

Dikkat Modülleri ile Oluşturulmuş Derin Öğrenme Modelini Kullanarak Pamuk Hastalığının Tespiti

Mesut TOĞAÇAR*¹

¹Fırat Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, Elazığ

Geliş tarihi: 31.03.2021

Kabul tarihi: 13.09.2021

Öz

Pamuk, dünya genelinde önemli bir endüstri sektörü olup, tarıma dayalı ülkelerde ekonomik kalkınmanın en önemli faktörlerinden biridir. Ülkemiz, pamuk tarımına elverişli ülkeler arasında yer almaktadır ve genelde Akdeniz ile Güneydoğu Anadolu bölgesinde pamuk üretimi gerçekleştirilmektedir. Pamuk bitkisinden iç ve dış etmenlerden kaynaklı birçok hastalık görülebilmektedir. Araştırmacılar, pamuk hastalığının tespitini gerçekleştirmek ve verimli bir üretim elde edebilmek için son zamanlarda yapay zekâ tabanlı çalışmalara odaklanmışlardır. Bu çalışmada kullanılan veri kümesi; hastalıklı pamuk yaprağı, hastalıklı pamuk bitkisi, sağlam pamuk yaprağı ve sağlam pamuk bitki görüntülerinden oluşmaktadır. Önerilen yaklaşımda, veri büyütme tekniği ile dikkat modüllerinden oluşan derin öğrenme modeli birlikte kullanılmıştır. Çalışmanın analizlerinde, Olasılıksal Dereceli Azalma (ODA) ve Uyarlanabilir Moment Tahmini (UMT) optimizasyon yöntemleri kullanılmıştır. Sınıflandırma sürecinde elde edilen en iyi genel doğruluk başarısı %96,56 olmuştur.

Anahtar Kelimeler: Derin öğrenme, Dikkat modülleri, Pamuk hastalığı, Veri büyütme

Detection of Cotton Disease Using Deep Learning Model Created with Attention Modules

Abstract

Cotton is an important industrial sector worldwide and is one of the most important factors of economic development in countries based on agriculture. Our country is among the countries that are suitable for cotton agriculture and cotton production is generally carried out in the Mediterranean and Southeast Anatolia. Many diseases caused by internal and external factors can be seen in cotton plants. Researchers have recently focused on artificial intelligence-based studies to detect cotton disease and achieve efficient production. The dataset used in this study; it consists of diseased cotton leaf, diseased cotton plant, fresh cotton leaf and disease fresh plant images. In the proposed approach, the data augmentation technique and the deep learning model consisting of attention modules are used together. Stochastic Gradient Descent (SGD) and Adaptive Moment Estimation (ADAM) optimization methods were used in the analysis of the study. The best overall accuracy success achieved in the classification process was 96.56%.

Keywords: Deep learning, Attention modules, Cotton disease, Data augmentation

*Sorumlu yazar (Corresponding author): Mesut TOĞAÇAR, mtogacar@firat.edu.tr

1. GİRİŞ

Pamuk, tarıma dayalı tüm ülkelerinde ekonomik getirisi olan ve çeşitli sanayi kollarında işlev gören bitki türüdür. Dünya genelinde pamuk üretiminin en çok gerçekleştiği ülkeler arasında; Hindistan, Çin, ABD gelmektedir [1]. Türkiye'de pamuk üretiminde dünyada sayılı ülkeler arasında yer almaktadır. Ülkemizin Akdeniz, Ege ve Güneydoğu Anadolu bölgesinde pamuk yetiştiriciliği yoğun bir şekilde gerçekleştirilmektedir [2]. Şanlıurfa, Aydın, Hatay, Diyarbakır, Adana ve İzmir ön sıralarda yer alan şehirlerdir [3].

Pamuk bitkisinden elde edilen lifler ve yağlar sanayinin hammaddesi olarak kullanılmaktadır [4]. Ekonomik değeri yüksek olan bu bitkinin iklim şartlarına elverişli olarak yetiştirilmesi gerekir. Ülkemizde, sıcak ve sulama imkânı fazla olan bölgelerde pamuk yetiştirilmektedir [5]. Pamuk bitkisinde çevresel etmenlerden kaynaklı birçok hastalık meydana gelebilmektedir ve oluşan bu durum "pamuk hastalığı" olarak adlandırılmaktadır [6,7]. Pamuk hastalığının yaygınlaşması durumunda üretimdeki verim azalmakta ve ülke ekonomisine zarar verebilmektedir. Üreticiler tarafından pamuk hastalığının önüne geçebilmek için çeşitli önlemler alınmaktadır [8].

