

Bal Arı Hastalıklarının Sınıflandırılması için ConvMixer, VGG16 ve ResNet101 Tabanlı Topluluk Öğrenme Yaklaşımı

Mustafa ALTIN^{1*}, Hüseyin ÜZEN², İpek BALIKÇI ÇİÇEK³

¹ Matematik, Fen Edebiyat Fakültesi, Bingöl Üniversitesi, Bingöl, Türkiye

² Bilgisayar Mühendisliği, Mühendislik Fakültesi, Bingöl Üniversitesi, Bingöl, Türkiye

³ Biyoistatistik ve Tıp Bilişimi Anabilim Dalı, Tıp Fakültesi, İnönü Üniversitesi, Malatya, Türkiye

*¹ maltin@bingol.edu.tr, ² huzen@bingol.edu.tr, ³ ipek.balikci@inonu.edu.tr

(Geliş/Received: 12/07/2023;

Kabul/Accepted: 10/11/2023)

Öz: Bal arıları birçok etkenden dolayı ekosistemin en önemli bileşenlerinden biridir. Fakat son zamanlarda artan varroa paraziti, iklim değişiklikleri ve böcek istilası gibi etkenlerden dolayı bal arıları tehdit altındadır. Bundan dolayı son zamanlarda gelişmiş yapay zekâ teknikleri ile arılarının analiz edilmesi oldukça önemli bir araştırma konusu olmuştur. Bu çalışmada arı hastalıklarının sınıflandırılması için Evrişimsel sinir ağ mimarileri tabanlı bir topluluk öğrenme yaklaşımı sunulmuştur. ConvMixer, VGG16 ve ResNet101 tabanlı topluluk öğrenme yaklaşımı (CVR-TÖY) olarak adlandırılan bu model temel olarak VGG16, ResNet101 ve ConvMixer sınıflandırıcılarının tahmin skorlarının birleştirilmesine dayanmaktadır. Bu sayede farklı yaklaşım teknikleri ile geliştirilen VGG16, ResNet101 ve ConvMixer yapılarının tahmin çıktıları etkili bir şekilde birleştirilerek bal arı hastalık sınıflandırma performansı artırılmıştır. Tahmin skorları birleştirilirken iki yaklaşım denenmiştir. Birinci yaklaşımda modellerin tahmin çıktılarının en yüksek değeri alınarak sınıflandırma tahmini yapılmıştır. İkinci model ise ortalama değer alma yaklaşımıdır. Ortalama değer alma yaklaşımının ortak akıl modeli ile en iyi sonucu ürettiği görülmüştür. Deneysel çalışmalarda 6 farklı kovan probleminden etkilenen arı görüntülerini içeren BeelImage Dataset (BI) veri kümesi kullanılmıştır. Bu deneysel çalışmada önerilen modelden %98.87 F1-skoru elde edilmiştir. Ayrıca yapılan deneysel çalışmada önerilen model son teknolojik modeller ile karşılaştırılmıştır. Karşılaştırma sonucunda önerilen modelin F1-skoru %2.31 daha yüksek performans göstermiştir.

Anahtar kelimeler: Bal Arısı, ConvMixer, VGG16, ResNet101, Topluluk Öğrenme Yaklaşımı

ConvMixer, VGG16 and ResNet101 Based Ensemble Learning Approach for Classification of Honey Bee Diseases

Abstract: Honey bees are one of the most important components of the ecosystem due to many factors. However, honey bees are under threat due to factors such as varroa parasite, climate change and insect infestation, which have increased recently. Therefore, the analysis of honey bees with advanced artificial intelligence techniques has been a very important research topic recently. In this study, an ensemble learning approach based on convolutional neural network architectures is presented for the classification of bee diseases. This model, called ConvMixer, VGG16 and ResNet101-based ensemble learning approach (CVR-TOY), is basically based on the combination of predictive scores of VGG16, ResNet101 and ConvMixer classifiers. In this way, the prediction outputs of VGG16, ResNet101 and ConvMixer structures developed with different approach techniques were effectively combined to increase honey bee disease classification performance. Two approaches were tried when combining the prediction scores. In the first approach, classification prediction is made by taking the highest value of the prediction outputs of the models. The second model is the averaging approach. It has been seen that the averaging approach produces the best results with the common sense model. In experimental studies, BI dataset, which contains images of bees affected by 6 different hive problems, was used. In this experimental study, an F1-score of 98.87% was obtained from the proposed model. In addition, the proposed model in the experimental study was compared with the latest technological models. As a result of the comparison, the F1-score of the proposed model showed 2.31% higher performance.

Key words: Honey Bee, ConvMixer, VGG16, ResNet101, Ensemble Learning Approach

1. Giriş

Yaklaşık olarak 20.000 çeşit arı türü içerisinde yer alan bal arıları koloniler halinde bulunurlar ve dünyada ekolojik dengenin sağlanmasında görev yapan canlı türleri arasında yer almaktadır [1]. Arılar Dünya’da bulunan canlı türleri arasında en eskilerden birisi olduğu için, canlı türlerinin gelişiminde dolaylı yoldan da olsa çok büyük

* Sorumlu yazar: maltin@bingol.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0001-5544-5910, ² 0000-0002-0998-2130, ³ 0000-0002-3805-9214

bir etkisi vardır. Örneğin besin zincirinde en altta yer alan bitkilerin devamlılığı arıların tozlaşma yapmasıyla sağlanabilmektedir [2]. Arılar, besin zincirindeki yerinden çıktığı anda, bitki çeşitliliğinin her yıl %50 oranında azalabileceği düşünülmektedir. Bu azalma göz önüne alındığında yaklaşık dört yıl içerisinde yeryüzündeki bitkisel kaynaklardan %93.75'inin tükenebileceği ön görülmüştür [3]. Bitkilerdeki azalma ile bağlantılı olarak yağış sistemlerinde değişim ve bu durumun sonucu olarak da iklimlerde değişimler ve dolayısıyla su sorunları meydana gelecektir. Bu olumsuzluklar sonucunda çok kısa sürede yaşam döngüsü değişecek ve insanoğlunun yaşantısı sosyo-ekonomik ve kültürel yönden doğrudan etkilenecektir. Bu durumlar göz önünde bulundurulduğunda bal arılarının doğal ortamın yanı sıra toplumların üzerinde küresel bir etkisi olduğu görülmektedir. Hem doğa için hem de insanoğlu için son derece önemli bir yere sahip olan bal arılarının geleceği; çeşitli hastalıklar, iklim koşulları ve parazitlerden dolayı tehdit altındadır [4, 5].

Bal arılarının popülasyonunun azalmasına neden olan en önemli hastalıklardan biri varroa parazitidir. Varroa paraziti, bal arılarına yapışarak arının günlük yaşamını doğrudan etkiler. Özellikle arının yağ dokusu ile beslendiği için arının zayıflamasına ve arıda uzuv eksikliği gibi deformasyonlara sebep olmaktadır. Ayrıca varroa paraziti akut arı felcine sebep olan virüslerin kovana yayılmasına sebep olmaktadır. Varroa paraziti kovan içinde kolaylıkla çoğalabilmektedir. Bundan dolayı kovan varroa parazitine maruz kaldığı takdirde tedavi edilmez ise öncelikle ciddi verim kaybına ve ileriki safhalarda arı kovanlarının yok olmasına sebep olmaktadır. Diğer yandan kovan böcekleri, soyulan kovan, karınca istilası ve kayıp kraliçe gibi bazı problemler de kovan sağlığını olumsuz etkilemektedir [4, 6, 7]. Bal ve polen ile beslenen küçük kovan böcekleri, peteklere fazla zarar verebilirler [8, 9]. Soyulan kovan problemi yabancı bir arının kovan içindeki balı çalmasıdır. Bunun sonucunda bal arılarının bağışıklık sistemleri zayıflar ve kovan sağlığı olumsuz etkilenir [10, 11]. Benzer şekilde bu probleme karınca istilaları da sebep olabilmektedir. Bu karınca istilası sonucunda bal arıları, kovanlarını terk edebilmektedirler [12]. Kraliçe arının kaybolması durumunda ise işçi arıları veya arıcılar yeni bir kraliçe arı bulamayabilir bunun sonucunda da koloni çoğalamaz ve bal arıları hayatta kalamaz [13].

