

DERİN ÖĞRENME İLE YAPRAK SINIFLANDIRMA DA GÖRÜNTÜ BOYUTU, ARKA PLAN RENGİ VE GRİ RESİM İLE RENKLİ RESİM ARASINDAKİ FARKIN İNCELENMESİ

EXAMINING THE DIFFERENCE BETWEEN IMAGE SIZE, BACKGROUND COLOR, GRAY PICTURE AND COLOR PICTURE IN LEAF CLASSIFICATION WITH DEEP LEARNING

Yunus CAMGÖZLÜ¹, Yakup KUTLU²

¹Bilgisayar Mühendisliği Bölümü, İskenderun Teknik Üniversitesi, Hatay, Türkiye

yunuscamgozlu@gmail.com

²Bilgisayar Mühendisliği Bölümü, İskenderun Teknik Üniversitesi, Hatay, Türkiye

yakup.kutlu@iste.edu.tr

Özetçe—Akademik çalışmalarda başarı kadar işlem süresi, gerekli işlem gücü gibi sürecin parametrelerindeki değişikliklere bağlı olarak değişen birçok faktör vardır. Sınıflandırma, tanıma ve tespit için kullanılan yöntemlerde girdi olarak alınan verilerdeki değişiklikler sonucu etkileyebileceği gibi kullanılan yöntemlere özgü değişkenler de etkileyebilir. Sınıflandırma ve tanıma gibi süreçlerde kullanımı gün geçtikçe artan evrişimli sinir ağları, renkli, gri veya siyah beyaz görüntüler dahil olmak üzere farklı görüntü boyutlarındaki veri setlerinin özelliklerini, katmanlardaki filtreler ve fonksiyonlarla öğrenir ve sınıflandırır. Oluşturulan modeldeki katmanlar, bu katmanlardaki filtreler ve filtrelerin boyutları gibi birçok farklı parametre değiştirilebilir. Bu değişiklikler sonucunda, kullanılan veri seti için en uygun katman sayısı, bu katmanlardaki parametreler ve fonksiyonlar için optimum değerler belirlenir. Kullanılan veri setindeki görüntülerin çoğaltılması veya sınıflandırma yönteminde farklı parametreleri test ederek en iyisinin belirlenerek birçok farklı yapıyı optimize etmeye odaklanan çalışmalar bulunmaktadır. Bu çalışmada belirlenen yaprak veri setinde sabit bir arka plana sahip yaprak görüntülerinde değişiklikler yapılırken, evrişimli sinir ağı ile yaprak sınıflandırmasında kullanılan model sabit tutulmuştur. 3 farklı görüntü boyutu için kullanılan resimlerin, gri resim veya renkli resim farkı ve arka plan renginin neden olduğu değişikliklerin incelenmesi amaçlanmaktadır.

Anahtar Kelimeler-- Segmentasyon, Derin Öğrenme, DerinconvNets, Görüntü İşleme

Abstract--In academic studies, there are many factors that change depending on the changes in the parameters of the process, such as the processing time, the required processing power, as well as the success. In the methods used for classification, recognition, and detection, the changes in the data received as input may affect the result, as well as the variables specific to the methods used. Convolutional neural networks, whose use is increasing day by day in processes such as classification and recognition using images, learn and classify the characteristics of data sets in different image sizes, including color, gray or black and white images, with filters and functions on the layers in the model. Many different parameters such as layers in the created model and filters and functions in these layers can be changed. As a result of these changes, the most suitable number of layers, the optimum values for the parameters and functions in these layers are

determined for the data set used. There are studies focused on optimizing many different structures, such as reproducing the images in the used data set or determining the best by testing different parameters in the classification method. In this study, while the changes were made in the leaf images with a fixed background in the determined leaf data set, the model used in leaf classification with convolutional neural network was kept constant. It is aimed to examine the pictures used for 3 different image sizes, the gray picture or color picture difference and the changes caused by the background color.

KeyWords-- Segmentation, Deep learning, Deep convNets, Image Processing

1.GİRİŞ

Yapay zekanın günümüz teknolojisinde yükselen kullanım oranı ile birlikte alt dallarında bulunan farklı sınıflandırma algoritmalarının da yaygınlaşması kaçınılmazdır. Bu alt dallardan biri olan evrişimli sinir ağları, yüz tanıma, otonom teknolojiler, hava tahminleri gibi farklı alanlarda kullanılmaktadır. Evrişimli sinir ağları veya ConvNets, büyük görüntüleri işlemek için gereken parametre sayısını azaltarak görüntülerdeki verilerin yerelliğinden yararlanarak özel bir tür sinir ağıdır [1]. Çok katmanlı yapısıyla verileri küçülterek büyük miktarda ki verilerden özelliklerini öğrenir ve bu özelliklere göre sınıflandırma yapar.

