

Araştırma Makalesi - Research Article

Yaprak Sınıflandırmak için Yeni Bir Evrişimli Sinir Ağı Modeli Geliştirilmesi

Developing a Novel CNN Model for Leaf Classification

Yunus Camgözlü^{1*}, Yakup Kutlu²

Geliş / Received: 28/02/2021

Revize / Revised: 20/07/2021

Kabul / Accepted: 03/10/2021

ÖZ

Doğanın bir parçası olan bitkiler çevremize güzellik katmanın yanı sıra alternatif tıp gibi farklı sebep için de kullanılmaktadır. Bu gibi uzmanlık gerektiren durumlarda halk arasında yayılan yanlış bilgilerle zehirli bitkilerin şifalı olduğu düşünülerek kullanılması ölüme kadar gidebilecek sorunlara yol açmaktadır. Bu çalışmada yapay zeka teknikleri kullanılarak yaprak görüntülerindeki yaprak türlerinin belirlendiği bir sistem aracılığıyla bu sorunlara çözüm sağlanması amaçlanmaktadır. Son zamanlarda yaygın olarak kullanılan yapay zeka tekniklerinden biri olan evrişimli sinir ağı kullanılmıştır. Çok katmanlı yapısı, birçok parametreye sahip olması ve çok fazla ön işlem gerektirmeden öznetelik öğrenebilmesi, birçok çalışmada kullanılmasının nedenlerinden biridir. Bu çalışmada, sabit bir arka plana sahip yaprak görüntülerinden oluşan 5 farklı veri seti ile evrişimli sinir ağının eğitimi ayrı ayrı yapılmış ve bu eğitim sonucu parametrelerin eğitime olan etkisi incelenmiştir. Bu veri setlerinin birleştirilmesiyle elde edilen 270 türden oluşan birleştirilmiş bir veri seti oluşturulmuştur. Evrişimli sinir ağı ile genel amaçlı bir yaprak sınıflandırma modeli elde edilmiştir. Sınıflandırma işlemi ile elde edilen sonuçlar literatürdeki çalışmalar ile karşılaştırılmıştır.

Anahtar Kelimeler- *Segmentasyon, Derin Öğrenme, Görüntü İşleme, Yaprak Sınıflandırma*

ABSTRACT

Plants, which are a part of nature, are used for different reasons, such as alternative medicine as well as adding beauty to our environment. In such cases requiring expertise, the misinformation spread among the public and the use of poisonous plants considering that they are medicinal causes problems that can go up to death. In this study, it is aimed to solve these problems through a system that determines the species of leaves in leaf images using artificial intelligence techniques. Convolutional Neural Network (CNN), one of the most widely used artificial intelligence techniques, has been used recently. Its multi-layer structure, having many parameters and being able to learn features without requiring too much pre-processing is one of the reasons why it is used in many studies. In this study, the training of the convolutional neural network was carried out separately with 5 different data sets consisting of leaf images with a fixed background, and the effect of these training parameters on training was investigated. A combined data set consisting of 270 species obtained by combining these data sets was created. A general purpose leaf classification model is obtained with convolutional neural network. The results obtained by the classification process were compared with the studies in the literature.

Keywords- *Segmentation, Deep Learning, Image Processing, Leaf Classification*

^{1*}Sorumlu yazar iletişim: yunuscamgozlu@gmail.com (<https://orcid.org/0000-0002-9849-8155>)

Bilgisayar Mühendisliği, İskenderun Teknik Üniversitesi, İskenderun, Hatay

²İletişim: yakup.kutlu@iste.edu.tr (<https://orcid.org/0000-0002-9853-2878>)

Bilgisayar Mühendisliği, İskenderun Teknik Üniversitesi, İskenderun, Hatay

I. GİRİŞ

Bitkilerin süs eşyası olmak dışında alternatif tıp gibi farklı alanlarda da sıkça kullanıldığı görülmektedir. Bu gibi uzmanlık gerektiren durumlarda kulaktan dolma bilgilerle bitkilerin yanlış şekilde ya da zehirli olmasına rağmen şifalı olduğu düşünülerek kullanılması ölüme kadar gidebilecek pek çok soruna yol açmaktadır. Türkiye ve Dünya’da pek çok bitki alternatif tıp ya da farklı nedenlerle kullanılmaktadır, bu durumu göz önüne alarak herhangi bir uzmanlığı olmayan sıradan insanların bitkiler hakkında detaylı bir bilgiye sahip olması beklenemez. Günlük hayatımızın birçok alanında teknolojinin sorunları çözdüğü veya iyileştirdiği dikkate alındığında, bitkilerin doğru kullanımı gibi uzmanlık gerektiren bu sorunu yaprak görüntülerine uygulanan yapay zeka teknikleri ile oluşturulan bir sistemin geliştirilmesi amaçlanmaktadır.

