sınıflandırma süreçlerinde genellikle manuel yöntemlere dayanmakta olup bu da süreçlerin hem zaman alıcı hem de hata oranlarının yüksek olmasına neden olmaktadır. Gelişen teknolojiyle birlikte, tarım ürünlerinin otomatik olarak sınıflandırılmasını sağlayacak yapay zeka temelli yaklaşımlar, hem üreticilere hem de tüketicilere çeşitli avantajlar sunma potansiyeline sahiptir. Bu çalışmada, Siirt fıstığı örneği üzerinden derin öğrenme tabanlı bir sınıflandırma modeli geliştirilmiştir. Çalışmanın ilk aşamasında, Siirt fıstığının kalite kriterleri belirlenmiş ve bu kriterlere göre geniş bir veri seti oluşturulmuştur. Veri seti, farklı kalite sınıflarını (örneğin, iri, orta boy, düşük kaliteli; deformasyona uğramış ya da renk farkı olan fıstıklar) kapsayacak şekilde çeşitlendirilmiştir. Derin öğrenme modeli olarak evrimsel sinir ağları (CNN) tercih edilmiş ve modelin performansını artırmak için çeşitli mimari düzenlemeler yapılmıştır. Modelin eğitimi ve testi sırasında hiperparametre optimizasyonu gerçekleştirilmiş, doğruluk oranını artırmak için dropout, öğrenme hızı ayarı ve erken durdurma gibi teknikler uygulanmıştır. Modelin performansı, doğruluk, kesinlik, duyarlılık ve F1 skor metriği kullanılarak değerlendirilmiştir. Elde edilen sonuçlar, Siirt fıstığının sınıflandırılmasında geliştirilen derin öğrenme modelinin %99 doğruluk oranı ile başarılı bir şekilde çalıştığını ortaya koymuştur. Modelin sonuçları, geleneksel manuel sınıflandırma yöntemleri ile karşılaştırıldığında, hem zaman hem de doğruluk açısından önemli avantajlar sağlamaktadır. Bu çalışma, tarım sektöründe kalite kontrol süreçlerini optimize etmek, üreticilere verimlilik sağlamak ve tüketici memnuniyetini artırmak adına önemli bir adım olarak değerlendirilmektedir. Gelecekteki çalışmalar için, daha büyük veri setlerinin oluşturulması, farklı derin öğrenme mimarilerinin test edilmesi ve modelin gerçek zamanlı uygulamalarda denenmesi önerilmektedir.

Anahtar Kelimeler – Derin Öğrenme, Evrimsel Sinir Ağları (CNN), ResNet Modelleri, Siirt Fıstığı.

I. GİRİŞ

Tarım ve gıda endüstrisinde, ürünlerin doğru sınıflandırılması, kalite kontrolü ve verimliliğin artırılması kritik öneme sahiptir. Geleneksel sınıflandırma yöntemleri, zaman alıcı olmasının yanı sıra, insan kaynaklı hatalara açık ve doğruluk açısından sınırlı olabilmektedir. Özellikle ticari değeri yüksek ürünlerde yanlış sınıflandırma, ciddi ekonomik kayıplara ve kalite sorunlarına yol açabilir [1]. Bu bağlamda, yapay zeka ve derin öğrenme gibi modern teknolojiler, tarımda daha hızlı, güvenilir ve otomatik süreçler sunarak bu sorunları çözme potansiyeline sahiptir [2].

Siirt ve Antep fıstığının sınıflandırılması, tarım ve gıda sektöründe oldukça önemli bir konudur. Derin öğrenme modellerinin bu süreçteki kullanımı, geleneksel yöntemlere kıyasla daha hassas, hızlı ve otomatikleştirilmiş bir sınıflandırma imkanı sunmaktadır. Siirt ve Antep fıstığı gibi tarımsal ürünlerin

sınıflandırılması, ürün kalitesini belirlemek ve ticari değerini artırmak için kritik öneme sahiptir. Derin öğrenme modelleri, bu süreçte manuel yöntemlere kıyasla çok daha hızlı sonuçlar vermektedir. Görüntü işleme ve yapay zeka tabanlı sınıflandırma yöntemleri sayesinde fıstığın boyutu, rengi, şekli ve iç dolgunluğu gibi özellikler değerlendirilmiş, böylece kalite kontrol süreci iyileştirilecek ve insan hatası minimize edilmiştir [3].