Araştırmacılar, ekonomik değeri yüksek olan pamuk bitkisinin verimini düşürmemek, sağlıklı bir şekilde kullanabilmek için teknolojik gelişmelere odaklanmış çalışmalar üzerinde durmaktadırlar. Son zamanlarda, pamuk hastalığının tespitinde yapay zekâ tabanlı birçok çalışma gerçekleştirilmiştir. Bunlardan bazıları incelenirse; Nikhil Shah ve arkadaşları [9], pamuk bitkisi görüntülerini kullanarak hastalıklı tür ve hastalıklı olmayan tür olmak üzere ikili bir sınıflandırma gerçekleştirmişlerdir. Onlar, görüntü verisine ön işlem adımlarını uygulamışlardır. Veri bölütleme, veri çoğaltma tekniklerini her bir görüntü için kullanmışlardır. Ardından, çok katmanlı yapay sinir ağı (YSA) modelini kullanarak sınıflandırma sürecini gerçekleştirmişlerdir. Onlar, analiz ölçümünde t-testini kullanmışlar ve elde ettikleri

ortalama bağıl hata oranı %5,1 tespit etmişlerdir. Nirmal Chowdhary ve arkadaşları [10], pamuk hastalığını tespiti için görüntü işleme ve makine öğrenme yöntemlerini kullanmışlardır. Onlar, her bir görüntü verisine ön işlem adımlarını "Uyarlanabilir histogram eşitleme (UHE)-Adaptive histogram equalization (AHE) ve k-ortalama bölütleme" uygulamışlardır.

Ardından makine öğrenme yöntemleri; destek vektör makineleri (DVM)-Support Vector Machines (SVM), en yakın komşu (EYK)-nearest neighbors (KNN) yöntemi ve YSA modeli ile sınıflandırmışlardır. En iyi sınıflandırma performansını YSA modeli ile elde etmişler ve %89 oranında bir başarı sağlamışlardır. Nimra Pechuho ve arkadaşları [11], pamuk hastalığının tespitinde derin öğrenme modelini kullanmışlardır. Onlar çalışmasında, Inception V3 modeli ile veri kümesini eğitmişler ve Softmax yöntemi ile modelin sınıflandırılmasını gerçekleştirmişlerdir. Sınıflandırma sürecinde elde ettikleri genel doğruluk başarıları %91 olarak gerçekleşmiştir. Mva Gulhane ve arkadaşları [12], pamuk hastalığının tespiti için ön işlem adımları ve makine öğrenme yöntemini kullanmışlardır. Onlar, ön işlem adımı olarak renkli görüntü bölütleme yöntemini uygulamışlardır. Sınıflandırma sürecini DVM yöntemi ile gerçekleştirmişler ve %90,5 oranında genel doğruluk başarıları elde etmişlerdir.

Bu makalenin amacı, pamuk hastalığının tespitini yapay zekâ tabanlı önerilen yaklaşımla başarılı bir şekilde gerçekleştirmektir. Bunun için görüntü kümesi ön işlem adımlarından geçirilerek dikkat modüllerinden oluşturulan evrimsel sinir ağı (ESA)-convolutional neural network (CNN) modeli eğitilmesi hedeflenmektedir. Bu çalışmada diğer bölümler ise şu şekildedir; veri kümesi ile ilgili bilgiler 2. bölümde verilmiştir. Çalışmanın analizinde kullanılan yöntem ve model hakkında bilgiler 3. bölümde verilmiştir. Deneysel analizler ve sonuçları 4. bölümde yer almıştır. 5. ve 6. bölümler, sırasıyla Tartışma ve Sonuç bölümünden oluşmuştur.

2. VERİ KÜMESİ

Veri kümesi, pamuk yaprağı ve bitki görüntülerinden oluşmaktadır ve Kaggle web sitesinde erişime sunulmuştur. Veri kümesi, dört sınıftan oluşmaktadır; hastalıklı pamuk yaprağı, hastalıklı pamuk bitkisi, sağlam pamuk yaprağı ve sağlam pamuk bitkisi. Sınıf türlerine ait örnek görüntüler Şekil 1’de gösterilmiştir. Her bir görüntü verisi JPEG dosya uzantılı olup, 24 bit derinliğindedir ve görüntülerin çözünürlüğü sabit değildir. Veri kümesi, test ve eğitim kümesi olarak iki gruba ayrılmıştır. Eğitim veri kümesinde toplam 1951 imge yer almaktadır. Test veri kümesinde toplam 349 imge yer almaktadır [13]. Toplam 2300 görüntüden oluşan veri kümesinin istatistiksel bilgileri Çizelge 1’de verilmiştir. Sınıf tabanlı istatistiksel bilgiler ise Şekil 2’de gösterilmiştir.