Yapay zeka ve alt dalları insanların yapacağı işlemleri daha hızlı yapmak, karmaşık hesaplamalarla girdi olarak aldıkları verileri işleyen ve buna göre istenen sonucu üretebilmektedir. Çağın önde gelen teknolojilerinden biri olarak birçok alanda önemli mesafeler kat edilmesini sağlamıştır. Geliştirilen yapay zeka teknolojileri günlük hayatta pek çok durumda yarar sağlamışlardır, bunun yanı sıra akademik olarak sağladıkları katkılara örnek vermek gerekirse doğadaki hayvan, bitki, böcek ve daha küçük canlıları daha iyi anlayabilmek için bir çok bilim insanının yararlandığı önemli bir araçtır.

Derin öğrenmenin alt dallarından biri olan Evrişimli Sinir Ağı (ESA), yüksek başarımlar elde ederek kullanım alanlarını her geçen gün genişleten görüntü odaklı çalışan bir yöntemdir. Evrişimli sinir ağının yapısında bulunan birden çok parametre (katmanlar, fonksiyonlar, filtreler gibi) mevcuttur. Yeni bir evrişimli sinir ağı modeli geliştirilirken havuzlama katman parametresi [1], filtre boyutu [2], görüntü boyutu [3], katman sayısı gibi pek çok parametreyi dikkate alarak uygun parametrelerin incelenmesi gerekmektedir. Bu modeller 2 parçaya ayrılır, öznitelik öğrenimi yapılan bölüm ve bu öznitelik yardımıyla sınıflandırma yapılan bölümden oluşmaktadır. Girdi olarak aldığı görüntülerden öznitelikleri öğrenerek bu özniteliklere göre sınıflandırma yapması diğer sınıflandırma metodların da gerekli olan ek işlemleri ortadan kaldırarak daha az işlem yapılmasına ve bu işlemler yapılmayarak elde edilen zamanın, yapılan eğitimdeki iterasyon sayısının arttırılmasına katkı sağlayabilmektedir.

Bu çalışmada sabit arka plan görüntüsüne, farklı ölçeklerde yaprak görüntülerine sahip olan 5 farklı yaprak veri seti ve bu veri setlerinin birleştirilmiş halinin ESA ağı ile sınıflandırılması yapılmıştır. Bu veri setleri literatürde yapılan araştırmalar sonucu elde edilen birçok veri seti arasından seçilmiştir. Eğitim için uygunluklarını test etmek amacıyla bu çalışmada kullanılacak model ile farklı denemeler yapılmıştır. Yapılan bu denemeler sonucu kullanılacak modeldeki konvolüsyon filtre boyutu, havuzlama katmanı sayısı ve türünün yanı sıra veri setlerinde bulunan görüntülerin boyutlarının değişimine bakılarak kullanılacak yapı oluşturulmuştur. Buna ek olarak yaprak görüntülerinin renkli veya gri resim olması ile birlikte arka plan renginin etkisi de incelenmiştir. Belirlenen veri setlerine döndürme, aynalama gibi çeşitli görüntü işleme teknikleri kullanılarak veri çoğaltma işlemi uygulanmıştır. Ayrıca bu veri setlerinin birleştirilmesi sonucu elde edilen yeni veri setinde farklı arka plan rengine sahip veri setleri arka plan çıkarma işlemi uygulanarak beyaz arka plana sahip yaprak resimleri bulunacak şekilde düzenlenmiştir. Son olarak birleştirilmiş veri setinde, farklı veri setlerinde bulunan aynı türdeki görüntüler birleştirilerek aynı türden birden fazla olması engellenmiştir. Yapılan bu işlemler sonucu elde edilen sonuçlar literatürdeki evrişimli sinir ağı kullanılan çalışmaların görüntü sayısı, kullanılan tür sayısı ve elde edilen başarımları ile kıyaslanarak değerlendirilmiştir.

Akademik çalışmalar için oluşturulan yaprak veri setlerinin kullanıldığı çalışmalara bakıldığında destek vektör makinesi, [4–8] en yakın komşu algoritması, [9,10] karar ağacı, [11] olasılıksal sinir ağı, [12,13] ve evrişimli sinir ağı eğitimi sırasında çıkarılan özniteliklerin farklı sınıflandırma yöntemleri ile kullanılması [14-17] gibi farklı yöntemler göze çarpmaktadır. Bu çalışmanın da konusu olan evrişimli sinir ağı kullanılarak yaprak veri setlerinin sınıflandırıldığı çalışmalara bakıldığında ESA modellerinin farklı kombinasyonlarda kullanılması ya da farklı görüntü boyut ve türlerinin girdi olarak kullanıldığı çalışmalar literatürde bulunmaktadır. Renkli görüntülerden oluşan 3 farklı yaprak veri seti, 11 konvolüsyon ve 6 maksimum havuzlamalı bir yapıya sahip modelle renkli görüntüler kullanılarak sınıflandırılmıştır [18]. Yaprak ve çiçek görüntülerinden oluşan veri seti, segmentasyon işlemi sonrası farklı işlemlerden geçerek evrişimli sinir ağı sınıflandırılır. Tahmin edilen türlere dayalı bir analiz ile sınıflandırma yapılır [19]. Evrişimli sinir ağı modelinde doğrusallık fonksiyonu olan ReLU yerine ELU kullanılarak sınıflandırma yapılmıştır [20]. 2 farklı yaprak görüntüsü, 2 farklı ESA modeli ile sınıflandırılmıştır [21].