Derin öğrenme, özellikle Evrişimsel Sinir Ağları (Convolutional Neural Networks - CNN) gibi yöntemle görüntü tanıma konusunda büyük başarılar elde etmiştir [4]. Bu yöntemler, fıstık görüntülerini analiz ederek sınıflandırmayı otomatik hale getirebilir. Ürünlerin farklı kalitelere ayrılması, hasarlı ve sağlam fıstıkların belirlenmesi gibi işlemler için kullanılabilir. Bu da iş gücü maliyetlerini düşürürken aynı zamanda daha tutarlı ve güvenilir sonuçlar sağlar.

Gıda sektöründe izlenebilirlik ve standartlara uygunluk oldukça önemlidir. Derin öğrenme modelleri ile yapılan sınıflandırma sayesinde, her bir fıstık türünün (Siirt ve Antep fıstığı) ait olduğu kalite standardı korunur ve üretim süreçlerinde herhangi bir hile veya sapmanın önüne geçilebilir. Aynı zamanda, ürünlerin coğrafi işaretlerine ve kökenine göre ayırmak, yerel ekonomilerin desteklenmesi açısından da önem taşır. Siirt ve Antep fıstığı gibi yerel ürünler, dünya çapında bilinir ve yüksek ticari değere sahiptir. Derin öğrenme modelleriyle yapılan sınıflandırma, ürünlerin pazar değeri açısından da avantaj sağlar. Farklı kalitelerdeki ürünlerin doğru şekilde sınıflandırılması ve paketlenmesi, ihracat pazarlarında rekabet gücünü artırır. Doğru ürün doğru pazarda olacaktır.

Geleneksel sınıflandırma yöntemleri, genellikle uzman kişiler tarafından yapılan manuel gözlem ve değerlendirme süreçlerini içerir. Ancak derin öğrenme modelleri, geniş veri setleri ile eğitildiğinde bu süreci hızlandırarak büyük ölçekli tarımsal üretimlerde uygulanabilir hale getirir. Bu sayede üretimden satışa kadar olan süreçlerin hızlanması ve optimize edilmesi mümkün olur. Derin öğrenme, tarım sektöründe son yıllarda giderek daha fazla uygulama alanı bulan bir teknoloji haline gelmiştir. Siirt ve Antep fıstığı gibi tarımsal ürünlerin sınıflandırılması üzerine yapılan akademik çalışmalar, hem bilgisayar bilimi hem de tarım bilimi alanlarında önemli katkılar sağlar [5]. Bu çalışmalar, aynı zamanda yapay zeka tabanlı tarım teknolojilerinin daha da geliştirilmesine ve uygulanabilirliğinin artırılmasına katkıda bulunur. Bu tür çalışmalar tarımda dijitalleşme ve yapay zeka uygulamalarının yaygınlaşmasına katkı sağlayarak, sektördeki inovasyonun önünü açmaktadır.

Son yıllarda, literatürde derin öğrenme ve makine öğrenmesi yöntemleriyle tarım ürünlerinin sınıflandırılmasına odaklanan birçok çalışma yapılmıştır [6]-[7]-[8]-[9]. Ancak, özellikle derin öğrenmenin kullanıldığı çalışmalar olmak üzere, fıstık türlerinin sınıflandırılmasıyla ilgili çalışma sayısı oldukça sınırlıdır [10]-[11]- [12]- [13]. Bu çalışmayla, derin öğrenme yöntemlerinden CNN modelleri kullanılarak, Siirt fıstığının sınıflandırılması amaçlanmıştır.

II. MATERYAL VE YÖNTEM

2.1 Veri Setinin Hazırlanması


Veri seti açık kaynak web sitelerinden elde edilen 2148 adet Siirt ve Antep fıstığının görüntülerinden oluşmaktadır (<https://www.kaggle.com/datasets/muratkokludataset/pistachio-image-dataset>). Bunların 916 adedi Siirt, 1232 adedi ise Antep fıstığı görsellerinden oluşmaktadır. Veri setindeki görüntüleri standart hale getirmek için 225x225 piksele dönüştürülmüştür. Daha sonra, bu veri seti, derin öğrenme algoritmaları kullanılarak eğitilmiştir. Veri setinden örnek görüntüler Tablo 1’de verilmiştir.