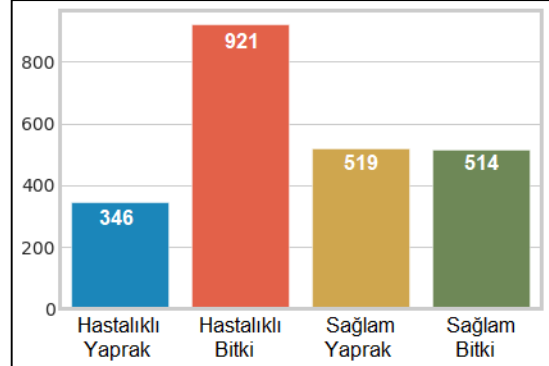


(a) (b) (c) (d)

Şekil 1. Pamuk veri kümesinin sınıf görüntüleri
a) hastalıklı yaprak, b) hastalıklı bitki,
c) sağlam yaprak, d) sağlam bitki

Çizelge 1. Eğitim ve test verilerinin istatistiksel bilgileri

Veri kümesi	Sınıf	Görüntü sayısı	Toplam
Eğitim	Hastalıklı yaprak	288	1951
	Hastalıklı bitki	815	
	Sağlam yaprak	427	
	Sağlam bitki	421	
Test	Hastalıklı yaprak	58	349
	Hastalıklı bitki	106	
	Sağlam yaprak	92	
	Sağlam bitki	93	



Şekil 2. Pamuk veri kümesinin sınıf bazlı istatistiksel bilgileri

3. TEKNİK VE YÖNTEMLER

3.1. Veri Büyütme Tekniği

Veri büyütme tekniği; görüntülerin farklı varyasyonlarını oluşturarak veri kümesindeki görüntü çeşitliliğini arttırmayı ve derin öğrenme modellerinin aşırı uyum (overfitting) probleminden kurtarmayı hedefler. Başka bir deyişle; model küçük kapasiteli veri setleri ile eğitilirken ortaya çıkan ezberleme probleminden kurtarmaya çalışır. Böylece daha genel bir modelin eğitilmesi amaçlanır. Veri büyütme tekniğinde; çevirme, kesme, kaydırma, yakınlaştırma, doldurma gibi parametreler yer almaktadır [14]. Bu çalışmada, Çizelge 2’de belirtilen parametreler kullanıldı ve yalnızca eğitim verilerine uygulandı. Veri büyütme tekniğinin kodları python yazılımında tasarlandı ve keras kütüphanesinin “Image Data Generator” fonksiyonu kullanılarak işlemler gerçekleştirildi. Çalışmanın analizinde kullanılan veri büyütme parametreleri ve değerleri Çizelge 2’de verildi.

Çizelge 2. Veri büyütme tekniğinde kullanılan parametreler ve değerleri

Parametre	Değer
Dönüş aralığı	20
Genişlik kaydırma aralığı	0,15
Yükseklik kaydırma aralığı	0,15
Kesme aralığı	0,15
Yakınlaştırma aralığı	0,15
Yatay çevirme	Doğru
Doldurma modu	En yakın

3.2. Optimizasyon Yöntemleri

Optimizasyon yöntemlerinin temel amacı, ESA mimarisinde en iyi öğrenme gerçekleşene kadar her aşamada ağırlıkları güncellemektir [15]. Bu çalışmada, Olasılıksal Dereceli Azalma (ODA)-Stochastic Gradient Descent (SGD) ve Uyarlanabilir Moment Tahmini (UMT) - Adaptive Moment Estimation (ADAM) optimizasyon yöntemleri kullanıldı. ODA yönteminde, ağırlık güncellemesi her eğitim seti için gerçekleştirildi. Bu nedenle hedefe olabildiğince erken ulaşmaya çalışıldı. ODA yönteminin formülü Eşitlik 1'de verildi. Eşitlik 1 incelendiğinde; θ değişkeni güncellenecek ağırlık vektörünü; α , öğrenme katsayısını ve $\nabla_{\theta} J(\theta)$ maliyet fonksiyonunu temsil etmektedir. Koordinat düzlemindeki özellik konumunu x ve y değişkenleri, temsil etmektedir [16].

$$\theta_t = \theta_{t-1} - \alpha \nabla_{\theta} J(\theta; x^i, y^i) \quad (1)$$

UMT yöntemi, her yinelemede öğrenme katsayısını güncelleyen yöntemlerden biridir. Bu yöntem, RMSProp yönteminin avantajları ile tasarlanmıştır. UMT yönteminin maliyetini hesaplarken Eşitlik 2 ile Eşitlik 6 arasındaki matematiksel formüller kullanılmaktadır.