II. MATERYAL VE METOD

A. Veri Setleri

Literatürde yapılan araştırmalar sonucu farklı sayıda tür, görüntü sayısı ve bu görüntülerin renkli, gri veya siyah beyaz görüntüler bulunduran yaprak veri setlerinin değerlendirilmesi yapılmıştır. Ayrıca bu veri setleri birleştirilerek yeni bir veri seti (Birleşmiş VS) haline getirilmiştir. Daha sonra oluşturulan evrişimli sinir ağı modeli ile sınıflandırma çalışmaları yapılmıştır.

- 1) *Mendeley Veri Seti*: Mendeley [22] veri seti hastalıklı ve sağlıklı yapraklardan oluşmaktadır. 12 tür ve 4404 görüntünün bulunduğu bu veri setinde hastalıklı yaprak görüntülerinden kullanıma uygun olmayanlar çıkarılmıştır.
- 2) *Swedish Leaf Veri Seti*: Swedish Leaf [23] veri setinde bulunan 15 türdeki 1125 yaprak görüntüsü beyaz arka planlıdır.
- 3) *Flavia Veri Seti*: 32 tür ve 1907 görüntünün bulunduğu Flavia [12] veri setindeki yaprak görüntüleri beyaz arka planlıdır.
- 4) *UCL Veri Seti*: 40 tür ve 443 görüntünün bulunduğu UCL [24] veri setinde yaprak görüntülerinin arka plan renkleri farklılık göstermektedir.
- 5) *Leafsnap Veri Seti*: 2 bölümden oluşan Leafsnap [25] veri setinde bulunan lab adlı bölümdeki görüntüler kullanılmıştır. Bu veri seti 185 tür ve 23147 görüntüden oluşmaktadır.
- 6) *Birleşik Veri Seti*: Tüm veri setleri birleştirilirken ortak türler tek bir türe indirgenmiştir, bu sayede 283 olan toplam tür sayısı 270'e düşürülmüştür.

Kullanılan veri setleri incelendiğinde, her veri setindeki tür başına düşen görüntü sayısının az olması ve yapılacak eğitimler sonucu elde edilecek başarımların artırılması amacıyla görüntü işleme teknikleri kullanılarak veri çoğaltma yapılmıştır. Bu işlemler sonucu elde edilen görüntü sayıları Tablo 1'de görülmektedir. Kullanılan görüntü işleme teknikleri veri setlerinin orijinal görüntü sayısına göre farklılık göstermektedir. UCL gibi tür sayısı fazla, görüntü sayısı çok az olan veri setine öncelikle yansıtma işlemi uygulanmıştır. Daha sonra ise diğer veri setlerine de uygulanan 30 dereceden 330 dereceye kadar 30 derecelik artışlarla 11 farklı açıda döndürme işlemine tabi tutulmuştur. Bu işlemler sonucu veri setindeki orijinal görüntülerde dahil olmak üzere 12 farklı açının bulunduğu bir yapı oluşturulmuştur. Leafsnap ve birleşik veri setinde ise farklı görüntü sayısına sahip olan birçok tür bulunmaktadır. Bu veri setlerinde düşük görüntü sayısına sahip türlerdeki görüntülere farklı sayıda döndürme işlemi uygulanmıştır. Veri setlerinde bulunan görüntülerin farklı rotasyonlarda olması sebebiyle aşırı öğrenmeyi önlemek için veri çoğaltma işlemi sınırlı ve çok fazla görüntüye sahip türler için farklı bir şekilde yapılmıştır. Ayrıca yapılan çoğaltma işlemleri sonrası eğitim ve test verisi ayrımı yapılmıştır. Kullanılan 5 farklı veri setinden arka plan rengi beyaz olmayanlara, arka plan çıkarma işlemi uygulanarak tüm veri setleri birleştirilirken aynı arka plana sahip görüntüler elde edilmiştir. Yapılan bu işlem tüm veri setlerinin birleştirilmiş haline özgü olmakla birlikte, oluşturulmuş olan bu birleştirilmiş veri setinin benzer özelliklere sahip olmasını da sağlamıştır. 5 farklı veri setinin birleştirilmesi sonucu 283 tür olduğu görülmektedir, aynı türlerin bulunduğu bu veri setlerinin birleştirilmesinde ortak türlerin görüntüleri birleştirilmiştir. 270 türe sahip olan birleştirilmiş veri seti, birleştirilirken kullanılan veri setleri farklı sayıda döndürme işlemlerine tabi tutulmuştur.