Evrişimli sinir ağı da diğer sınıflandırma yöntemleri gibi birçok parametreden oluşmaktadır. Bu parametrelere örnek vermek gerekirse oluşturulan modelin katman sayısı, kullanılan fonksiyonlar ve bu katmanlarda ki filtre boyutları gibi parametreleri değişebilmektedir. Ayrıca girdi olarak alınan görüntüleri boyutu, gri, siyah beyaz ya da renkli resim olması da alınacak sonucu, işlem süresini ve işlem gücünü etkilemektedir.

Literatüre bakıldığında evrişimli sinir ağına yapılan sınıflandırma işlemlerini daha iyi hale getirmek için farklı alanlarda pek çok çalışma mevcuttur. Veri çoğaltma işlemi ile yapılmıştır [2]. Görüntü boyutu, filtre boyutu, filtre sayısı ve katman sayısı değişimine bakılmıştır [3]. Parçacık sürüsü optimizasyonu kullanılarak [4]. Evrişimli sinir ağının farklı boyutlara göre incelenmesi ile birlikte, giriş verisinin boyutu, konvolüsyon katmanlarının filtre sayısı değişimi, konvolüsyon filtre boyutu ve havuzlama katmanı filtre boyutunun değişimine bakılmıştır [5].

Bu çalışma da, literatür de farklı alanlarda uygulanan yöntemler evrişimli sinir ağı ile yaprak sınıflandırmayı optimize etmek için kullanılmıştır. Yapılan çalışma da 66x50, 90x75 ve 132x100 görüntü boyutları için renkli ve gri resimlerin veri setinde ki orijinal halleri yani renkli arka planlı hali ile arka planı çıkarılarak beyaz olarak değiştirilen görüntüler 3 tekrar şeklinde evrişimli sinir ağı ile sınıflandırma yapılmıştır. Yapılan eğitimler sonucu elde edilen sonuçlar ve bu sonuçlar elde edilirken geçen işlem sürelerinin ortalaması karşılaştırılarak incelenmiştir

II. EVRİŞİMLİ SİNİR AĞI

Geçmişte birkaç evrişimli sinir ağı mimarisi önerilmiştir ve bunların çoğu üç yapısal kavrama dayanmaktadır: yerel alıcı alanlar, ağırlık paylaşımı ve alt örnekleme. Bununla birlikte, bu ağlar, uygulamalarında önemli ölçüde farklılık gösterir; en önemlisi, kullanımlarını ve diğer görevlere uygulanabilirliklerini sınırlayan belirli görevler için özel olarak uyarlanmıştır [6].

Evrişimli sinir ağlarında kullanılan modellerde bulunan katmanlar, katmanların sayısı, farklı katman türlerinin farklı sıra ve sayıda bir arada kullanılması gibi çeşitli şekillerde değişikliklerle en iyi sonucu elde etmek için düzenlenirler. Bu değişikliklerin yanı sıra katmanlarda bulunan filtre boyutu, kullanılan fonksiyonlarda da değişiklikler yapılmaktadır

Modellerde bulunan konvolüsyon katmanı özellik öğrenimi gibi çok önemli bir işlevi yerine getirmektedir. Bu yapılan işlem de görüntülere uygulanan farklı boyutta ve birbirinden farklı olan filtreler uygulanarak tanıma ve sınıflandırma gibi işlemlerin yapılmasında önemli bir görev üstlenmektedir. Bu işlemler sırasında görüntülerin kenarlarında oluşan kayıpları engellemek için doldurma işlemi uygulanır. Maksimum havuzlama ve ortalama havuzlama olmak üzere 2 farklı şekilde konvolüsyon katmanlarının arasında göze çarpan bu katmanlar farklı çeşit ve farklı boyutta ki filtreleri görüntüye uygulayarak her bir bölümde ki kullanılan türe göre ortalama ya da maksimum değeri alır. Farklı sayıda konvolüsyon ve havuzlama katmanını sınıflandırma katmanına bağlayan düzleme katmanı aldığı verileri tek boyutlu bir matris şekline getirir ve sınıflandırma katmanına iletir.

Sınıflandırma katmanı, gelen tek boyutlu matriste önceki katmanlar tarafından çıkarılan yüksek seviye özellikler sinir ağı ile sınıflandırılır.

III. MODEL ve VERİ SETİ

A. Veri Seti

UCL [7] veri seti 40 tür ve 443 görüntüden oluşmaktadır. Bu yaprak görüntülerinde yapraklar dikey olarak konumlandırılarak çekilmiş olup tablet kamerası ile yapılan çekimler yüksek çözünürlüklü değildir. Çekimler için kullanılan arka plan rengi ışık kaynağı sebebiyle her resim de farklılık göstermektedir.