Tablo 1. Veri setinden seçilen rastgele görüntüler

Türü	Görüntü	Görüntü Sayısı
Siirt Fıstığı		916
Antep Fıstığı		1232

2.2 Evrişimli sinir ağları (CNN)

Evrişimli Sinir Ağı (Convolutional Neural Network - CNN), derin öğrenme ve yapay zeka alanında, özellikle görüntü işleme, nesne tanıma, ses işleme ve doğal dil işleme gibi alanlarda yaygın olarak kullanılan bir yapay sinir ağı türüdür. CNN'ler, geleneksel sinir ağlarından farklı olarak, verilerdeki yerel özellikleri öğrenmek ve modellemek için evrişim (convolution) işlemi kullanırlar. CNN'ler, özellik çıkarımı, yerel bağımlılıkları öğrenme ve daha az parametreyle yüksek doğruluk elde etme gibi avantajlara sahiptir [14]. Bu yapıların öğrenme yetenekleri, farklı alanlardaki birçok problemi çözmede etkili bir araç haline gelmiştir. Şekil 1'de bir evrişimsel sinir ağı örneği gösterilmektedir.



Şekil 1. Evrişimli sinir ağları yapısı

Bu çalışmada fıstık görüntülerinin sınıflandırılması için önceden eğitilmiş ResNet50, ResNet101, ResNet152, MobileNet, Xception, DenseNet modelleri kullanılmıştır. Veri seti eğitim ve test oranları %70-%30 olarak belirlenmiştir. Modelin ağırlıklarını güncellemek için çeşitli optimizasyon yöntemleri (Gradient Descent, SGD, Momentum, RMSprop, Adam vb.) incelenmiştir. Çalışmada, batch size 32 olarak belirlenmiş ve küçük batch boyutlarının daha detaylı ancak dalgalı öğrenme sağladığı, büyük batch boyutlarının ise daha stabil ancak daha fazla kaynak gerektirdiği görülmüştür. Ayrıca, kayıp fonksiyonu olarak Categorical Crossentropy tercih edilmiş olup, model parametreleri eğitim sürecinde bu fonksiyonu minimize edecek şekilde ayarlanmıştır.


III. BULGULAR

Kullanılan derin öğrenme modellerinin doğruluk, kesinlik, duyarlılık ve F1-ölçütü aldığı değerler Tablo 2’de verilmiştir.

Tablo 2. Derin öğrenme modellerinin performans metrikleri


Model Adı	Doğruluk	Kesinlik	Duyarlılık	F1-Ölçütü
MobileNet	0,98	0,98	0,98	0,98
Xception	0,98	0,98	0,98	0,98
ResNet 50	0,99	0,99	0,99	0,99
Resnet 101	0,98	0,99	0,98	0,98
Resnet 152	0,96	0,97	0,96	0,98
DenseNet 169	0,97	0,96	0,97	0,97

Tabloda görüldüğü üzere, belirtilen derin öğrenme modellerinden en yüksek doğruluk, kesinlik, duyarlılık ve F1-ölçütüne ResNet-50 (0.99) modeliyle ulaşmıştır. Tablo 2 incelendiğinde, bütün derin öğrenme modellerinde tüm metriklerde birbirine yakın başarımlar elde edilmiştir. Genel olarak derin öğrenme modelleri sınıflandırma konusunda yüksek başarıya ulaşmıştır. Kullanılan modellerin başarımları grafiksel olarak Şekil 2’de gösterilmiştir.



Şekil 2. Derin öğrenme modelleri sınıflandırma başarımları

Derin öğrenme modellerinin iterasyon sayısına bağlı olarak eğitim ve test başarımları grafikleri Şekil 3’de gösterilmiştir. Grafikler incelendiğinde, bütün modellerin başarımlarının yaklaşık 10. iterasyonda maksimum seviyeye çıktığı, modellerin 100. iterasyona ulaşmaya kadar da başarımlarının maksimum seviyede kalmaya devam ettiği görülmektedir.



Şekil 3. Modellerin başarı performansları ve iterasyon değerleri

Tablo 3’de ise bu modellerin koşturulma süreleri verilmiştir. Çalışmada en uzun süre ResNet-152 modeli, en kısa süre de MobileNet modeliyle elde edilmiştir. En iyi başarıma sahip ResNet-50 modelinin, hız yönünden en iyi ikinci performansa sahip olduğu görülmektedir.