Tablo 1 Kullanılan veri setlerinin tür sayısı, görüntü sayısı ve veri çoğaltma sonrası elde edilen görüntü sayısı

Veri Seti	Tür Sayısı	Görüntü Sayısı	Veri Çoğaltma Sonrası Görüntü Sayısı
Mendeley	12	4 149	52 624
Swedish Leaf	15	1 125	13 500
Flavia	32	1 907	22 877
UCL,	40	443	10 632
Leafsnap	184	11 234	57 966
Birleşmiş VS(Tüm Veri Setleri Birleşik Hali)	270	18 858	65 100

B. Evrişimli Sinir Ağı

ConvNets, derin öğrenme alanında daha genel bir model sınıfının bir çeşididir. Bu modeller, birçok katmanlı mimariye özel bir vurgu yapmaktadır [26]. Evrişimli sinir ağı modelleri, farklı sayıda katmandan ve bu katmanlardaki farklı parametreler ile fonksiyonlardan oluşmaktadır. Konvolüsyon, havuzlama, düzleme ve sınıflandırma katmanlarında yapılan değişikliklerle farklı amaçlara hizmet eden modeller oluşturulmaktadır. Bu katmanlardan biri olan konvolüsyon katmanı, görüntüleri işlerken kullandığı filtreleri resim üzerine uygulayarak yüksek seviyeli özniteliklerin çıkarılmasını sağlar. Bu işlem yapılırken kullanılan filtre boyutlarının artıp azalması öğrenilen öznitelik miktarını etkilemektedir. Havuzlama katmanı, maksimum, ortalama ve minimum havuzlama olarak 3 farklı türde bulunmaktadır. Filtreler resim üzerinde dolaşırken kullanılan havuzlama katmanına göre maksimum veya ortalama değeri olarak işlemi sonuçlandırır.

Modele göre değişiklik gösteren farklı sayıdaki konvolüsyon ve havuzlama katmanlarından sonra gelen düzleme katmanı, bu katmanlarla sınıflandırma katmanı arasında köprü görevi görür. Düzleme katmanı önceki katmanlar tarafından oluşturulan çok boyutlu matrisi, tek boyutlu matris haline dönüştürerek iletir. Sınıflandırma katmanında bulunan nöronlar aracılığıyla etiket ile eşlenmiş değerleri inceler ve doğruluğu fazla olan etiketler belirlenerek sınıflandırma yapılır.

C. Model

Bu çalışmada kullanılan veri setlerinden bir kaçı ile yapılan bu çalışmalar sonucunda farklı veri setlerinin, farklı görüntü sayısı ve farklı boyuttaki yaprak görüntülerine göre elde ettiği sonuçlar değerlendirilmiştir. Buna göre oluşturulan modelde, 6 konvolüsyon ve 3 ortalama havuzlama katmanı bulunmaktadır, konvolüsyon filtre boyutu ise 3 olarak belirlenmiştir. Ayrıca bu model için yapılan görüntü boyutu ve yaprak görüntülerinin arka plan renklerine dayalı analize göre görüntü sayısı fazla olan veri setleri de dikkate alınarak 90x75 boyutlu gri resimlerin kullanılması tercih edilmiştir.

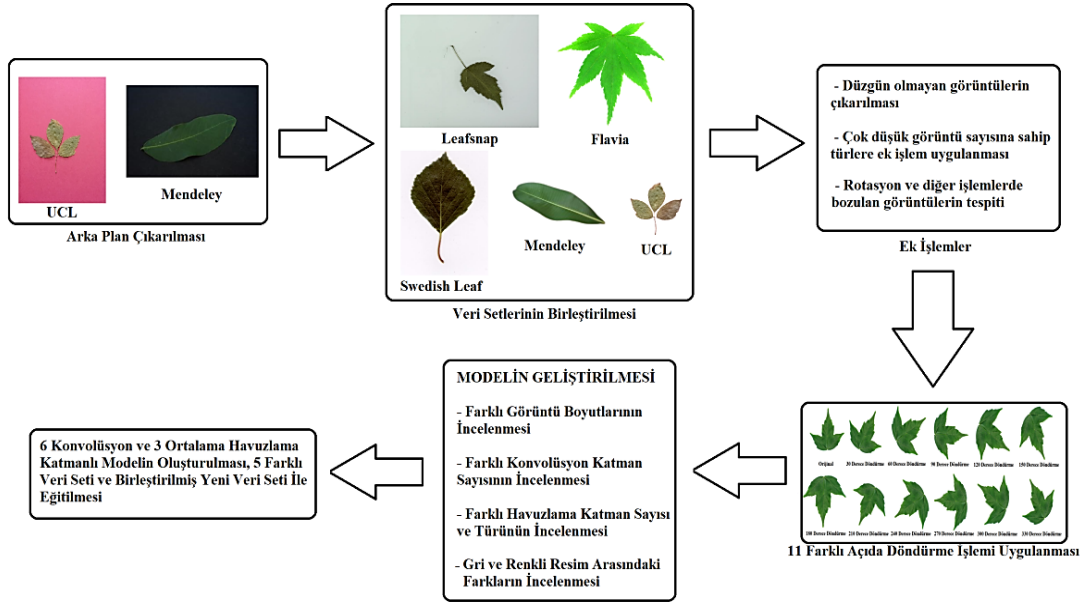
ESA modeli kullanılırken belirli değerler ve fonksiyonlar standart şekilde bırakılırken bazıları ise yapılan denemeler sonucunda özel olarak değiştirilmiştir. Rastsallaşma değeri 4 olarak belirlenirken aktivasyon fonksiyonu ReLu olarak belirlenmiştir. Son katmanda ise Softmax aktivasyon fonksiyonu kullanılmıştır. Optimizasyon fonksiyonu olarak Adam kullanılan modelimizde öğrenme oranı 0.001 olarak belirlenmiştir. Son olarak parça boyutu ise 250 olarak belirlenmiştir.