Bu eşitliklerdeki değişkenler m_t ve v_t sırasıyla gradyanların tahmin edilen ilk momentini ve ikinci momentini göstermektedir. m_t ve v_t 'nin başlangıç değerleri genellikle sıfır olarak kabul edilmektedir. Birinci ve ikinci momentler, Eşitlik 4 ve Eşitlik 5'e göre; maliyet fonksiyonu ise Eşitlik 6'ya göre hesaplanmaktadır [17,18]. Bu çalışmada kullanılan diğer değerler; β_1 için 0,99, β_2 için 0,99 ve ϵ için 10^{-8} olarak tercih edilmiştir.

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (2)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (3)$$

$$m_t = \frac{m_t}{1 - \beta_1^t} \quad (4)$$

$$v_t = \frac{v_t}{1 - \beta_2^t} \quad (5)$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{v_t + \epsilon}} m_t \quad (6)$$

3.3. Önerilen Yaklaşım

Önerilen model, python yazılım dilinde tasarlandı. Mimari yapısında; evrişimsel, havuzlama, seyreltme ve yoğunluk gibi katmanları içerir [19]. Evrişimsel katman, girdi görüntüleri üzerinde filtreler (2x2, 3x3 vb.) gezindirek görüntü içerisinde verimli özelliklerin çıkartılmasını ve aktivasyon haritaların oluşmasını sağlamaktadır. Havuzlama katmanı, genelde evrişimsel katmanlardan sonra tercih edilmektedir ve aktivasyon girdilerinin boyutunu verimliliği etkilemeyecek şekilde düşürmektedir [20]. Seyreltme katmanı, girdi değerlerinde eş değer gördüğü değerleri yok sayarak, modelin sığ bir yapıda eğitilmesini önlemektedir [21]. Yoğunluk katmanı, tam bağlantılı katman gibi modelin son katmanlarında tercih edilmektedir. Bu katman bir önceki katmandan gelen tüm çıkış değerlerini tek bir düğüm noktasında toplar ve sınıflandırma sürecinde kullanılacak fonksiyona olasılık tabanlı değerlerin hazırlanmasına yardımcı olmaktadır [22]. Önerilen modelin yapısı hakkında detaylı bilgi Çizelge 3'te verildi. Modelin girdi boyutu 224x224 olarak ayarlandı. Evrişimsel katmanların filtre boyutu (3x3, 5x5, 8x8) olarak seçildi. Eğitim sürecini kolaylaştırmak, zamandan kazanç sağlamak için her bir evrişimsel katman içerisinde sızdıran ReLU kullanıldı. Maksimum havuzlama katmanlarının filtre boyutu (2x2) seçildi ve ortalama havuzlama katmanlarının filtre boyutu (3x3) seçildi. Önerilen modelin son katmanlarına doğru seyreltme katmanı kullanıldı ve bu katman için tercih edilen oranlar 0,2 ile 0,5'ti. Sınıflandırma sürecinde Softmax fonksiyonunun çıkış değeri 4 olarak ayarlandı.

Önerilen modelde kullanılan dikkat modülü girdi görüntülerinde modelin odaklanması gereken bölgeleri tespit ederek, eğitim başarımını artırmaktadır. Dikkat modülleri önerilen yaklaşımda ilgili katmandan (seyreltme katmanı) sonra blok olarak kullanıldı. Bu blok içerisinde dört adet evrişimsel katman bulunmaktadır. Girdi

özellikleri normalizasyon işleminden geçirildikten sonra evrişimsel katmanlar tarafından (1x1) filtreler dolaştırılarak aktivasyon haritalar oluşturuldu. Aktivasyon haritalarında dikkat edilecek bölgelerin özelliklerini bulabilmek için "up_c2" fonksiyonu


kullanıldı. Son aşamada ortalama havuzlama katmanı kullanılarak piksel sayısına göre yeniden ölçeklendirme yapıldı. Bu işlem "Lambda" katmanı sayesinde gerçekleşti ve dikkat bölgeleri elde edildi.

Çizelge 3. Önerilen modelin yapısı ve tercih edilmiş parametre değerleri


Katman/Fonksiyon	Giriş kanal sayısı	Adım boyutu/Değer
Evrişimsel	64	3x3
Sızdıran ReLU	-	-
Maksimum havuzlama	-	2x2
Seyreltme	-	0,5
Evrişimsel	64	5x5
Sızdıran ReLU	-	-
Maksimum havuzlama	-	2x2
Seyreltme	-	0,5
Evrişimsel	16	8x8
Sızdıran ReLU	-	-
Maksimum havuzlama	-	2x2
Seyreltme	-	0,5
Dikkat modül	1	2x2
Evrişimsel	512	5x5
Sızdıran ReLU	-	-
Ortalama havuzlama	512	3x3
Seyreltme	-	0,5
Ortalama havuzlama	512	3x3
Yoğunluk	512	-
Sızdıran ReLU	-	-
Yoğunluk	512	-
Seyreltme	-	0,2
Seyreltme	-	0,2
Yoğunluk	1024	-
Softmax	Çıkış = 4	