Tablo 3. Derin öğrenme modellerinin doğruluk ve koşturulma süreleri

Model Adı	Doğruluk	Süre
MobileNet	0,98	31 dakika
Xception	0,98	1 saat 41 dakika
ResNet-50	0,99	1 saat 38 dakika
ResNet-101	0,98	3 saat 15 dakika
ResNet-152	0,96	4 saat 11 dakika
DenseNet	0,97	1 saat 41 dakika

IV. TARTIŞMA

Gıda sektöründe izlenebilirlik ve standartlara uygunluk oldukça önemlidir. Derin öğrenme modelleri ile yapılan sınıflandırma sayesinde, her bir fıstık türünün (Siirt ve Antep fıstığı) ait olduğu kalite standardı korunur ve üretim süreçlerinde herhangi bir hile veya sapmanın önüne geçilebilir. Aynı zamanda, ürünlerin coğrafi işaretlerine ve kökenine göre ayırmak, yerel ekonomilerin desteklenmesi açısından da önem taşır. Siirt ve Antep fıstığı gibi yerel ürünler, dünya çapında bilinir ve yüksek ticari değere sahiptir. Derin öğrenme modelleriyle yapılan sınıflandırma, ürünlerin pazar değeri açısından da avantaj sağlar. Farklı kalitelerdeki ürünlerin doğru şekilde sınıflandırılması ve paketlenmesi, ihracat pazarlarında rekabet gücünü artırır. Böylece doğru ürün doğru pazarda olacaktır.

Geleneksel sınıflandırma yöntemleri, genellikle uzman kişiler tarafından yapılan manuel gözlem ve değerlendirme süreçlerini içerir. Ancak derin öğrenme modelleri, geniş veri setleri ile eğitildiğinde bu süreci hızlandırarak büyük ölçekli tarımsal üretimlerde uygulanabilir hale getirir. Bu sayede üretimden satışa kadar olan süreçlerin hızlanması ve optimize edilmesi mümkün olur. Derin öğrenme, tarım sektöründe son yıllarda giderek daha fazla uygulama alanı bulan bir teknoloji haline gelmiştir. Siirt ve Antep fıstığı gibi tarımsal ürünlerin sınıflandırılması üzerine yapılan akademik çalışmalar, hem bilgisayar bilimi hem de tarım bilimi alanlarında önemli katkılar sağlar. Bu çalışmalar, aynı zamanda yapay zekâ tabanlı tarım teknolojilerinin daha da geliştirilmesine ve uygulanabilirliğinin artırılmasına katkıda bulunur. Bu tür çalışmalar tarımda dijitalleşme ve yapay zeka uygulamalarının yaygınlaşmasına katkı sağlayarak, sektördeki inovasyonun önünü açmaktadır.

V. SONUÇLAR

Siirt fıstığının sınıflandırılması, hem tarımsal üretim hem de ticari ve bilimsel çalışmalar açısından kritik bir öneme sahiptir. Bu sınıflandırma, fıstığın genetik özelliklerini, kalite kriterlerini ve yetiştirme koşullarını belirlemek için bir temel sunar. Siirt fıstığı, özellikle yerel ve uluslararası pazarlarda, kendine özgü lezzeti, aroması ve besin değeriyle tanınır. Ancak, bu özelliklerin korunması ve daha iyi anlaşılması için bilimsel bir sınıflandırma gereklidir. Doğru bir sınıflandırma, fıstığın standardizasyonunu sağlayarak ticari değerini artırır ve tüketici güvenliğini destekler. Aynı zamanda, genetik çeşitliliğin belirlenmesi ve korunması, fıstığın hastalıklara, zararlılara ve çevresel değişimlere karşı dayanıklılığını artıracak yeni çeşitlerin geliştirilmesine olanak tanır. Bunun yanı sıra, sınıflandırma çalışmaları, bölgesel tarımsal planlamada etkili kararlar alınmasını sağlayarak Siirt fıstığı üreticilerinin ekonomik getirilerini artıracaktır. Dolayısıyla, Siirt fıstığının sınıflandırılması sadece ekonomik bir değer yaratmakla kalmaz, aynı zamanda sürdürülebilir tarım uygulamaları ve küresel gıda güvenliği açısından da stratejik bir rol oynar.