III. SONUÇLAR

A. Sonuç

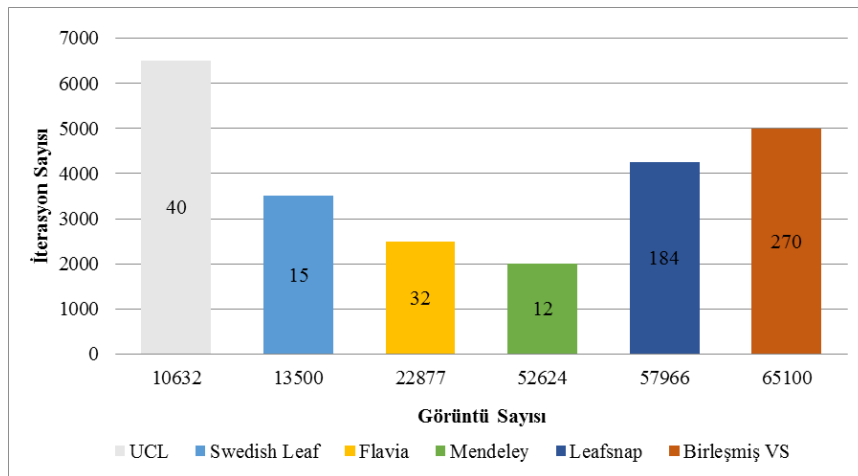
Yaprak sınıflandırılmasında yeni bir ESA modeli geliştirmek ve bu model için uygun parametrelerin belirlenmesi gerçekleştirilmiştir. Bu amaçla 5 farklı veri seti ve bu veri setlerinin birleştirilmesi sonucu elde edilen yeni veri setinin görüntü işleme teknikleri ile ön işlemler yapılmıştır. Daha sonra ise oluşturulan evrişimli sinir ağı modeli ile bu veri setleri sınıflandırılmıştır. Bu çalışmada ESA eğitimi için kullanılan açık kaynak kodlu tensorflow kütüphanesi kullanılmıştır. Python programlama dilinde yazılan kodlar AMD Ryzen 5 3600x işlemci, Nvidia GTX 1080 ekran kartı ve 32 gigabayt sistem belleğine sahip bir bilgisayarda çalıştırılmıştır.

Şekil 1'de yapılan çalışmanın kısa bir özeti gösterilmektedir. Farklı arka plana sahip veri setlerine uygulanan arka plan çıkarma işlemi sonrası birleştirilen veri setleri döndürme işlemine tabi tutulmuştur. Bu işlem öncesinde uygun olmayan görüntüler çıkarılır ve yapılan tarama sonucunda az görüntü sayısına sahip olan türlere yansıtma işlemi uygulanır. Farklı veri setleri ve farklı değişkenlerin test edilmesi ile yapılan çalışmalar sonucunda model oluşturulur ve bu model kullanılarak sınıflandırma işlemi yapılır.




Şekil 1. Yapılan çalışmanın akış diyagramı

Model geliştirilmesinde veri setleri %80 eğitim %20 test verisi olarak kullanılmış ve sınıflandırma sonucu elde edilen sonuçlar, veri setlerindeki görüntü sayısı, tür sayısı, iterasyon sayısı ve başarımları birlikte değerlendirilmiştir. Ayrıca literatürde ESA sınıflandırma yöntemi kullanılan çalışmalar ile kıyaslama yapılmıştır. Yeni bir evrimsel sinir ağı modeli geliştirirken sınıflandırma ve birleşik veri seti oluşturulması için seçilen 5 veri seti ile yapılan simülasyon sonuçları değerlendirilmiştir. Dikkate değer parametreleri kullanarak yeni modelin tasarımı belirlenmiştir. Şekil 2 ve Şekil 3'te gösterilen grafiklere bakıldığında, kullanılan veri setlerinin görüntü sayılarına, ortalama görüntü sayıları ve sınıflandırma için belirlenen iterasyon sayıları arasındaki kayda değer bir ilişki söz konusudur. Genel olarak örnek sayısı arttıkça iterasyon sayısı artmaktadır. Fakat her tür için ortalama görüntü sayısı arttıkça iterasyon sayısının azaldığı görülmektedir. Örneğin Mendeley veri seti gibi her bir türünde çok sayıda yaprak görüntüsü olması eğitimi kısa sürede yani düşük iterasyonla tamamlayabildiğini göstermektedir. Diğer taraftan yakın sayıda olan UCL ve Flavia veri setlerine (sırasıyla 40 tür ve 32 tür) bakıldığında UCL veri setinde ortalama örnek sayısı 266/Tür iken Flavia veri setinde ortalama örnek sayısı 715/Tür görülmektedir. Burada iterasyon sayılarına bakıldığında UCL veri seti daha uzun sürede eğitilmiştir.