Bu çalışmada kullanılan dikkat modülünün örnek görüntü kümesi Şekil 3'te gösterildi. Sınıflandırma sürecinde önerilen modelin son katmanında Softmax fonksiyonu kullanıldı. Softmax aktivasyon fonksiyonu, genellikle ESA mimarilerinin son katmanında kullanılmaktadır. Amacı, doğrusal olmayan bir regresyon sürecinin sonunda bir önceki

katmanın özelliklerinin normalize edilmesini sağlamaktır. Daha sonra normalize edilmiş değerleri olasılıklara dönüşmekte ve sınıflandırma işlemini gerçekleştirmektedir [23]. Önerilen yaklaşımın tasarımı Şekil 4'te gösterildi. Önerilen yaklaşım ile pamuk hastalığının tespitini gerçekleştirmeyi amaçlanarak tasarlandı.



Şekil 3. Dikkat modülünün örnek girdi görüntüleri üzerinde uygulanması [24]



Şekil 4. Önerilen yaklaşımın genel tasarımı

4. DENEYSEL SONUÇLAR

Önerilen yaklaşım ve deneysel çalışmalar için Jupyter Notebook arayüzü kullanıldı. Yazılım kodları, Google Colab sunucusu kullanılarak derlendi. Donanımsal gereksinimler Google Sunucuları tarafından sağlandı. Deneysel analizler ve sonuçların değerlendirilmesi için karmaşıklık matrisi kullanıldı. Karmaşıklık matrisinin hesaplanmasında kullanılan metrikler; duyarlılık (Duy), özgüllük (Özg), hassasiyet (Has), f-skoru (F-skr) ve doğruluk (Dğr). Metrikler, Eşitlik 7 ile Eşitlik 11 arasındaki formüller ile hesaplanmaktadır. Bu eşitliklerde kullanılan parametreler; Doğru Pozitif (DP), Doğru Negatif (DN), Yanlış Pozitif (YP), Yanlış Negatif (YN)'dir [25,26].

$$Duy = \frac{DP}{DP+DN} \quad (7)$$

$$\text{Özg} = \frac{DN}{DN+DP} \quad (8)$$

$$Has = \frac{DP}{DP+YP} \quad (9)$$

$$F\text{-skr} = \frac{2 \times DP}{2 \times DP + YP + YN} \quad (10)$$


$$Dğr = \frac{DP+DN}{DP+DN+YP+YN} \quad (11)$$

Çalışmanın veri seti, test ve eğitim verilerinden oluşmaktadır. Minimum seri boyutu, veri kümesinin alt görüntü kümelerine ayrılacak şekilde eş zamanlı olarak grupsal olarak seri bir şekilde model tarafından eğitime sürecidir. Minimum seri boyutu, donanımsal gereksinimlere bağlıdır [27]. Bu çalışma için minimum seri boyutu 32 olarak belirlendi. Dönem sayısı, 10 tercih edildi ve kayıp fonksiyonu "kategorik çapraz entropi" seçildi. Deneysel analizler iki optimizasyon yöntemi için gerçekleştirildi. ODA optimizasyon yöntemi ile ilk deney analizi gerçekleştirildi.


ODA yöntemi ile elde edilen genel doğruluk başarısı %95,70 olarak bulundu. Birinci analiz eğitim ve test başarı grafiği Şekil 5'te gösterildi. Hastalıklı yaprak verilerinde %98,52; hastalıklı bitki verilerinde %98,23; sağlam yapraklarda %97,09 ve sağlam bitkilerde %97,37 olarak elde

edildi. Deneyin ikinci analizinde UMT yöntemi kullanılarak sınıflandırma işlemi gerçekleştirildi. Önerilen yaklaşımın UMT yöntemi ile %96,56 oranında genel doğruluk başarıları elde edildi. UMT yöntemi ile sınıf tabanlı doğruluk başarıları; hastalıklı yaprak verilerinde %98,54; hastalıklı bitki verilerinde %99,12; sağlam yapraklarda %97,97 ve sağlam bitkilerde %97,40 olarak elde edildi. Optimizasyon yöntemleri arasında UMT daha başarılı bir sonuç verdi. Ayrıca, f-skor başarıları oranında da UMT yöntemi ile gerçekleştirilen