Yukardaki problemler karşısında arıcıların devamlı olarak kovanları takip etmesi gerekmektedir. Arıcıların varroa parazitinin tespiti için pudra şekeri veya un ile rulo testi gibi yöntemleri vardır. Bunlara ek olarak hırsız arılar veya böcek istilası gibi problemler için de kovanlar belli aralıklar ile gözlemlenmektedir. Bu yöntemler zaman alıcı olmasının yanında yöntemin başarısı ve zararsız olması arıcının deneyimine bağlıdır [4, 7]. Yapılan çalışmalarda bu yöntemlerin veriminin düşük olduğu görülmüştür. Bundan dolayı, bu yöntemler yerine günümüzde gelişen kameralar ve yapay zekâ teknikleri arıların gözetlenmesi ve böylece bal arılarının hastalıklarının erken tespit edilmesinde çok daha etkili yöntemler olabilmektedirler [4-6].

Bu çalışmada bal arılarının hastalık tespiti için VGG16 [14], ResNet101 [15] ve ConvMixer [16] sınıflandırıcılarının tahmin skorlarının birleştirilmesine dayanan yeni bir topluluk öğrenme yöntemi sunulmuştur [17, 18]. Bu yöntemin geliştirilmesindeki temel amaç, günümüzde farklı yapılar ile geliştirilmiş güçlü yöntemleri bir araya getirmektir. Özellikle sınıflandırma başarısının ana kaynağı olan güçlü öznitelikler için farklı temel yapı taşları ile oluşturulmuş yapıları bir araya getirilmiştir. Bu doğrultuda, topluluk öğrenme için öznitelik çeşitliği göz önünde bulundurularak; VGG16, ResNet101 ve ConvMixer ağ mimarileri temel alınmıştır. Kullanılan VGG16 ağ mimarisi 16 katmana sahip kısmen sığ bir ağ mimarisidir. Diğer yandan ResNet101 ağ mimarisi atlama bağlantıları ile geliştirilen ve 101 katmana sahip oldukça derin bir ağ mimarisidir. Son olarak son zamanlarda oldukça popüler olan ConvMixer ağ mimarisi görüntü parçalama tekniğini temel alan ve global öznitelik elde edebilen bir ağ mimarisidir. Bu ağ mimarilerinin çıktılarını birleştirmek için sınıflandırıcı çıktı tahminleri ortalama ve en yüksek değer alma şeklinde iki farklı yaklaşım kullanılmış ve bunlar karşılaştırılmıştır. Yapılan karşılaştırmalarda ortalama değer alma etkili bir model olmuştur.

Bu çalışmanın devamı şu şekilde organize edilmiştir: Bal arıları ile ilgili literatürde yapılan çalışmalar bölüm 2'de sunulmuştur. Bölüm 3'te önerilen modelde kullanılan metotlara yer verilmiştir. Bölüm 4'te önerilen yaklaşım verilmiştir. Son olarak bölüm 5 ve 6'da deneysel çalışmalar ve sonuçlar verilmiştir.

2. İlgili Çalışmalar

Dünyada doğal yaşam ve ekonomi için oldukça önemli bir konuma sahip olan arıcılık sektörü, son yıllarda yaşanan koloni kayıplarından dolayı bilgisayar bilimcilerinin dikkatini çekmiştir [19, 20]. Son 10 yılda arılara müdahale etmeden görüntüleme teknolojileri kullanarak arıların analiz edilmesi ve bazı arı hastalığının teşhisi için birtakım çalışmalar yapılmıştır. Bal arıların görüntüleme tabanlı analiz yöntemlerinin temel amacı kovanın iç veya dış ortamından alınan görüntülerin makine öğrenmesi veya görüntü işleme algoritmalarının yardımı ile arılar hakkında bazı çıkarımların yapılmasıdır. Bu alanda yapılan bazı bilimsel çalışmalar aşağıda özetlenmiştir;

Kimura ve ark. (2011) tarafından, bal petekleri üzerinden alınmış görüntülerden vektör niceleme metodu ile arıların bireysel tespiti ve takibi yapılmıştır. Yapılan çalışmada arıların sallanma dansını analiz ederek bal arılarının davranışları hakkında çıkarımlar yapılmıştır [6]. Ayrıca, Chen ve ark (2012), bal arılarının kovan giriş ve çıkış aktivitelerini analiz etmek için bir görüntüleme sistemi geliştirmiştir. Geliştirilen sistem kızıl ötesi kamera, kızıl ötesi aydınlatma ve geçiş yolundan oluşmaktadır. Kovan girişine konumlandırılan sistem sayesinde arıların giriş ve çıkış hareketleri kaydedilmektedir. Analizler için kovan içerisinde rastgele seçilen 100 adet arının sırt bölgesine iki karakterden oluşan bireysel bir kod ile etiketlenmiştir. Etiketlemenin temel amacı seçilen 100 adet arının günlük olarak kaç defa ve günün hangi saatlerinde kovan içerisine veya dışarıya çıktıklarını tespit etmektir. Arıların giriş veya çıkış hareketleri sırasında kameradan alınan arı görüntüleri destek vektör makinesi (SVM) sınıflandırıcı kullanılarak yapılandırılan karakterlerin tanımlaması yapılmıştır. Bu şekilde arılar birbirlerinden ayırt edilmiştir. Yapılan çalışmada karakter tanıma için SVM sınıflandırıcısı %86 - %98 oranında başarılar elde etmiştir [21]. Bu alanda yapılan başka bir çalışma ise Chiron ve ark. (2013) tarafından yapılmıştır. Bu çalışmada, farklı seviyelerde uçan bal arıların takibi için hem yoğunluk hem de derinlik görüntülerini alabilen 3 boyutlu bir kamera kullanmıştır. Arı takibi için Kalman Filtre ve Küresel En Yakın Komşu yöntemleri kullanmıştır [22]. Yapılan çalışma olumlu sonuçlar vermesine karşın yöntemin uygulanması için yüksek maliyet gerektirmektedir. Tashakkori ve ark. (2015), Sinyal Gürültü Oranı (Signal-to-Noise Ratio-SNR) yöntemi kullanmıştır. Fakat bu yöntemlerde görüntülerde bal arısının kameraya yakın veya uzakta uçmasından dolayı oluşacak boyut değişikliği yöntemlerin başarısını direk etkileyecektir [23]. Bozek ve ark. (2017) bal arılarının segmentasyonu için Evrişimsel Sinir Ağları (ESA) tabanlı U-net mimarisi önermiştir. Yapılan çalışmada veri kümesi için yüksek çözünürlüklü bir kamera yardımı ile petek üzerinde bulunan toplu bal arısı görüntüleri elde edilmiştir. Daha sonra önerilen U-net mimarisi ile arı segmentasyonu yapılmıştır. Segmentasyon sonucu elde edilen arı görüntülerinden temel bileşen yöntemi ile her bir arının rotasyonu belirlenmiştir. Yapılan çalışma yaklaşık olarak %96 oranında başarılar göstermiştir [7].