Şekil 2. Evrimsel sinir ağı ile yaprak sınıflandırmada iterasyon sayısı, görüntü sayısı ve tür sayısı arasındaki ilişki



Şekil 3. Evrişimli sinir ağı ile yaprak sınıflandırmada iterasyon sayısı, ortalama görüntü sayısı ve tür sayısı arasındaki ilişki

Evrişimli sinir ağı ile yapılan yaprak sınıflandırma işleminde veri setlerinin tür sayısı, görüntü sayısı, iterasyon sayısı ve başarımları Tablo 2’de görülmektedir. Buna göre yüksek görüntü sayısı ve düşük tür sayısı için az iterasyonla yüksek eğitim başarımları sağlanmaktadır. Yüksek tür ve görüntü sayısına sahip veri setleri için iterasyon sayıları da artmaktadır.

Literatüre baktığımızda evrişimli sinir ağı ile yaprak veri setlerinin sınıflandırılması az olmakla birlikte bu çalışmada kullanılan UCL, Mendeley ve birleşik veri setleri için herhangi bir çalışma bulunmamaktadır. Yapılan eğitimlerin uzun sürmesi ve yüksek donanım ihtiyacı duyulması araştırmacıların işini zorlaştırmaktadır.

Literatürde, yeni model eğitmek yerine hazır eğitilmiş modellerin kullanıldığı yaprak tanıma modelleri mevcuttur.

Tablo 2. Veri setlerinin tür sayısı, görüntü sayısı ve başarımları

Veri Seti	Tür Sayısı	Görüntü Sayısı	İterasyon Sayısı	Eğitim Başarımları	Test Başarımları	Eğitim/Test Oranı
Mendeley	12	52 624	2 000	96,22	91,30	%80 - %20
Swedish Leaf	15	13 500	3 500	97,89	90,00	%80 - %20
Flavia	32	22 877	2 500	96,57	90,99	%80 - %20
UCL	40	10 632	6 500	97,48	86,02	%80 - %20
Leafsnap	184	57 966	4 250	94,05	87,32	%80 - %20
Birleşmiş VS	270	65 100	5 000	88,01	79,00	%80 - %20

Leafsnap veri setinin kullanıldığı derin öğrenme tabanlı sınıflandırma yöntemlerinin karşılaştırılması Tablo 3’de görülmektedir. Aynı veri setini kullanan diğer çalışmaya (Barre, 2017) bakıldığında yaprak görüntüleri farklı veri çoğaltma yöntemleriyle kullanılarak 272300’e çıkarılmış ve 200000 iterasyona kadar eğitim yapılmıştır. Düşük görüntü boyutu kullanılmasına rağmen daha iyi bir başarımlar elde edilmiştir.

Tablo 3. Leafsnap veri setinin sınıflandırılmasında metod, tür, görüntü sayısı ve başarımları kıyaslaması

Çalışmayı Yapan	Metot	Tür Sayısı	Görüntü Sayısı	Başarımları	Eğitim/Test Oranı
Barre, 2017	ESA	184	272 300	86,30	%99 - %1
Shah, 2017	ESA	150	7 710	95,61	%70 - %30
Bu çalışma da	ESA	184	57 966	87,32	%80 - %20

Swedish Leaf veri setinin kullanıldığı derin öğrenme tabanlı sınıflandırma yöntemlerinin karşılaştırılması Tablo 4’de verilmiştir. Tabloda görüldüğü üzere aynı veri seti kullanılarak farklı görüntü sayısı ile yapılan çalışmaya baktığımızda, yapılan sınıflandırmanın daha iyi başarımlar sağladığı görülmektedir. Fakat görüntü çoğaltma algoritmalarının kullanılma sebeplerinden biri genelleme performansını arttırmaktır.

Yaptığımız çalışmada eğitilen modelin rotasyon bağımsız hale getirilmesi ve ESA eğitimlerinin daha iyi yapılmasıdır. Ayrıca düşük görüntü sayısına sahip çalışmanın yüksek görüntü boyutlu resim kullanılarak eğitim gerçekleştirilmiş olması da yüksek başarıma ulaşmasındaki etkenlerden biridir.