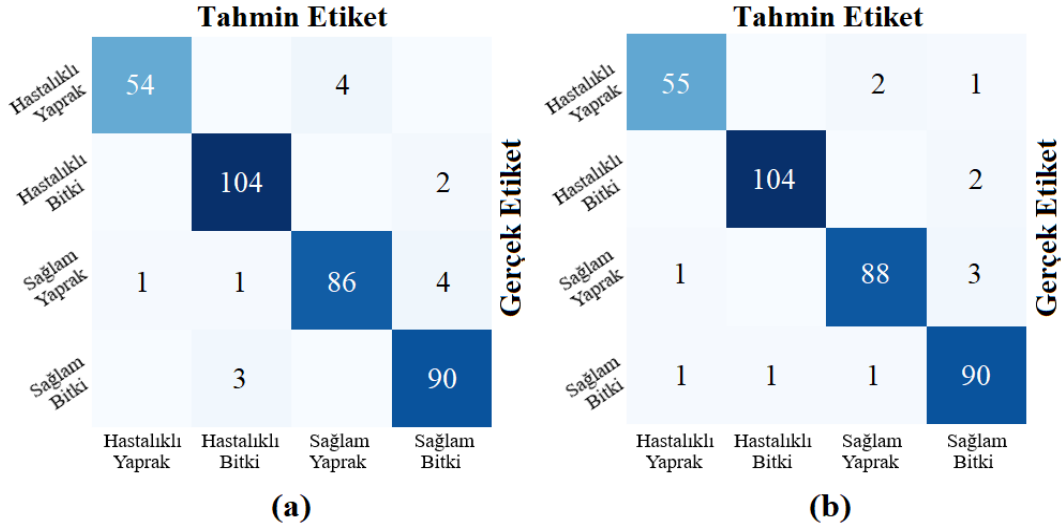
analizin diğer yöntemin analizine göre daha başarılı olduğu görüldü. İkinci analizin eğitim ve test başarıları grafiği Şekil 6'da gösterildi. Deneysel analizlerden elde edilen karmaşıklık matrisleri Şekil 7'de gösterildi. Karmaşıklık matrislerinden elde edilen metrik tabanlı performans bilgileri ise Çizelge 4'te verildi. ODA yöntemi ile UMT yönteminin analiz sonuçlarının karşılaştırılması Şekil 8'de gösterildi. Tüm sınıf türlerinde UMT yöntemi ile elde edilen doğruluk oranları daha yüksekti.




Şekil 5. Önerilen Yaklaşımın ODA optimizasyon yöntemi ile elde edilen doğruluk başarı grafiği



Şekil 6. Önerilen yaklaşımın UMT optimizasyon yöntemi ile elde edilen doğruluk başarı grafiği



Şekil 7. Deneysel analizler sonucu tercih edilen optimizasyon yöntemine göre elde edilen karmaşıklık matrisleri; a) ODA optimizasyon yöntemi, b) UMT optimizasyon yöntemi



Şekil 8. Deneysel analizlerin sınıf türlerine göre karşılaştırılması

Çizelge 4. Deneysel analizlerden elde edilen karmaşıklık matrislerinin metrik sonuçları (%)

Optimizasyon	Sınıf	F-Skr.	Duy.	Özg.	Has.	Dğr.	Genel Dğr.
ODA	Hastalıklı yaprak	95,57	93,10	99,64	98,18	98,52	95,70
	Hastalıklı bitki	97,19	98,11	98,29	96,29	98,23	
	Sağlam yaprak	94,50	93,47	98,41	95,55	97,09	
	Sağlam bitki	95,23	96,77	97,60	93,75	97,37	
UMT	Hastalıklı yaprak	95,65	94,83	99,29	96,49	98,54	96,56
	Hastalıklı bitki	98,57	98,11	99,57	99,05	99,12	
	Sağlam yaprak	96,17	95,65	98,81	96,70	97,97	
	Sağlam bitki	95,24	96,77	97,63	93,75	97,40	

5. TARTIŞMA

Tarımsal faaliyetlerde son zamanlarda yapay zekâ destekli birçok çalışma gerçekleştirilmiştir ve bu durum her geçen gün daha fazla kullanılmaktadır. Bu yönüyle yapay zekâ insanların ve dolayısıyla ülkelerin ekonomisini doğrudan etkileyen bir alan olarak öne çıkmaktadır. Ülkemizde pamuk yetiştiriciliği, ekonomik değeri olan ve birçok sanayi alanında talep gören tarımsal bir bitkidir. Dolayısıyla pamukların yetişmesini olumsuz etkileyen pamuk hastalığının erken tespiti önemlidir. Bu çalışmada, pamuk hastalığının tespiti yapılarak, bitki görüntüleri üzerinde analizler gerçekleştirildi. Önerilen yaklaşımın en önemli avantajı, dikkat modülünün görüntü verilerinde odaklanması, gereken hastalıklı bölgelerin tespit edilmesi ve modelin eğitimi için bu bölgelerin kullanılması amaçlanmıştır. Böylece önerilen model eğitilirken verimli öznelikler çıkartıldı ve modelin sınıflandırma performansına katkısı görüldü.