Bu çalışmada, ResNet50, ResNet101, ResNet152, MobileNet, Xception ve DenseNet gibi ileri düzey derin öğrenme modelleri kullanılmıştır. Modellerin performansları, doğruluk, kesinlik, duyarlılık, F1 skoru gibi metriklerle değerlendirilmiştir. Sonuçlar, özellikle ResNet50 modelinin %99 doğruluk oranı ile en başarılı performansı sergilediğini göstermiştir. Diğer modeller de birbirine yakın performanslar sergileyerek genel olarak yüksek doğruluk oranlarına ulaşılmıştır. MobileNet, en kısa işlem süresi ile dikkat çekerken, ResNet152 en uzun sürede eğitim tamamlamıştır. Bu durum, farklı modellerin performans ve

işlem süresi açısından çeşitli avantaj ve dezavantajlara sahip olduğunu ortaya koymaktadır. Bu çalışmanın, sürdürülebilir tarım uygulamaları ve gıda güvenliği gibi küresel ölçekte stratejik konulara yönelik değerli bir katkı sağladığı düşünülmektedir. Derin öğrenme yöntemlerinin, Siirt fıstığı özelinde sağladığı başarılı sonuçlarla, gelecekte benzer tarımsal ürünlerin sınıflandırılmasında önemli bir yere sahip olacağı beklenmektedir.

KAYNAKLAR

- [1] Brosnan, T., & Sun, D. W. (2004). Improving quality inspection of food products by computer vision—a review. *Journal of food engineering*, 61(1), 3-16.
- [2] Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and electronics in agriculture*, 147, 70-90.
- [3] Aalami, N. (2020). Derin öğrenme yöntemlerini kullanarak görüntülerin analizi. *Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi*, 1(1), 17-20.
- [4] Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 1251-1258).
- [5] Singh, D., Taspınar, Y. S., Kursun, R., Cinar, I., Koklu, M., Ozkan, I. A., & Lee, H. N. (2022). Classification and analysis of pistachio species with pre-trained deep learning models. *Electronics*, 11(7), 981.
- [6] Ramesh, S., Hebbar, R., Niveditha, M., Pooja, R., Shashank, N., & Vinod, P. V. (2018, April). Plant disease detection using machine learning. In *2018 International conference on design innovations for 3Cs compute communicate control (ICDI3C)* (pp. 41-45). IEEE.
- [7] Saleem, M. H., Potgieter, J., & Arif, K. M. (2019). Plant disease detection and classification by deep learning. *Plants*, 8(11), 468.
- [8] Sujatha, R., Chatterjee, J. M., Jhanjhi, N. Z., & Brohi, S. N. (2021). Performance of deep learning vs machine learning in plant leaf disease detection. *Microprocessors and Microsystems*, 80, 103615.
- [9] Vidyarthi, S. K., Tiwari, R., Singh, S. K., & Xiao, H. W. (2020). Prediction of size and mass of pistachio kernels using random Forest machine learning. *Journal of Food Process Engineering*, 43(9), e13473.
- [10] Heidary-Sharifabad, A., Zarchi, M. S., Emadi, S., & Zarei, G. (2021). An efficient deep learning model for cultivar identification of a pistachio tree. *British food journal*, 123(11), 3592-3609.
- [11] Singh, D., Taspınar, Y. S., Kursun, R., Cinar, I., Koklu, M., Ozkan, I. A., & Lee, H. N. (2022). Classification and analysis of pistachio species with pre-trained deep learning models. *Electronics*, 11(7), 981.
- [12] Aktaş, H., Kızıldeniz, T., & Ünal, Z. (2022). Classification of pistachios with deep learning and assessing the effect of various datasets on accuracy. *Journal of Food Measurement and Characterization*, 16(3), 1983-1996.
- [13] Hosseinpour-Zarnaq, M., Omid, M., Taheri-Garavand, A., Nasiri, A., & Mahmoudi, A. (2022). Acoustic signal-based deep learning approach for smart sorting of pistachio nuts. *Postharvest Biology and Technology*, 185, 111778.
- [14] Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 4700-4708).
- [15] İnik, Ö., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.