Tablo 4. Swedish Leaf veri setinin sınıflandırılmasında metot, tür, görüntü sayısı ve başarı oranı kıyaslaması

Çalışmayı Yapan	Metot	Tür Sayısı	Görüntü Sayısı	Başarı Oranı	Eğitim/Test Oranı
Atabay, 2016	ESA	15	2 250	99,11	%70 - %20
Bu çalışma da	ESA	15	13 500	90,00	%80 - %20

Literatürde farklı sınıflandırma yöntemleri ile sıkça kullanılan Flavia veri seti, evrişimli sinir ağı modelleri ve bazı parametreleri sınıflandırma yapıldığı Tablo 5’de görülmektedir. Yapılan çalışmalara baktığımızda görüntü sayısının etkisi önemli olduğundan farklı oranlarda görüntü çoğaltma yapıldığı görülmektedir. Shah (2017) yaptığı çalışmada veri çoğaltma işlemi yapılmamıştır. Buna karşın Atabay (2016), Barre (2017) ve önerdiğimiz çalışmada farklı veri artırma oranları kullanıldığı görülmektedir. Bunun yanı sıra yüksek görüntü boyutu ile işlem yapılan bu çalışmalardan en iyi başarıma sahip olan çalışmada hem yaprak görüntüleri hem de yaprak doku parçalarıyla eğitilen 2 farklı model birleştirilerek eğitim yapılmış bir evrişimli sinir ağı yaklaşımı kullanılmıştır.

Tablo 5. Flavia veri setinin sınıflandırılmasında metot, tür, görüntü sayısı ve başarı oranı kıyaslaması

Çalışmayı Yapan	Metot	Tür Sayısı	Görüntü Sayısı	Başarı Oranı	Eğitim/Test Oranı
Atabay, 2016	ESA	32	3 814	97,24	%70 - %20
Barre, 2017	ESA	32	44 623	97,90	%99 - %1
Shah, 2017	ESA	32	1 907	99,28	%70 - %30
Bu çalışmada	ESA	32	22 877	90,99	%80 - %20

Son olarak Tablo 2’de verilmiş sonuçlara bakıldığında birleşmiş veri setinde artırılmış görüntü sayısı ile toplam 65100 örnek kullanılırken 5000 iterasyonda %88 eğitim başarımları ve %79 test başarımları elde edilmiştir. Bu açıdan literatüre baktığımızda 270 farklı türe sahip birleşmiş veri seti için yapılmış bir çalışma mevcut değildir. Bu sebeple karşılaştırma yapılamamaktadır.

B. Tartışma

Bu çalışmada, bitkilerin genel tür çeşitliliği göz önüne alındığında, görsel bitki türü tanımlamasının tam bir otomatikleşme olmaması sebebiyle yaprak türlerini sınıflandırmak için yapılan modellerin karşılaştırılması yapılmıştır. Derin Öğrenme yaklaşımları, yeni görsel eğitim verileri ile kendi kendine öğrenen bir alternatif sunan bir modeldir. Bu sebeple farklı veri setleriyle performans incelenerek farklı özelliklere sahip yaprak veri setlerinin oluşturulan modele göre davranışları gösterilmiştir. Yapılan çalışmalara baktığımızda eğitimde görüntü sayısının etkisi önemli olduğundan farklı oranlarda görüntü çoğaltma yapıldığında, bu işlemin başarımları arttığı görülmektedir.

Tüm veri setleri birleştirilerek elde edilen 270 farklı türe sahip yeni birleşmiş veri setinde artırılmış görüntü sayısı ile toplam 65100 örnek kullanılmıştır. Derin öğrenme modeli eğitiminde 5000 iterasyonda %88 eğitim başarımları ve %79 test başarımları elde edilmiştir. Bu açıdan literatüre baktığımızda 270 farklı türe sahip geniş bir veri seti için yapılmış bir çalışma mevcut değildir.

KAYNAKLAR

- [1] Camgözlü, Y. & Kutlu, Y. (2019). Analysis of Pooling Effect on CNN using Leaf Database. *Natural and Engineering Sciences*, 4(3), 118 – 123.
- [2] Camgözlü, Y. & Kutlu, Y. (2020). Analysis of Filter Size Effect in Deep Learning. arXiv: 2101.01115.
- [3] Camgözlü, Y. & Kutlu, Y. (2020). Derin Öğrenme ile Yaprak Sınıflandırma da Görüntü Boyutu Arka Plan Rengi ve Gri Resim ile Renkli Resim Arasındaki Farkın İncelenmesi. *Akıllı Sistemler ve Uygulamaları Dergisi*, 3(2), 130-133.
- [4] Tsolakidis, D., Kosmopoulos, D. & Papadourakis, G. (2014). Plant Leaf Recognition Using Zernike Moments and Histogram of Oriented Gradients. *Artificial Intelligence: Methods and Applications*. SETN 2014. Lecture Notes in Computer Science, 8445, 406-417.