Tashakkori ve ark. (2017), kovan girişine monte edilmiş bir kamera yardımı ile bal arılarının giriş ve çıkış aktivitelerini analiz etmiştir. Yapılan çalışmada mini bilgisayar sistemleri (Raspberry Pi) kullanarak kovanların uzun süre boyunca izlenmesinin mümkün olduğunu göstermiştir. Geliştirilen sistem 9 saate kadar görüntü alabilmektedir. Alınan görüntüler toplanıp çevrimdışı olarak işlenmiştir. Yapılan çalışmada sadece görüntü alınması hakkında değerlendirmeler yapılmıştır [20]. Boenisch ve ark. (2018), 10 hafta boyunca yaklaşık 2000 arıyı etiketleyerek izlemiştir. Çalışmada kullanılan görüntüleme sistemi iki tarafı kamera ile gözetlenen bir petekten oluşmaktadır. Alınan görüntüler görüntü tanıma ve makine öğrenme yöntemleri ile tüm arıların sırt bölgesinde bulunan bireysel kodlar çözülerek arılar birbirinden ayrılmıştır. Çalışmada 10 hafta boyunca bal arılarının bireysel faaliyetleri kapsamlı bir şekilde toplanmış ve değerlendirilmiştir [24]. Magnier ve ark. (2018), kovan giriş ve çıkış aktiviteleri saymak için arka plan çıkartma, kenar bulma, eşikleme, elips uydurma gibi temel görüntü işleme algoritmaları kullanılmıştır. Test sonuçlarında ortalama olarak %75 oranında doğruluk sonucu elde edilmiştir [25]. Rodriguez ve ark. (2018), görüntüleme sistemi yardımı ile arıların yiyecek arama davranışlarını analiz etmişlerdir. Bu çalışmada kovan girişine konulmuş bir görüntüleme sistemi ile arılar düzenli olarak videolara alınmıştır. Alınan video çerçevelerindeki arılar kırpılmış daha sonra bu kırpılmış arı görüntüleri geliştirilen bir ESA mimarisi yardımı ile polen taşıma ve taşımama durumlarına göre sınıflandırılmıştır. Farklı ESA ağ mimarileri kullanılarak yapılan testlerde %92.14-%94.36 oranlarında sonuçlar bulunmuştur [26]. Kim ve ark. (2019), geliştirilen görüntüleme sistemi yardımı ile bal arılarının varroa paraziti taşıyıp taşımama durumları incelenmiştir. Kovan girişine yerleştirilen görüntüleme sistemi kovan içerisine giren her bir arının görüntüsünü almaktadır. Daha sonra alınan bu görüntülerden görüntü işleme algoritması ve derin öğrenme yöntemi ile kovandaki varroa paraziti seviyesi tespit edilmiştir. Elde edilen sonuçlar doğrultusunda varroa paraziti tespiti için geleneksel yöntemlere karşı görüntüleme sisteminin kullanılabilirliği ispatlanmıştır. Çalışmada 19 farklı nanometre(nm) alanında görüntü alabilen multispektral kamera kullanılmıştır. Yapılan analizler sonucunda varroa paraziti tespiti için en uygun 3470 (mavi), 630 (kırmızı) ve 780 (kızılötesi) nm bulunmuştur [5]. Yapılan çalışmada sınıflandırıcı için lineer diskriminant analiz yöntemi kullanılmıştır. Yang ve ark. (2021), arı hastalık tespiti için BI veri kümesini 5 farklı ESA mimarisi ile sınıflandırmış ve sınıflandırma sonuçları analiz edilmiştir [4]. Kullanılan veri kümesi 5172 tane arı görüntüsü içermektedir. Jenny tarafından yayınlanan bu veri kümesi arıların doğal ortamında çekilmiş videoların işlenerek arı görüntüleri çıkartılması ve sonrasında her bir arı görüntüsünün sağlık durumlarının uzmanlar tarafından etiketlenmesi ile oluşturulmuştur [27]. Yoo ve ark. (2023), arıların sağlık durumlarını sınıflandırmak için transformer tabanlı BeeNet ağ mimarisini önermişlerdir. Önerilen ağ mimarisi iki bölüme oluşmaktadır. Birinci bölümde ResNet50 ağ mimarisi ile derin öznitelikler elde edilmiştir. İkinci bölümde ise elde edilen derin öznitelikler Transformer modeli ile sınıflandırılmıştır. Önerilen yaklaşım hem arıları sınıflandırmada hem de arıların sağlık durumlarının sınıflandırılmasında kullanılmıştır. Bu model ile arıların sınıflandırılmasında %92.45 doğruluk ve arıların sağlık durumlarının sınıflandırılmasında

%94.50 doğruluk skoruna ulaşılmıştır [28]. Vouidiotis ve ark. (2022), arılar üzerindeki varroaları tespit etmek için MobileNet V2-Faster R-CNN modelini önermişlerdir. Önerilen modelde öncelikle görüntü işleme tabanlı bir ön işleme ile arı tespiti yapılmıştır. Daha sonra MobileNet V2-Faster R-CNN modeli ile arı üzerindeki varroalar tespit edilmiştir. Ayrıca yapılan çalışmada MobileNet V3 ve ResNet50 omurga ağ yapıları denenmiştir. Yapılan deneysel çalışmalarda performans (%77 doğruluk ve %86 kesinlik) açısından MobileNet V2 omurga ağı daha etkili sonuçlar üretmiştir. Ayrıca bu çalışmada gerçek zamanlı uygulamalar için MobileNet V2 modelinin etkili olduğu belirtilmiştir [29].

3. Materyal ve Yöntem

3.1. VGG16, ResNet 101 ve ConvMixer ağ mimarileri

Bu çalışmada arı hastalıklarını sınıflandırmak için topluluk öğrenme modeli kullanılmıştır. Topluluk modelleri için farklı karakteristik yapıya sahip olan önceden eğitilmiş VGG16 ve ResNet101 ağ mimarileri kullanılmıştır. Bu modellere ek olarak son zamanlarda oldukça popüler olan ConvMixer modeli kullanılmıştır. Bu bölümde öncelikle, daha önceden eğitilmiş modeller genel olarak ele alınmıştır. Daha sonra, son zamanlarda oldukça popüler olan ConvMixer ağ mimarisi detaylandırılmıştır.

3.1.1. Önceden eğitilmiş VGG16 ve ResNet 101 ağ mimarileri

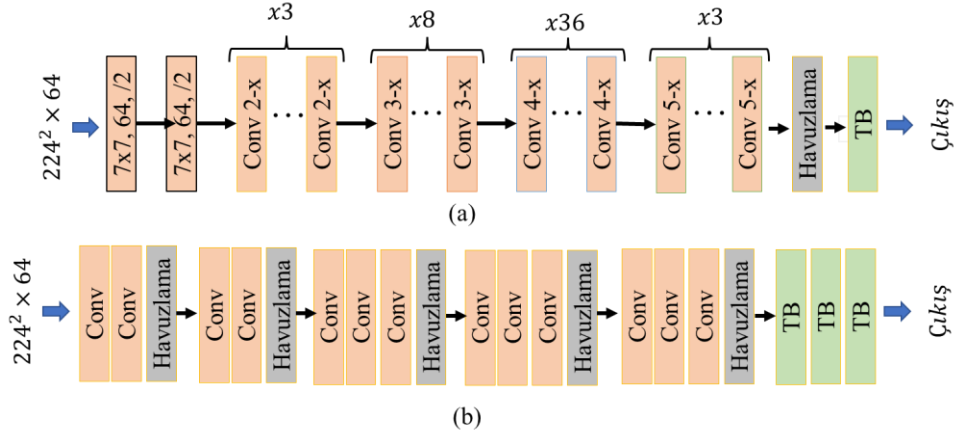
Gelişmiş GPU sistemlerinin yaygınlaşması ile birçok farklı ESA mimarisi önerilmiştir. VGG16 mimarisi bu mimarilerinin öncüsüdür. Birçok çalışmada uygulanan VGG16 mimarisi etkileyici performanslar göstermiştir. Arka arkaya gelen 16 evrişim katmanından oluşan VGG16 mimarisinden daha derin öznetelikler elde etmek için 19 katmandan oluşan VGG19 ağı geliştirilmiştir. Bu sayede daha derin anlamsal öznetelikler elde edilmesiyle başarı artırılmaya çalışılmıştır. Fakat derin öğrenmede katman sayısı arttıkça kaybolan gradyan problemi oluşmaya başlamaktadır [15, 30].

