



**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİ TEKNOLOJİLERİ ANABİLİM DALI**

**TRANSFER ÖĞRENME MODELLERİNİN
BASAMAKLANDIRILMIŞ DERİN ÖZELLİKLERİNİ VE
TOPLULUK SINIFLANDIRICILARI KULLANARAK
LASTİK ÇATLAKLARININ TESPİT EDİLMESİ**

YÜKSEK LİSANS

Özcan ASKAR

**Ocak-2024
BATMAN**

**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİ TEKNOLOJİLERİ ANABİLİM DALI**

**TRANSFER ÖĞRENME MODELLERİNİN
BASAMAKLANDIRILMIŞ DERİN ÖZELLİKLERİNİ VE
TOPLULUK SINIFLANDIRICILARI KULLANARAK LASTİK
ÇATLAKLARININ TESPİT EDİLMESİ**

YÜKSEK LİSANS

Özcan ASKAR

**Danışman
Doç.Dr. Ramazan TEKİN**

**Ocak-2024
BATMAN**

TEZ KABUL VE ONAYI

Özcan ASKAR tarafından hazırlanan “Transfer Öğrenme Modellerinin Basamaklandırılmış Derin Özelliklerini ve Topluluk Sınıflandırıcıları Kullanarak Lastik Çatlaklarının Tespit Edilmesi” adlı tez çalışması 24/01/2024 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Batman Üniversitesi Fen Bilimleri Enstitüsü Bilgi Teknolojileri Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Dr.Öğr.Üyesi Mahmut KAYA

.....

Danışman

Doç.Dr. Ramazan TEKİN

.....

Üye

Doç.Dr. Yılmaz KAYA

.....

Yukarıdaki sonucu onaylarım.

Dr. Öğr. Üyesi Ömer Murat ÖTER
Enstitü Müdürü V.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Özcan ASKAR

Tarih:

ÖZET**YÜKSEK LİSANS TEZİ****TRANSFER ÖĞRENME MODELLERİNİN BASAMAKLANDIRILMIŞ DERİN
ÖZELLİKLERİNİ VE TOPLULUK SINIFLANDIRICILARI KULLANARAK
LASTİK ÇATLAKLARININ TESPİT EDİLMESİ****Özcan ASKAR****Batman Üniversitesi Lisansüstü Eğitim Enstitüsü
Bilgi Teknolojileri Anabilim Dalı****Danışman: Doç.Dr. Ramazan TEKİN****2024, 45 Sayfa****Juri****Doç.Dr. Ramazan TEKİN****Doç.Dr. Yılmaz KAYA****Dr.Öğr.Üyesi Mahmut KAYA**

Bu çalışma, araç sürücülerinin lastiklerinde oluşan çatlakları tespit etmeye yönelik yapay zeka destekli bir yıpranmış lastik tespit sistem önermektedir. Genel olarak, sürücüler lastik diş derinliği ve hava basıncının önemini bilse de lastik oksidasyonundan kaynaklanan risklerin farkında değildir. Oysa lastik oksidasyonu ve çatlaklar, sürüş güvenliğini etkileyen önemli sorunlara yol açabilir. Bu çalışmada, ön-eğitilmiş transfer öğrenme yöntemleri kullanılarak elde edilen derin öznelikler ve topluluk öğrenme yöntemleri kullanılarak lastiklerde çatlak tespitine yönelik CTLDF+EnC isimli yeni bir hibrit mimari önerilmektedir. Önerilen hibrit modeller, özneliklerin elde edildiği dokuz transfer öğrenme yöntemi ve sınıflandırıcı olarak İstifleme, Yumuşak ve Katı oylama topluluk öğrenme yöntemlerini içermektedir. Çalışma literatürdeki endüstriye kullanıma yönelik X-Ray görüntü tabanlı yapılmış çoğu çalışmanın aksine herhangi bir sayısal görüntüleme cihazı ile elde edilebilecek görüntüler ile çalışmaktadır. Çalışma kapsamında en yüksek test doğruluk değeri 76,92% ile CTLDF+EnC (İstifleme) hibrit model ile elde edilmiştir. CTLDF+EnC (Yumuşak) ve CTLDF+EnC (Katı) mimarileri için ise doğruluk değerleri sırasıyla 74,15% ve 72,92% olarak elde edilmiştir. Çalışmanın sonuçları, önerilen hibrit modellerin lastik problemlerini tespit etme konusunda etkili olduğunu göstermiştir. Ayrıca düşük maliyetli ve uygulanabilir bir yapı sunulmaktadır.