Çekilen yaprak görüntüleri sabit bir uzaklıktan çekilmiştir




Şekil 1. Kullanılan veri setinde arka plan çıkarma işlemi öncesi ve sonrası gösterimi

Yukarıda ki resme baktığımızda sol tarafta bulunan veri setinde ki fotoğrafların orijinal hali görülmektedir. Sağ tarafta ise arka plan çıkarma işlemi sonucu elde edilen yaprak görüntüsü bulunmaktadır.

Veri setinde her bir tür için görüntü sayısının az olması dolayısıyla hem renkli arka plana sahip görüntüler hem de arka plan çıkarma işlemi uygulanmış görüntüler için veri çoğaltma işlemi uygulanmıştır. Bu yapılan işlemler ayna efekti ve döndürme işlemidir. Döndürme işlemi resmin 30 derecelik açılarla 30 dereceden 330 dereceye kadar 11 farklı açı değerine göre döndürülmesidir. Döndürme işlemi orijinal görüntüler ve ayna efekti uygulanmış görüntülere birlikte uygulanmıştır. Oluşan bu yeni görüntüler ve orijinal görüntülerle birlikte veri setinin görüntü sayısı 10632'ye yükseltilmiştir.

B. Model

Bu çalışmada kullanılan model analiz için, evrişimli sinir ağı ile yaprak sınıflandırmasında havuzlama etkisini göstermek için farklı sayıda havuzlama kullanılmıştır. Ayrıca, bu çalışmada maksimum havuzlama ve ortalama havuzlama olmak üzere iki havuzlama yöntemi kullanılmıştır [8].




Şekil 2. Evrişimli sinir ağı ile yaprak sınıflandırma da havuzlama etkisinin sonuçları grafiği [8]

Bu sonuçlara göre 6 konvolüsyon katmanı ve 3 ortalama havuzlama katmanı olan bir model belirlenmiştir. Ortalama havuzlamanın daha iyi sonuç verdiği görülmektedir, daha başarılı olan 2 havuzlama katmanlı model yerine 3 havuzlama katmanlı modelin kullanılmasının nedeni tür sayısının fazla olmasıdır.

6 adet konvolüsyon katmanının her biri 3, 5 ve 9 filtre boyutlu olarak kullanılmıştır. Filtre boyutlarının farklılıklarının oluşturduğu etkiyi belirlemek için belirlenen 3 farklı filtre boyutu her konvolüsyon da ayrı modeller oluşturularak kullanılmıştır. Ayrıca filtre boyutundaki artış ve azalışın olduğu durumlarda ise her 2 konvolüsyon katmanından sonra filtre boyutları artırılmış ya da azaltılmıştır [9]. Yapılan çalışma sonucu elde edilen sonuçlara göre bu çalışma da konvolüsyon filtre boyutu 3 olarak belirlenmiştir.


IV. SONUÇ

Evrişimli sinir ağı ile yapılan sınıflandırma işlemlerinde modelde ki katman sayısı, bu katmanlarda ki parametreler ve fonksiyonlar sınıflandırma için ne kadar önemliyse sınıflandırılacak verinin niteliği de aynı öneme sahiptir. Bu sebeple farklı parametreler ve farklı görüntü türleri bir ara getirilerek yapılan bu çalışma da 66x50, 90x75 ve 132x100 olarak belirlenen görüntü çözünürlüğü, gri resim ve renkli resim olarak 2 farklı şekilde oluşturulmuştur. Bu şekilde oluşturulan orijinal yaprak görüntülerine ek olarak oluşturulan bu görüntülere arka plan çıkarma işlemi uygulanmış ve arka planları beyaz olarak değiştirilmiştir. Sonuç olarak 2 farklı arka plana sahip gri ve renkli resimlerden oluşan aynı veri setinin farklı halleri belirlenen model ile 3 tekrar yapılarak eğitilmiştir. 3 tekrar yapılmasının sebebi oluşan farklılıkların daha iyi belirlenebilmesi sağlanmaktadır.




Şekil 3. Farklı Arka Plan Rengine Sahip Yaprak Görüntüleri İçin 3 Farklı Boyutta Yapılan Eğitimlerin Dakika Olarak İşlem Süresi Grafiği

Yapılan çalışma da, arka plan renginin işlem süresine herhangi bir etkisi görülmemiştir.



Şekil 4. Renkli Arka Planlı Yaprak Görüntülerinin 3 Farklı Görüntü Boyutu İçin Ortalama Başarım Grafiği

Renkli arka planlı yaprak görüntülerinin görüntü boyutuna göre elde ettiği sonuçlara baktığımızda, gri resimlere oranla fazla veri olmasından dolayı başarımlar neredeyse sabit kalmıştır. Yine renkli arka planlı yaprak görüntülerinde gri resimler için daha detaylı bir araştırma yapılarak uygun boyutun belirlenmesi gerekmektedir.