ESA mimarileri eğitiminde geri yayılım modelini kullanmaktadır. Geriye yayılım fonksiyonu Denklem 1'de verilmiştir.

$$w_1 = w_1 - \alpha \frac{\partial J(W)}{\partial w_1} \quad 0 < \alpha < 1 \quad (1)$$

$$\frac{\partial J}{\partial w_1} = \frac{\partial J}{\partial e} \frac{\partial e}{\partial w_{n-1}} \dots \frac{\partial w_2}{\partial w_1} \quad (\text{Zincir Kuralı})$$

Burada J amaç fonksiyonu ve e hatayı göstermektedir. w_1 parametresinin güncellenmesi için $\frac{\partial J}{\partial w_1}$ türevinin hesaplanması gerekmektedir. $\frac{\partial J}{\partial w_1}$ hesaplamak için zincir kuralı uygulanmıştır. $\frac{\partial e}{\partial w_{n-1}} \dots$ zincir kuralında geçerli olan ara katmanlarının türevini temsil etmiştir. α değeri adım genişliğini göstermektedir ve genellikle küçük bir değer seçilmektedir. Bu sayede ağı parametreleri küçük bir miktar değiştirilerek güncellenmektedir [31]. Burada temel olarak beklenen çıktı ile tahmin çıktısı arasındaki hata değeri elde edilir. Daha sonra bu hatanın gradyanı kullanılarak optimum ağırlıklara gidecek yön bulunmaya çalışılır. Son olarak evrişim katmanlarına geri yayılarak yön bilgisi ile evrişim katmanları güncellenir. Fakat ardışık katmanlarda ve kısmi türevden dolayı arka arkaya gelen çarpma işlemi ileriki katmanlarda gradyan bilgisi sıfıra çok yaklaşıyor. Bu durum kaybolan gradyan olarak tanımlanmıştır. Bu problem ile başa çıkmak için bazı araştırmacılar atlama bağlantılarını önermiştir [14, 15, 32]. Atlama bağlantıları geri yayılımda ara bağlantılar sağlayarak önceki katmanlarının eğitilmesine olanak tanımaktadır. Ayrıca atlama bağlantıları ile ilk katmandaki öznetelikler sonraki katmanlara taşınarak etkili bir yapı sunmaktadır. Bu model ile geliştirilen ResNet50 ve ResNet101 mimarilerinin birçok çalışmada üstünlüğü kanıtlanmıştır. Şekil 1'de VGG16 ve ResNet 101 ağ mimarisinin katman detayları verilmiştir.



Şekil 1. ResNet101 (a) ve VGG16 (b) ağ mimarilerinin genel gösterimi

3.1.2. ConvMixer ağ mimarisi

Vision Transformer (ViT) modeli derin öğrenmede yeni bir dönem açmıştır [33, 34]. Fakat ViT modelinin öz dikkat mekanizması ikinci dereceden karmaşıklığa sahiptir. Bundan dolayı ViT modeli yüksek seviyede veri ve donanım gereksinimine ihtiyaç duymaktadır [34, 35]. Bu problemlerden yola çıkan Trockman vd. ViT modelinin performans kaynağının araştırması ile ConvMixer modelini geliştirmiştir [16].

ConvMixer modelinde MLP mixer ve ViT modelinde olduğu gibi giriş görüntüsü yamalara bölünmektedir. Daha sonra yamaları temsil eden çıktıya bir dizi evrişim işlemleri uygulanmaktadır. Bununla birlikte ConvMixer modelini parçalama işlemi için geleneksel bir evrişim katmanı kullanılmaktadır. Fakat burada çekirdek ve atlama değeri parça boyutu (patch size (p)) olarak ayarlanmıştır. Bu işlemler Denklem 2’de gösterilmiştir.

$$z_0 = \text{BN} \left(\sigma \left(\text{Conv}_{\text{kernal:p}}^{\text{stride:p}} (\text{image}) \right) \right) \quad (2)$$

Burada verilen z_0 ve p sırası ile görüntü yamalara bölme çıktısı ve yama boyutunu temsil eder. Denklem 2’de gösterildiği gibi parçalama işleminde evrişim işleminden sonra sırası ile GELU (σ) ve Batch normalizasyon (BN) katmanı uygulanmıştır. Ayrıca Evrişim işleminde filtre sayısı h olarak alınmıştır. Denklem 2 işleminin sonucunda $W \times H$ boyutundaki giriş görüntüsü $\frac{W}{p} \times \frac{H}{p} \times h$ boyutunda bir çıktı elde edilmektedir. Bu çıktıdaki her bir vektör dizisi ($1 \times 1 \times h$), bir yamayı temsil etmektedir. ConvMixer modelinin ikinci aşamasında z_0 çıktısı bir derinlemesine ayarlanabilir evrişim bloğuna aktarılmıştır. Bu evrişim bloğu Denklem 3’de gösterilmiştir.

$$z'_1 = \text{BN} \left(\sigma \left(\text{DepthWiseConv}(z_{1-1}) \right) \right) + z_{1-1} \quad (3)$$

$$z_1 = \text{BN} \left(\sigma \left(\text{PointWiseConv}(z'_1) \right) \right)$$

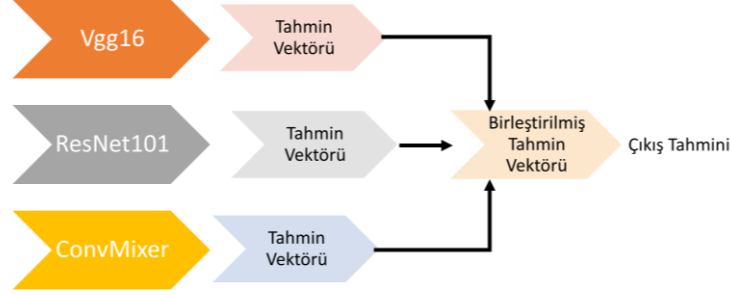
Denklem 3’de gösterildiği gibi derinlemesine ayarlanabilir evrişim bloğu iki aşamada gerçekleşir. Bunlar sırası ile derinlemesine evrişim ve noktasal evrişimdir. Her evrişim işleminden sonra sırası ile GELU (σ) ve Batch normalizasyon (BN) işlemi uygulanmıştır. Ayrıca Denklem 3’de görüldüğü gibi ConvMixer modelinde Residual atlama bağlantıları mevcuttur. Bu sayede öznelik haritaları arasında bilgi aktarımları sağlanmaktadır.

3.2. Önerilen topluluk öğrenme yaklaşımı

Bu çalışmada arıların hastalık durumlarının sınıflandırılması için ConvMixer, VGG16 ve ResNet101 tabanlı Topluluk Öğrenme Yaklaşımı (CVR-TÖY) önerilmiştir. Önerilen modelde Bölüm 3.1’de verilen VGG16 ve ResNet101 ve ConvMixer ağ mimarileri kullanılmıştır. VGG16 modeli 16 katmana sahip sığ bir ağ mimarisidir. Bundan dolayı sınıflandırıcı skoru elde etmede mekânsal ayrıntılar ön plana çıkmaktadır. ResNet101 modeli ise 101 katmana sahip derin bir ağ mimarisidir. Bu ağ mimarisi atlama bağlantıları sayesinde oldukça etkili bir yapı sergilemektedir. Ayrıca derin katmanları sayesinde güçlü anlamsal öznelikler elde etmektedir. Son olarak

ConvMixer modeli geleneksel evrişim ağlarının aksine görüntü parçalama modeli kullanır. Bu sayede görüntüdeki farklı noktalar arasındaki ilişkiyi elde eden güçlü öznitelikler elde etmektedir. VGG16 ve ResNet101 ve ConvMixer ağ modelinin farklı yaklaşımlarından dolayı önerilen modelde bu modeller kullanılmıştır.

Önerilen topluluk öğrenme yaklaşımında VGG16 ve ResNet101 ve ConvMixer ağ modelleri bağımsız olarak eğitilmektedir. Daha sonra eğitilmiş bu modeller topluluk öğrenme yaklaşımı modeli kullanılarak ortak bir sınıflandırma skoru elde etmek için sonuçlar birleştirilir. Bu yaklaşım Şekil 2’de gösterilmiştir.