- [5] Tomar, D. & Agarwal, S. (2016). Leaf Recognition for Plant Classification Using Direct Acyclic Graph Based Multi-Class Least Squares Twin Support Vector Machines. *International Journal of Image and Graphic*, 16 (3), 1650012-1 – 1650012-17.
- [6] Wang, Z., Sun, X., Ma, Y., Zhang, H., Ma, Y., & Xie, W. (2014). *Plant Recognition Based on Intersecting Cortical Model*. 2014 International Joint Conference on Neural Networks, 975-980.
- [7] Wang, X., Du, W., Guo, F. & Hu, S. (2020). Leaf Recognition Based on Elliptical Half Gabor and Maximum Gap Local Line Direction Pattern. *IEEE Access*, 8, 39175 – 39183.
- [8] Zhang, Y., Cui, J., Wang, Z., Kang, J. & Min, Y. (2020). Leaf Image Recognition Based on Bag of Features. *Applied Sciences*, 10, 5177 - 5194.
- [9] Kır, B., Öz, C. & Gülbağ, A. (2012). *K-NN Sınıflandırma Algoritması Kullanılarak Yaprak Tanıma*. 20. Signal Processing and Communications Applications Conference, 18 – 20 April 2012, Fethiye, Muğla Turkey, 1 - 4.
- [10] Lavania, S. & Matey, P. (2014). *Leaf Recognition using Contour Based Edge Detection and SIFT Algorithm*. 2014 IEEE International Conference on Computational Intelligence and Computing Research, 1-4.
- [11] Keivani, M., Mazloum, J., Sedaghatfar, E. & Tavakoli, M. (2020). Automated Analysis of Leaf Shape, Texture and Color Features for Plant Classification. *International Information and Engineering Technology Association, Traitement du Signal*, 37(1), 17 – 28.
- [12] Wu, S., Bao, F., Xu, E., Wang, Y., Chang, Y. & Xiang, Q. (2007). *A Leaf Recognition Algorithm for Plant Classification Using Probabilistic Neural Network*. 2007 IEEE Int. Symp. Signal Process. Inf. Technol. 11-16.
- [13] Kadir, A., Edi, L., Susanto, A. & Santosa, P. (2011). Leaf Classification Using Shape, Color and Texture Features. *International Journal of Computer Trends and Technology*, 1(3), 306-311.
- [14] Lee, S., Chan, C., Mayo, S. & Remagnino, P. (2017). How Deep Learning Extract and Learns Leaf Features for Plant Classification. *Pattern Recognition*, 71, 1-13.
- [15] Wang, Z., Sun, X., Yang, Z., Zhang, Y., Ying, Z. & Ma, Y. (2017). Leaf Recognition Based on DPCNN and BOW. *Neural Processing Letters*, 47, 99 – 115.
- [16] Hewitt, C. & Mahmoud, M. (2018). Shape-only Features for Plant Leaf Identification. arXiv:1811.08398.
- [17] Beikmohammadi, A. & Faez, K. (2018). *Leaf Classification for Plant Recognition with Deep Transfer Learning*. 2018 4th Iranian Conference on Signal Processing and Systems, 21-26.
- [18] Barre, P., Stöver, B., Müller, K. & Steinhage, V. (2017). Leaf Net: A Computer Vision System for Automatic Plant Species Identification. *Ecological Informatics*, 40, 50 – 56.
- [19] Krause, J., Baek, K., Lim, L. & Sugita, G. (2018). *WTPlant (What's That Plant?): A Deep Learning System for Identification Plants in Natural Images*. International Conference on Multimedia Retrieval, 517-520.
- [20] Atabay, H. (2016). A Convolutional Neural Network with A New Architecture on Leaf Classification. *IJOAB*, 7(5), 326 – 331.
- [21] Shah, M., Singha, S. & Awate, S. (2017). *Leaf Classification using Marginalized Shape Context and Shape + Texture Dual-Path Deep Convolutional Neural Network*. 2017 International Conference on Image Processing, 860-864.
- [22] Chouhan S., Singh, U., Kaul, A. & Jain, S. (2019). *A Data Repository of Leaf Images: Practice towards Plant Conservation with Plant Pathology*. 2019 4th International Conference on Information Systems and Computer Networks (ISCON), 700-707.
- [23] Söderkvist, O. (2001). *Computer Vision of Leaves from Swedish Trees*. Master's thesis, Linköping University, The Institute of Technology, Department of Electrical Engineering, Computer Vision.
- [24] Silva, P., Marcal, A. & Silva, R. (2013). Evaluation of Features for Leaf Discrimination. *Springer Lecture Notes in Computer Science*, 7950, 197-204.
- [25] Kumar, N., Belhumeur, P., Biswas, A., Jacobs, D., Kress, W., Lopez, I. & Soares, V. (2012). *Leafsnap: A Computer Vision System for Automatic Plant Species Identification*. European Conference on Computer Vision (ECCV 2012), 502-516.
- [26] Humphery, E. & Bello, J. (2012). *Rethinking Automatic Chord Recognition with Convolutional Neural Networks*. 2012 11th International Conference on Machine Learning and Applications, 357-362.