Şekil 5. Beyaz Arka Planlı Yaprak Görüntülerinin 3 Farklı Görüntü Boyutu İçin Ortalama Başarım Grafiği

Renkli arka plan görüntüleri ve arka plan çıkarma sonucu beyaz arka planlı görüntülerin gri ve renkli resimler için 3 farklı boyutta yapılan evrişimli sinir ağı eğitim sonuçlarına ve bu işlemler için geçen süreye baktığımızda, görüntü boyutunun artışı ile işlem süresinin artışının olacağı beklenen bir sonuçtur. Gri resimlere oranla 3 kat daha fazla veri işlenen renkli resimler, gri resimlere göre 1.5 ila 2 kat arasında fazla işlem süresi gerektirmesine rağmen değişmektedir. Resim boyutuna göre başarımlar değerleri sadece renkli resimler incelendiğinde artarken gri resimlerde bu farklılık göstermektedir. Arka plan renginin işlem süresine etkisi olmasa da başarımlara olan etkisi grafiklerde gözlemlenmektedir.

Bu farkı gri resimlerin farklı boyutta ki eğitimleri için

incelemek gerekirse, 90x75 boyutlu resimler için çok az bir fark orta çıkarken 66x50 ve 132x100 boyutlu görüntülerde %6 ve %4 lük bir artış gözlenmektedir. Bu artışın arka plan çıkarma işlemi sonucu elde edilen görüntülerde herhangi bir bozulma olmadığı için eğitim verisinde ki dağılımın her bir eğitim öncesi değişmesine bağlı olması ile birlikte renkli görüntülerde beyaz olmayan arka plana sahip görüntülerde ki ışığa bağlı değişimler sonucu oluşan renk farklarını da tanınmasıyla açıklanabilmektedir. Bu durum renkli resimlerin beyaz arka planla, renkli arka plan kıyaslandığında daha belirgin şekilde ortaya çıktığı görülmektedir.

Yapılan eğitimlerin tümüne baktığımızda görüntü boyutunun artması ile işlem süresi artmakla birlikte başarımların da artmadığı hatta bazı durumlar da azaldığı görülmektedir. Bu sonuçlar ışığında 90x75 görüntü boyutu, işlem süresi ve başarımlarına bakarak değerlendirilmeli ve daha detaylı bir araştırma ile incelenmelidir.

Veri setinde bulunan görüntü sayısına bağlı olarak renkli resimler ile işlem yapılmasının daha iyi olacağı öngörülmektedir. Yapılan çalışmanın genişletilmesi gerektiği, farklı veri setleri kullanılarak tür sayısı, görüntü sayısı gibi parametrelere bakılarak daha geniş bir çalışma detaylı bir şekilde incelenebilir.

KAYNAKÇA

- [1] Farabet, C., Martini, B., Akselrod, P., LeCun, Y., Culurciello, E. "Hardware Accelerated Convolutional Neural Networks for Synthetic Vision," Proceedings of 2010 IEEE International Symposium on Circuits and Systems, 2010.
- [2] Mikolajczyk, A., Grochowski, M. "Data Augmentation for Improving Deep Learning in Image Classification Problem," 2018 International Interdisciplinary PhD Workshop (IIPhDW), 2018.
- [3] Sinha, T., Verma, B., Haidar, A. "Optimization of Convolutional Neural Network parameters for image classification," IEEE Symposium Series on Computational Intelligence (SSCI), 2017.
- [4] Yamasaki, T., Honma, T., Aizawa, K. "Efficient Optimization of Convolutional Neural Networks using Particle Swarm Optimization," IEEE Third International Conference on Multimedia Big Data, 2017.
- [5] Pan, S., Guan, H., Chen, Y., Yu, Y., Gonçalves, W., Junior, J., Li, J. "Land-Cover Classification of Multispectral LiDAR Data Using CNN with Optimized Hyper-Parameters," ISPRS Journal of Photogrammetry and Remote Sensing 166, pp. 241-254, 2020.
- [6] Tivive, F., Bouzerdoum, A. "An Eye Feature Detector Based On Convolutional Neural Network," Proceedings of the Eighth International Symposium on Signal Processing and Its Applications, 2005.
- [7] Silva, P., Marcal, A., Silva, R. "Evaluation of Features for Leaf Discrimination," Springer Lecture Notes in Computer Science, Vol. 7950, 197-204, 2013.
- [8] Camgözlü, Y., Kutlu, Y. "Analysis of Pooling Effect on CNN using Leaf Database," International Conference on Artificial Intelligence towards Industry 4.0 (ICAII4.0), 348-353, 2019.
- [9] Camgözlü, Y., Kutlu, Y. "Analysis of Filter Size Effect in Deep Learning," Journal of Artificial Intelligence with Application, 2020, 1, 20 – 29, 2020.