Şekil 2. Önerilen ConvMixer, VGG16 ve ResNet101 tabanlı Topluluk Öğrenme Yaklaşımı

Birleştirme işlemi için iki yaklaşım kullanılmıştır. Birinci yaklaşımda modellerin tahmin çıktıları arasında en yüksek puana sahip çıktı temel alınarak tahmin çıktısı olarak ele alınır. Bu modelin formalizasyonu Denklem 4’de verilmiştir.

$$P_{\max_çıkış} = \text{argmax}(\text{concat} \left(\begin{pmatrix} P1 \\ P2 \\ P3 \end{pmatrix} \right)) \quad (4)$$

Denklem 4’de verilen P1, P2 ve P3 sırası ile ConvMixer, ResNet101 ve VGG16 ağ mimarilerinin tahmin çıktı vektörleridir. Bu vektörler 6 boyutludur. Vektördeki her değer sırası ile sağlıklı, varroa paraziti ve karınca istilası gibi sınıflarının tahmin çıktısıdır. Denklem 4’de öncelikle 3 vektör birleştirme katmanı (concat()) ile birleştirilir. Birleştirme işleminin sonucunda 3x6 boyutlu bir matris elde edilir. Daha sonra bu matristeki en yüksek oylamaya sahip değer (argmax()) temel alınarak sınıflandırma çıktısı ($p_{\max_çıkış}$) elde edilir.

En yüksek değeri alma metodunda sınıflandırıcılar rekabet halindedir. Diğer bir deyişle sınıflandırıcılar arasında ortak bir bağ aramaz ve en iyi tahmin skoruna erişen kazanır. Fakat bu en iyi tahminin doğru olup olmadığı belli değildir. Bundan dolayı sınıflandırıcılar arasında rekabet yerine ortak akıl yaklaşımı (Averaging) daha iyi performans sergileyebilir. Çünkü iki sınıflandırıcının kısmen düşük skorlar ile tahmin ettiği doğru sınıfı diğerinin yüksek skorla ile tahmin ettiği yanlış sınıfı oylama modeli ile engelleyebilir. Bu metotta öncelikle sınıflandırıcıların sonuçlarının ortalaması alınır. Daha sonra ortalama alınmış çıktılar temel alınarak sınıf çıktısı elde edilir. Ortalama temelli topluluk yaklaşımının formalizasyonu Denklem 5’de verilmiştir.

$$P_{\text{ortalama}}(i) = \frac{1}{N} \sum_j^N P_{i,j} \quad (5)$$

$$p_{\text{ort_çıkış}} = \text{argmax}(P_{\text{ortalama}})$$

Denklem 5’de gösterilen j sınıflandırıcılarının tahmin çıktısında elde edilen 6 boyutlu vektörlerin indeksidir. i değeri ise bu vektörlerde dolaşım sağlayan indekstir. Denklem 5’de verilen P_{ortalama} tahmin çıktıların ortalaması değerlerini temsil eden vektördür. Bu vektör 6 boyutludur. Denklem 4’ün ikinci kısmında ortalama değerleri temsil eden bu vektördeki en yüksek puana (argmax) göre sınıflandırma çıktısı ($p_{\text{ort_çıkış}}$) elde edilir.

Önerilen yaklaşımda kullanılan VGG16 ve ResNet101 mimarileri (tam bağlı katmanlar hariç) orijinal yapılarındaki gibi kullanılmıştır. Sadece arı hastalıklarının sınıflandırılması için katmanlarına ortalama havuzlama katmanı ve tam bağlı katman eklenmiştir. Bu tam bağlı katman 6 nöronludur. Diğer yandan kullanılan ConvMixer ağ mimarisinde parça boyutu 4, derinlik 8 olarak ayarlanmıştır. Ayrıca sınıflandırma çıktısı için ağ mimarisinin son katmanlarına ortalama havuzlama katmanı ve tam bağlı katman eklenmiştir.

Her bir sınıflandırıcı çıktısında, sınıfların olasılık dağılımını gösteren 3 boyutlu bir vektör elde edilmektedir. Bu nedenle, bu çıktı için Kategorik Çapraz Entropi kayıp fonksiyonu kullanılmıştır. Sınıflandırma ağı için kullanılan Kategorik Çapraz Entropi kayıp fonksiyonu Denklem 6'da gösterilmiştir.

$$L_{cls} = - \sum_k^M Y_k \log(P_k) \quad (6)$$

Denklem 6'da L_{cls} sınıflandırma ağının kayıp değerini, Y ve P sırasıyla 6-boyutlu beklenen ve tahmin vektörlerini ifade eder. M sınıf sayısını ve k sınıfların indeksini temsil eder.

4. Deneysel Çalışmalar

Bu bölümde önerilen ConvMixer, VGG16 ve ResNet101 tabanlı CVR-TÖY detaylı deneysel çalışmalar ile analiz edilmiştir. Analizler i7 intel işlemci, 32 GB ram ve RTX3080 ti ekran kartı donanıma sahip bir bilgisayarda gerçekleştirilmiştir. Ayrıca deneysel çalışmalarda tüm modeller için öğrenme oranı, adım sayısı ve batch boyutu sırası ile 0.0001, 50 ve 16'dır. Deneysel çalışmaların sonuçları; doğruluk, F1-skor, kesinlik ve duyarlılık metrikleri kullanılarak verilmiştir. Değerlendirme sonuçları F1-skor ve doğruluk sonuçları temel alınmıştır.

4.1. Veri kümeleri

Bu çalışmada deneysel çalışmalar için BI veri seti kullanılmıştır [36]. Bu veri kümesi varroa paraziti, karınca istilası, kayıp kraliçe, soyulan kovan, böcek istilası gibi problemleri içeren arı görüntülerinden oluşmaktadır. BI veri kümesi toplamda 5172 görüntü ve 6 sınıftan oluşmaktadır. Bu sınıflar sırası ile varroa istilası, karınca istilası, kayıp kraliçe, soyulan kovan, böcek istilası ve sağlıklı arı şeklindedir. Veri setinden alınan örnek görüntüler, Şekil 3'te verilmiştir. Deneysel çalışmalarda eğitim için veri kümesinin %80'i rastgele olarak alınmış geri kalanı ise test için kullanılmıştır.



Şekil 3. BI veri kümesinden örnek görüntüler. (a) Sağlıklı, (b) Karınca istilası, (c) soyguncu arı, (d) Kayıp kraliçe, (e) böcek istilası, (f) Varroa paraziti.


4.2. Önerilen modelin diğer son teknolojik modeller ile karşılaştırılması

Bu deneysel çalışmada önerilen model son teknolojik modeller ile karşılaştırılmıştır. Bu karşılaştırmalarda VGG16, MobileNet, InceptionV3, ResNet101, ResNet50 ve EfficientNet, Swin Transformer, ConvMixer modelleri kullanılmıştır [37-39]. Bu karşılaştırma sonuçları Tablo 1'de verilmiştir.


Tablo 1'de görüleceği üzere en yüksek doğruluk ve F1-skorları CVR-TÖY yöntemi kullanılarak elde edilmiştir. Buna ek olarak önerilen modelin yapısında kullanılan VGG16 ve ResNet101 modelleri ile ikinci en yüksek skorlar elde edilmiştir. Diğer yandan ConvMixer modeli ise %96.98 doğruluk skoruna ulaşmıştır. Her ne kadar ConvMixer modeli InceptionV3 ve MobileNet modelinden düşük sonuçlar üretmiş olsa da 3 modelin birlikte kullanılması etkili bir yapı oluşturmuştur. Tablo 1'de sonuçları VGG16, ResNet101, ConvMixer modellerin ve önerilen CVR-TÖY modelin karışıklık matrisi Şekil 4'de verilmiştir.