Önerilen yaklaşımda yöntem ve parametre tercihleri önem arz etmektedir. Nitekim, deneysel analizlerde gerçekleştirilen optimizasyon yöntemi seçiminde bile performans sonuçları arasında belirgin bir fark oluşturması, bu duruma örnektir. Önerilen yaklaşımın dezavantajlı yöntemi olarak belki de model içerisinde katmanlar ve tercih edilen parametrelerin yeniden iyileştirilmesi gerekebilir.

6. SONUÇ

Türkiye gibi birçok ülke tarıma dayalı bir ekonomiye sahiptir. Ülkemizde pamuk hem tarımsal faaliyetlerde hem de sanayi kollarında rağbet gören bir bitki türüdür. Güneydoğu, Akdeniz ve Ege bölgeleri pamuk yetiştiriciliğinde ön sıralarda yer almaktadır. Pamuk yetiştiriciliğinde pamuk bitkisinden elde edilen verim önemlidir. Bu verimliliği olumsuz etkileyen hastalık türlerinin erken tespiti ve gerekli müdahalelerin zamanında yapılması gerekmektedir. Bu çalışmada pamuk hastalığının tespitinde yapay zekâ destekli bir yaklaşım sunuldu. Önerilen yaklaşımın dikkat modüllerinden oluşması, derin öğrenme modelinin performansına katkı sağladı.

Ayrıca, doğru bir optimizasyon yönteminin tercihi model eğitime katkı sunduğu bu çalışmada görüldü. UBT optimizasyon yöntemi ile hastalıklı yaprak verilerinde %98,54; hastalıklı bitki verilerinde %99,12; sağlam yapraklarda %97,97 ve sağlam bitkilerde %97,40 doğruluk oranları elde edildi.

Gelecek çalışmada, dikkat modüllerini farklı yöntem ve yaklaşım içeren yapay zekâ destekli modeller üzerinde eğitimi gerçekleştirilecektir ve çeşitli makine öğrenme yöntemleri ile başarıları kıyaslanacaktır.

7. KAYNAKLAR

1. Chohan, S., Perveen, R., Abid, M., Tahir, M.N., Sajid, M., 2020. Cotton Diseases and Their Management BT-Cotton Production and Uses: Agronomy, Crop Protection, and Postharvest Technologies. In: Ahmad S, Hasanuzzaman M (eds). Springer Singapore, Singapore, 239–270.
2. Eski, Ö., Kayalak, S., 2018. Türkiye’de Pamuk Üretimi için Bir Öngörü Modeli: Var Yaklaşımı. ÇOMÜ Ziraat Fakültesi Dergisi, 6, 131–137. <https://doi.org/10.33202/comuagri.503960>.
3. 2019 Pamuk Bülteni, <https://www.tarimorman.gov.tr>, Erişim Tarihi: 09.08.2020.
4. Çoban, M., Çiçek, S., Küçüktaban, F., Yazıcı, L., Çiftçi, H., 2016. Bazı Pamuk Melezlerinin Verim ve Lif Kalite Özelliklerinin İncelenmesi. Tarla Bitkileri Merkezi Araştırma Enstitüsü Dergisi, 25(2), 112–112. <https://doi.org/10.21566/tarbitderg.281873>.
5. Çopur, O., 2018. GAP Projesinin Türkiye Pamuk Üretimine Etkisi: Son On Yıldaki Değişimler. Adyütayam, 6(1), 11–18.
6. Çelik, İ., Soysal, M., İnan, Ö., Çetinkaya, M., 2010. Antalya Bölgesinde Pamuk Solgunluk Hastalığı (*Verticillium dahliae*) Surveyi. Batı Akdeniz Tarımsal Araştırma Enstitüsü Derim Dergisi, 27(1), 18–32.
7. Sakçı, N., Sağır, A., Temiz, M.G., 2017. Pamukta Solgunluk Hastalığı (*Verticillium Dahliae* Kleb.)’nın Tohumun İçeriğine Etkisinin Belirlenmesi. Bitki Koruma Bülteni, 57(1),1-11. <https://doi.org/10.16955/bitkorb.299002>.