Tablo 1. CVR-TÖY modelinin son teknolojik modeller ile karşılaştırılması


Model	Doğruluk	F1-skor	Kesinlik	Duyarlılık
VGG16	98.73	96.56	95.93	97.42
MobileNet	97.66	91.54	93.45	90.26
InceptionV3	97.37	92.62	95.46	90.93
ResNet101	98.63	96.44	95.31	97.81
ResNet50	98.63	94.95	94.92	94.98
EfficientNet	64.78	13.38	16.41	16.66
Swin Transformer	90.46	85.51	87.67	84.52
ConvMixer	96.98	94.97	94.87	95.12
CVR-TÖY	99.31	98.87	98.83	98.92




CVR-TÖY



ResNet 101



VGG16



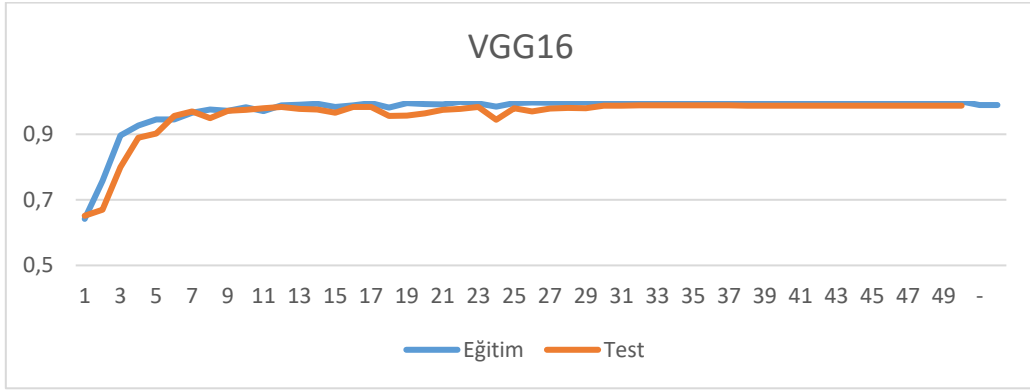
ConvMixer

Şekil 4. CVR-TÖY, ResNet101, VGG16 ve ConvMixer modellerin Karışıklık Matrisleri

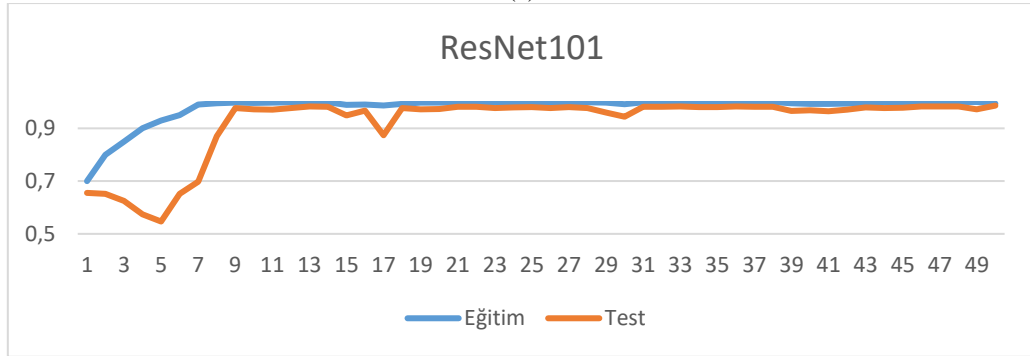
Şekil 4'de gösterildiği gibi CVR-TÖY modeli tüm sınıflarda, örneklerin %94'ünden fazlasını doğru tahmin etmiş bunun yanında sınıf 1, sınıf 3, sınıf 4 ve sınıf 6 sınıflardaki örneklerinin tamamını doğru sınıflandırmıştır. Diğer modeller arasında ConvMixer modeli ile sınıf 5'teki örneklerin %85.71'ini doğru sınıflandırılmışken VGG16 modeli ile sınıf 4'teki örneklerin %85.71'ini doğru sınıflandırılmıştır. Diğer yandan ResNet101 modeli ile VGG16 ve ConvMixer modellerine göre sınıf 1'de düşük skorlar elde edilmişken sınıf 4'de daha iyi skorlar elde edilmiştir. Modellerin farklı sınıflardaki farklı başarıları önerilen CVR-TÖY modelinde birleştirilerek daha yüksek skorlar sağlanmıştır.

4.3. Ablasyon çalışmaları


Önerilen CVR-TÖY modelinde topluluk öğrenme için VGG16, ResNet101 ve ConvMixer ağ mimarileri kullanılmıştır. Topluluk öğrenme için ağ mimari seçiminde öznelik çeşitliliği temel alınmıştır. Bundan dolayı VGG16, ResNet101 ve ConvMixer ağ mimarileri kullanılmıştır. Bu ağ mimarileri sırası ile sığ ağ mimarisi (VGG16), oldukça derin ağ mimarisi (ResNet101) ve global anlamsal öznelik elde edebilen ağ mimarisi (ConvMixer) olarak gruplandırılabilir. Çünkü en temel ağ yapılarından biri olan VGG16 ağ mimarisi 16 katmana sahip kısmen sığ bir ağ mimarisidir. Diğer yandan atlama bağlantıları ile geliştirilen ve 101 katmana sahip ResNet101 ağ mimarisi oldukça derin bir ağ mimarisidir. Son olarak ConvMixer ağ mimarisi görüntü parçalama tekniğini temel alan ve global öznelik elde edebilen son teknolojik bir ağ mimarisidir.



(a)



(b)



(c)

Şekil 5. Deneysel çalışmalarda en uygun adım sayısı belirlemek için 50 adım boyunca eğitim ve test veri kümesinden alınan doğruluk sonuçları

Önerilen VGG16, ResNet101 ve ConvMixer ağ mimarileri kendi içinde sırası ile %98.73, %98.63 ve %96.98 doğruluk skoru elde etmiştir. Bu ağ mimarilerinin birleşimi ile önerilen topluluk öğrenme yaklaşımı %99.31 doğruluk skoru elde etmiştir. Ağ mimarilerinin eğitiminde aşırı öğrenme olup olmadığını analiz etmek ve en uygun adım sayısını belirlemek için 50 adım boyunca VGG16, ResNet101 ve ConvMixer ağ mimarilerinin eğitim ve test sonuçları kaydedilmiştir. Bu sonuçlar Şekil 5’te verilmiştir. Burada görüleceği üzere VGG16, ResNet101 ve ConvMixer ağ mimarilerinde ortalama ilk 10 adımda ağ mimarilerinin eğitimi tamamlanmıştır. Bundan sonraki adımlarda ise elde edilen başarı genel olarak korunmuştur. Bu sonuçlar modellerde aşırı öğrenme olmadığını göstermektedir. Ayrıca Ağ mimarilerinin eğitimi için adım sayısının 50 seçilmesi yeterli olmuştur.

Önerilen CVR-TÖY modelinde VGG16, ResNet101 ve ConvMixer sınıflandırıcı modellerinin topluluk öğrenme yaklaşımı ile birleştirilmiştir. Buna ek birleştirme işlemi ortalama değer alma ve en büyük değeri seçme yaklaşımları denenmiştir. Bu yaklaşımların sonuçları Tablo 2’de verilmiştir. Burada verilen Model 1 sınıflandırma tahmin çıktısını sınıflandırıcının çıktılarındaki vektörlerin en yüksek tahmin puanına göre seçmektedir. Model 2 ise sınıflandırıcı çıktılarının ortalama değerleri alınarak sınıflandırma çıktısını tahmin etmektedir.

Tablo 2. Ortalama değer alma ve En yüksek değer alma modellerinin karşılaştırılması

Model	Topluluk öğrenme Stratejisi	Doğruluk	F1-skor	Kesinlik	Duyarlılık
Model 1	Ortalama değer alma	99.31	98.87	98.83	98.92
Model 2	En yüksek değer alma	98.73	97.89	97.71	98.17

Tablo 2’deki sonuçlar kıyaslandığında Model 1 ile %99.31 doğruluk ve %98.87 F1-skor elde edilmiştir. Buna kıyasla en yüksek değerini alarak çıktı tahmini elde eden model yaklaşık %0.45 doğruluk ve %1 F1-skor ile daha düşük performans üretmiştir. Bu sonuçlar gösteriyor ki sınıflandırma çıktılarının ortalama değerinin alınması daha yüksek performans sağlamaktadır.

Önerilen model 3 farklı ESA mimarisinin birleşiminden oluşmaktadır. Bu sınıflandırıcı sayısı 2 adet seçilme durumundaki skorları görmek için Tablo 3’teki deneysel çalışma yapılmıştır. Burada VGG16, ResNet101 ve ConvMixer mimarilerinin ikili kombinasyonu alınarak sonuçlar kaydedilmiştir.

Tablo 3. VGG16, ResNet101 ve ConvMixer modellerinin ikili kombinasyonları

Model	Doğruluk	F1-skor	Kesinlik	Duyarlılık
CVR-TÖY	99.31	98.87	98.83	98.92
ConvMixer-ResNet101	98.73	97.89	97.71	98.17
ConvMixer-VGG16	98.54	97.67	97.96	97.40
ResNet101-VGG16	99.02	97.07	96.27	98.07

Tablo 3’teki sonuçlarda görüldüğü üzere ikili kombinasyonlarda en yüksek F1-skor (%97.89) ConvMixer-ResNet101 modelleri ile elde edilmiştir. Buna kıyasla önerilen CVR-TÖY modelinden %0.98 daha yüksek F1-skoru elde edilmiştir.

Önerilen CVR-TÖY modeli Tablo 1 ve 3’teki sonuçlara bakıldığında VGG16, ResNet101 ve ConvMixer modelleri bir arada kullanarak çok etkileyici sonuçlar üretmiştir. Fakat bu modelde, farklı derin ağları bir arada kullanması zamansal açıdan zayıf kalmasına sebep olmaktadır. Çünkü önerilen model her ağ mimarisinden sonuç üretmesi beklendikten sonra bu sonuçları birleştirmektedir. Bu durumda önerilen model zaman açısından bireysel sonuçlara göre geride kalmaktadır. Bu durumu analiz etmek için önerilen modeller ayrı ayrı denenmiş ve zaman tüketimleri Tablo 4’te verilmiştir.

Tablo 4. CVR-TÖY, VGG16, ResNet101 ve ConvMixer modellerinin bir saniyedeki işleyebildiği görüntü sayısı (FPS, Frames Per Second)

Model	Doğruluk	FPS	Test için Harcanan Toplam Süre
CVR-TÖY	99.31	26.53	38.75
VGG16	98.73	234.55	4.38
ResNet101	98.63	39.48	26.04
ConvMixer	96.98	123.39	8.33

Tablo 4'te görüleceği üzere önerilen CVR-TÖY modeli her ne kadar %99.31 doğruluk skoruna ulaştığı görülse de zaman tüketimi açısından bir saniyede işleyebileceği görüntü sayısı 26.53'tür. Bu skor diğer modellerin en düşük FPS'sidir. Fakat arıların sağlık durumları bağımsız serverlarda işlenebildiğinden bu hız yeterli olarak görülebilir. Diğer yandan en yüksek FPS skoru VGG16 modeli ile elde edilmiştir. Gerçek zamanlı uygulamalar ve oldukça yüksek FPS'ye ihtiyaç duyulduğu durumlarda VGG16 ağ mimarisi kullanılabilir.

4.4 Önerilen modelin literatürdeki yöntemler ile karşılaştırılması

Bu bölümde önerilen CVR-TÖY model literatürdeki modeller ile karşılaştırılmıştır. Karşılaştırmalarda ele alınan yöntemler ve yöntemlerin sonuçları Tablo 5'te verilmiştir.

Tablo 5. Önerilen CVR-TÖY modelin literatürdeki yöntemler ile karşılaştırılması

Metod	Yöntem	Veri Kümesi	Doğruluk	F1-skor
GoogLeNet-DVM [4]	ESA, Transfer Öğrenme, Derin Öznitelikler ve DVM Sınıflandırıcı	BI	98.20	97.28
KM [40]	ESA ve Derin Öznitelikler	BI	92.42	-
Deeplabv3-Resnet [40]	ESA, Transfer Öğrenme ve Görüntü Parçalama	Kişisel Varroa Veri Kümesi	-	95.0
BeeNet [28]	ESA, Derin Öznitelikler ve Transformer	Kişisel Varroa Veri Kümesi	94.50	-
US+CSC [41]	ESA ve Sınıftaki Örnek Sayısı Dengeleme	BI	93.46	90.00 (macro)
CVR-TÖY	ESA, Transfer Öğrenme ve Topluluk Öğrenme	BI	99.31	98.87

Tablo 5'te görüleceği üzere bal arılarının sağlık durumları sınıflandırmak için genellikle ESA mimarileri kullanılmıştır. Bunun yanı sıra GoogLeNet-DVM modeli GoogLeNet mimarisinden derin öznitelikler çıkartılmış ve DVM sınıflandırıcısı ile birleştirmiştir. Bu sayede %98.20 doğruluk skoruna ulaşılmıştır. GoogLeNet-DVM modelinin geliştirildiği çalışmada derin özniteliklerin önemi vurgulanmıştır [4]. Diğer yandan bu çalışmada önerilen CVR-TÖY modelinde ise daha güçlü ve çeşitli öznitelikler ile bal arılarının sağlık durumu sınıflandırmak için VGG16, ResNet101 ve ConvMixer ağ mimarileri birlikte kullanılmıştır. Bu sayede önerilen model ile 99.31 doğruluk skoru elde edilmiştir. Tablo 5'te verilen Deeplabv3-ResNet modeli arı görüntüsünde varroa olup olmadığını analiz etmek için görüntüleri parçalayarak varroa durumunu sınıflandırmıştır [28, 40]. Bu modelde ResNet101 ağ mimarisi kullanılmıştır. Bu model 95.0 F1-skora ulaşmıştır. BeeNet modeli iki aşamalı bir derin ağ mimarisidir. Önerilen modelde öncelikle ResNet50 ağ mimarisi ile derin öznitelikler elde edilmiştir. Daha sonra bu öznitelikler Trasformer modeli ile global öznitelikler çıkartılmıştır. Önerilen model %94.50 doğruluk skoruna ulaşmıştır. Her ne kadar elde edilen başarı oldukça etkili olsa da Transformer yaklaşımı oldukça maliyetlidir. Bunun yerine son zamanlarda gelişen ConvMixer çok daha ekonomik bir yaklaşımdır. Bu doğrultuda önerilen CVR-TÖY modeli global anlamsal öznitelikler çıkartmak için ConvMixer ağ mimarisi kullanmıştır. Sonuç olarak önerilen model Tablo 5'teki diğer modeller karşılaştırıldığında ConvMixer, ResNet101 ve VGG16 ağ mimarilerini bir arada kullanarak daha yüksek başarı sağlamıştır.

5. Sonuç

Bal arıları birçok etkenden dolayı ekosistemin en önemli bileşenlerinden biridir. Ekosistem için çok önemli bir konuma sahip olduğu için bal arılarının yaşam ortamlarının denetlenmesi ve bal arılarına ait hastalıkların tespit edilmesi önemli bir alan olmuştur. Varroa parazitleri, karıncalar, iklim değişiklikleri gibi bazı problemlerden dolayı arı kovanlarının verimsizleşmesi, arı kayıplarının artması ve bazı arı kolonilerinin yok olmasına sebep olmaktadır. Bu problemler karşısında geleneksel yöntemler zaman alıcı ve verimsiz olabilmektedir. Bundan dolayı son zamanlarda gelişmiş yapay zekâ teknikleri ile arıların analiz edilmesi oldukça önemli bir araştırma konusu olmuştur.

Bu çalışma ile arı hastalıklarının ESA mimarileri ile sınıflandırılması için topluluk öğrenme tabanlı bir yaklaşım sunulmuştur. Bu model temel olarak VGG16, ResNet101 ve ConvMixer sınıflandırıcılarının tahmin skorlarının birleştirilmesine dayanmaktadır. Birleşim işlemi sınıflandırıcı çıktı tahminleri ortalama alınarak topluluk öğrenme modelinin çıktı tahmini elde edilmiştir. Bu sayede farklı yaklaşım teknikleri ile geliştirilen VGG16, ResNet101 ve ConvMixer yapılarının tahmin çıktıları etkili bir şekilde birleştirilerek bal arı hastalık tahmini performansı artırılmıştır. Ayrıca bu deneysel çalışmada BI veri kümesi kullanılmış olup önerilen CVR-TÖY modelinin bileşenleri ayrıntılı olarak analiz edilmiştir. Bu deneysel çalışmada önerilen model son teknolojik modeller ve literatürdeki yöntemler ile karşılaştırılmıştır. Karşılaştırma sonucunda önerilen model %99.31 doğruluk ve %98.87 F1-skoru ile daha yüksek performans elde etmiştir.

Gelecekteki çalışmada bu çalışmada etkinliği kanıtlamış olan ConvMixer, VGG16 ve ResNet101 modellerini öznetelik katmanlarını birleştirmeye yönelik çalışmalar yapılacaktır.