8. Ferro, H.M., Souza, R.M., Lelis, F.M.V., Silva, J.C.P., Medeiros, F.H.V.D., 2020. Bacteria for Cotton Plant Protection: Disease Control Crop Yield and Fiber Quality. *Rev Caatinga* 33(1), 43–53.
9. Shah, N., Jain, S., 2019. Detection of Disease in Cotton Leaf using Artificial Neural Network. In: 2019 Amity International Conference on Artificial Intelligence, 473–476.
10. Chowdhary, K.N., Nithin, Y.M., Srikanta, P., Rekha, B.S., 2018. A Machine Learning Approach for Detection of Cotton Leaf Disease. *Int. J. Sci. Res. Dev.*, 6(3), 1902–1905.
11. Pechuho, N., Khan, Q., Kalwar, S., 2020. Cotton Crop Disease Detection using Machine Learning via Tensorflow. *Pakistan J. Eng. Technol.*, SI(1), 126-130.
12. Gulhane, V.A., Gurjar, A.A., 2011. Detection of Diseases on Cotton Leaves and its Possible Diagnosis. *Int J Image*, 5(5), 590–598.
13. Bhoi, J., 2020. Cotton Disease Dataset. In: Kaggle. <https://www.kaggle.com/janmejybhohi/cotton-disease-dataset>. Accessed 29 Oct 2020.
14. Shorten, C., Khoshgoftaar, T.M., 2019. A Survey on Image Data Augmentation for Deep Learning. *J. Big Data*, 6(60), 1-48. <https://doi.org/10.1186/s40537-019-0197-0>
15. Sun, S., Cao, Z., Zhu, H., Zhao, J., 2020. A Survey of Optimization Methods from a Machine Learning Perspective. *IEEE Trans Cybern*, 50, 3668–3681. <https://doi.org/10.1109/tcyb.2019.2950779>
16. Kennedy, R.K.L., Khoshgoftaar, T.M., Villanustre, F., Humphrey, T., 2019. A Parallel and Distributed Stochastic Gradient Descent Implementation Using Commodity Clusters. *J. Big Data*, 6(16) 1-23. <https://doi.org/10.1186/s40537-019-0179-2>.
17. Kumar, A., Sarkar, S., Pradhan, C., 2020. Malaria Disease Detection Using CNN Technique with SGD, RMSprop and ADAM Optimizers. In: *Journal of Ambient Intelligence and Humanized Computing*, 211–230.
18. Zhong, H., Chen, Z., Qin, C., Huang, Z., Zheng, V.W., Xu, T., Chen, E., 2020. Adam Revisited: A Weighted Past Gradients Perspective. *Front Comput Sci*, 14(5), 145309. <https://doi.org/10.1007/s11704-019-8457-x>.
19. Chauhan, K., 2020. CNN-Attention: An Image Classifier with Attention Layers Visualized. In: GitHub. <https://github.com/kapilnchauhan77/CNN-Attention>. Accessed 31 Oct 2020.
20. Suárez-Paniagua, V., Segura-Bedmar, I., 2018. Evaluation of Pooling Operations in Convolutional Architectures for Drug-drug Interaction Extraction. *BMC Bioinformatics* 19, 209. <https://doi.org/10.1186/s12859-018-2195-1>.
21. Jiang, X., Lu, M., Wang, S.H., 2020. An Eight-layer Convolutional Neural Network with Stochastic Pooling, Batch Normalization and Dropout for Fingerspelling Recognition of Chinese Sign Language. *Multimed Tools Appl* 79, 15697–15715. <https://doi.org/10.1007/s11042-019-08345-y>.
22. Yang, Y., Wu, Q.M.J., Feng, X., Akilan, T., 2020. Recomputation of the Dense Layers for Performance Improvement of DCNN. *IEEE Trans Pattern Anal Mach Intell*, 42, 2912–2925. <https://doi.org/10.1109/tpami.2019.2917685>
23. Luo, Y., Wong, Y., Kankanhalli, M., Zhao, Q., 2020. Softmax: Improving Intra-class Compactness and Inter-class Separability of Features. *IEEE Trans Neural Networks Learn Syst*, 31, 685–699. <https://doi.org/10.1109/tnnls.2019.2909737>
24. Bello, I., Zoph, B., Le, Q.V., Vaswani, A., Shlens, J., 2019. Attention Augmented Convolutional Networks. *Proc IEEE Int Conf Comput Vis 2019-Octob*: 3286–3295. <https://doi.org/10.1109/ICCV.2019.00338>.
25. Gadekallu, T.R., Khare, N., Bhattacharya, S., Singh, S., Maddikunta, P.K.R., Srivastava, G., 2020. Deep Neural Networks to Predict Diabetic Retinopathy. *J Ambient Intell Humaniz Comput*. <https://doi.org/10.1007/s12652-020-01963-7>.
26. Chicco, D., Jurman, G., 2020. The Advantages of the Matthews Correlation Coefficient (MCC) Over F1 Score and Accuracy in Binary Classification Evaluation. *BMC Genomics*, 21, 6. <https://doi.org/10.1186/s12864-019-6413-7>.
27. Kandel, I., Castelli, M., 2020. The Effect of Batch Size on the Generalizability of the Convolutional Neural Networks on a Histopathology Dataset, *ICT Express*. <https://doi.org/https://doi.org/10.1016/j.ict.2020.04.010>.