Kaynaklar

- [1] Muz MN, Özdemir N, Dilek M. Küresel arı sağlığı ve veteriner hekimlik. Veteriner Farmakoloji ve Toksikoloji Derneği Bülteni 2019; 10: 24-30.
- [2] Öztekin C, Çapa Aydın Y, Yılmaz Tüzün Ö. Biyoloji öğretmen adaylarının genel biyoloji konularındaki kavram yanlışları, Hacettepe Üniversitesi Eğitim Fakültesi Dergisi 2000; 140-147.
- [3] Huckle J., "British Bee Journal," ed: British Bee Publications, London, England, 1882.
- [4] Berkaya SK, Gunal ES, Gunal S. Deep learning-based classification models for beehive monitoring. Ecol Inf 2021; 64: 101353.
- [5] Bjerger K, Frigaard CE, Mikkelsen PH, Nielsen TH, Misbik M, Kryger P. A computer vision system to monitor the infestation level of Varroa destructor in a honeybee colony. Comput Electron Agric 2019; 164: 104898.
- [6] Kimura T, Ohashi M, Okada R, Ikeno H. A new approach for the simultaneous tracking of multiple honeybees for analysis of hive behavior Apidologie 2011; 42: 607-617.
- [7] Bozek K, Hebert L, Mikheyev AS, and Stephens GJ. Towards dense object tracking in a 2D honeybee hive. in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition 2018; 4185-4193.
- [8] Ellis JD. "Small hive beetle (Aethina tumida) contributions to colony losses," in Honey Bee Colony Health, ed: CRC Press, 2011; pp. 135-144.
- [9] Ellis J, Hepburn H. An ecological digest of the small hive beetle (Aethina tumida), a symbiont in honey bee colonies (Apis mellifera). Insectes sociaux 2006; 53: 8-19.
- [10] Metlek S, Kayaalp K. Detection of bee diseases with a hybrid deep learning method. Journal of the Faculty of Engineering and Architecture of Gazi University 2021; 36: 1715-1731.
- [11] Calvo J. "Causes and Effects of Losing a Queen Bee," ed, 2020.
- [12] Payne AN, Shepherd TF, Rangel J. The detection of honey bee (Apis mellifera)-associated viruses in ants. Sci Rep 2020; 10: 2923.
- [13] Yılmaz O, Ertürk YE. "Honey bee biology in Turkey," in VII International Scientific Agriculture Symposium, "Agrosym 2016", 6-9 October 2016, Jahorina, Bosnia and Herzegovina. Proceedings 2016; 2413-2418.
- [14] Simonyan K, Zisserman A. "Very deep convolutional networks for large-scale image recognition," arXiv preprint arXiv:1409.1556, 2014.
- [15] Franceschini S, Ambrosiano M, Vitale S, Basile F, Gifuni A, Grassini G, et al., "Hand gesture recognition via radar sensors and convolutional neural networks," in 2020 IEEE Radar Conference (RadarConf20) 2020; 1-5.
- [16] Trockman A, Kolter JZ. "Patches are all you need?," arXiv preprint arXiv:2201.09792, 2022.
- [17] Mohammed A, Kora R. "A comprehensive review on ensemble deep learning: Opportunities and challenges," Journal of King Saud University-Computer and Information Sciences 2023.
- [18] Matloob F, Ghazal TM, Taleb N, Aftab S, Ahmad M, Khan MA, et al., "Software defect prediction using ensemble learning: A systematic literature review," IEEE Access 2021; 9: 98754-98771.
- [19] Chazette L, Becker M, Szczerbicka H. "Basic algorithms for bee hive monitoring and laser-based mite control," in 2016 IEEE symposium series on computational intelligence (SSCI) 2016; 1-8.

- [20] Tashakkori R, Hernandez NP, Ghadiri A, Ratzloff AP, Crawford MB. "A honeybee hive monitoring system: From surveillance cameras to Raspberry Pis," in SoutheastCon 2017; 1-7.
- [21] Chen C, Yang EC, Jiang JA, Lin TT. "An imaging system for monitoring the in-and-out activity of honey bees," *Comput Electron Agric* 2012; 89: 100-109.
- [22] Chiron G, Gomez-Krämer P, Ménard M. "Detecting and tracking honeybees in 3D at the beehive entrance using stereo vision," *EURASIP Journal on Image and Video Processing* 2013; 2013: 1-17.
- [23] Tashakkori R, Ghadiri A. "Image processing for honey bee hive health monitoring," in SoutheastCon 2015, 2015; 1-7.
- [24] Boenisch F, Rosemann B, Wild B, Dormagen D, Wario F, Landgraf T. "Tracking all members of a honey bee colony over their lifetime using learned models of correspondence," *Frontiers in Robotics and AI*, 2018; 5: 35.
- [25] Magnier B, Ekszterowicz G, Laurent J, Rival M, Pfister F. "Bee hive traffic monitoring by tracking bee flight paths," in 13th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications, January 27-29, 2018, in Funchal, Madeira, Portugal, 2018; 563-571.
- [26] Rodriguez IF, Megret R, Acuna E, Agosto-Rivera JL, Giray T. "Recognition of pollen-bearing bees from video using convolutional neural network," in 2018 IEEE winter conference on applications of computer vision (WACV) 2018; 314-322.
- [27] Yang J. "The beeimage dataset: Annotated honey bee images," Accessed: Aug 2018; 13: 2019.
- [28] Yoo J, Siddiqua R, Liu X, Ahmed KA, Hossain MZ. "BeeNet: An End-To-End Deep Network For Bee Surveillance," *Procedia Comput Sci* 2023; 222: 415-424.
- [29] Voudiotis G, Moraiti A, Kontogiannis S, "Deep Learning Beehive Monitoring System for Early Detection of the Varroa Mite," *Signals* 2022; 3: 506-523.
- [30] Nasser M, Yusof UK. "Deep Learning Based Methods for Breast Cancer Diagnosis: A Systematic Review and Future Direction," *Diagnostics* 2023; 13: 161.
- [31] He K, Zhang X, Ren S, Sun J. "Deep residual learning for image recognition," in Proceedings of the IEEE conference on computer vision and pattern recognition, 2016; 770-778.
- [32] Rezaei Z. "A review on image-based approaches for breast cancer detection, segmentation, and classification," *Expert Syst Appl* 2021; 182: 115204.
- [33] Zhuang X, Liu F, Hou J, Hao J, Cai X. "Transformer-based interactive multi-modal attention network for video sentiment detection," *Neural Process Lett* 2022; 54: 1943-1960.
- [34] Üzen H, Türkoğlu M, Yanikoglu B, Hanbay D. "Swin-MFINet: Swin transformer based multi-feature integration network for detection of pixel-level surface defects," *Expert Syst Appl* 2022; 209: 118269.
- [35] Cao H, Wang Y, Chen J, Jiang D, Zhang X, Tian Q, et al. "Swin-unet: Unet-like pure transformer for medical image segmentation," in European conference on computer vision, 2022; 205-218.
- [36] Yang J, "The BeeImage Dataset: Annotated Honey Bee Images | Kaggle." [Online]. Available: <https://www.kaggle.com/jenny18/honey-bee-annotated-images>. [Accessed: 12-Mar-2023].
- [37] Tiryaki VM. "Mass segmentation and classification from film mammograms using cascaded deep transfer learning," *Biomed Signal Process Control* 2023; 84: 104819.
- [38] Nikzad-Khasmakhia N, Balafara M, Feizi-Derakhshia MR, Motamedb C. "BERTERS: Multimodal Representation Learning for Expert Recommendation System with Transformer," *arXiv preprint arXiv:2007.07229*, 2020.
- [39] Abdou MA. "Literature review: Efficient deep neural networks techniques for medical image analysis," *Neural Comput Appl* 2022; 34: 5791-5812.
- [40] Üzen H, Yeroğlu C, Hanbay D. "Development of CNN architecture for Honey Bees disease condition," in 2019 International Artificial Intelligence and Data Processing Symposium (IDAP), 2019; 1-5.
- [41] Rasp N, Rahm E, Lange L. "A Study on the Impact of Class Imbalance on CNNs for Bee Health Detection," 2022.