Anahtar Kelimeler: Derin Öznelikler, Lastik Çatlakları, Topluluk Öğrenme, Transfer Öğrenme

ABSTRACT**MS THESIS****DETECTİNG TİRE CRACKS USİNG CASCADİNG DEEP FEATURES OF
TRANSFER LEARNING MODELS AND ENSEMBLE CLASSIFIERS****Özcan ASKAR****THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
BATMAN UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN INFORMATION TECHNOLOGY****Advisor: Assoc.Prof.Dr. Ramazan TEKİN****2024, 45 Pages****Jury****Assoc.Prof.Dr. Ramazan TEKİN****Assoc.Prof.Dr. Yılmaz KAYA****Assist.Prof. Dr. Mahmut KAYA**

This study proposes an artificial intelligence-supported worn tire detection system to detect cracks in vehicle drivers' tires. In general, drivers are aware of the significance of tire tread depth and air pressure, but are not aware of the risks associated with tire oxidation. However, tire oxidation and cracks can lead to significant problems affecting driving safety. In this study, a new hybrid architecture called CTLDF+EnC is proposed for crack detection in tires using deep features obtained using pre-trained transfer learning methods and ensemble learning methods. The proposed hybrid models include nine transfer learning methods to extract features and Stacking, Soft and Hard voting ensemble learning methods as classifiers. Unlike most studies in the literature based on X-Ray images for industrial use, the study works with images that can be obtained with any digital imaging device. Within the scope of the study, the highest test accuracy value of 76.92% was obtained with the CTLDF+EnC (Stacking) hybrid model. For CTLDF+EnC (Soft) and CTLDF+EnC (Hard) architectures, accuracy values were obtained as 74.15% and 72.92%, respectively. The results of the study show that the proposed hybrid models are effective in detecting tire problems. In addition, a low-cost and feasible structure is presented.

Keywords: Deep Features, Ensemble Learning, Tire Cracks, Transfer Learning

ÖNSÖZ

"İnsan, çevresini güzelleştirmekle sorumludur" düşüncesiyle, lastik sektöründe yürüttüğüm çalışmalar ve bilgi teknolojileri alanında tamamladığım yüksek lisans eğitimi, beni harekete geçirmeye yönlendirdi. Tez danışmanım Doç.Dr. Ramazan TEKİN'in rehberliğinde, aldığım eğitimden keyif alarak ve iş birliği içinde, bu tez çalışmasını hazırlama fırsatını buldum. Kendisine, katkıları, ilgisi ve tüm destekleri için içtenlikle teşekkür ederim. Son olarak aileme, eşime ve çocuklarıma bu çalışmanın ortaya çıkmasında bana göstermiş oldukları sabır ve manevi desteklerinden ötürü ayrıca teşekkür ederim.

Özcan ASKAR
BATMAN-2024



İÇİNDEKİLER

ÖZET	iv
İÇİNDEKİLER	vii
1. GİRİŞ.....	1
2. LİTERATÜR BİLGİSİ	3
3. MATERYAL VE YÖNTEM.....	6
3.1. Sistemin Genel Yapısı.....	6
3.2. Veri Seti	7
3.3. Derin Öznetelik ve Topluluk Sınıflandırma Temelli Hibrit Sistem	8
3.4. Ön-Eğitilmiş Transfer Öğrenme Modelleri	10
3.4.1. Xception TÖ Modeli	11
3.4.2. NaSNet TÖ Modeli	12
3.4.3. MobileNet TÖ Modeli.....	13
3.4.4. DenseNet TÖ Modeli	15
3.4.5. VGG TÖ Modeli	16
3.4.6. Inception TÖ Modeli.....	16
3.4.7. ResNet TÖ Modeli	19
3.5. Ekstra Ağaç Sınıflandırıcı (EAS) ile Öznetelik Seçimi	20
3.6. Topluluk Sınıflandırma Yöntemleri	21
3.6.1. Oylama Esaslı Topluluk Sınıflandırıcılar.....	21
3.6.2. İstifleme Esaslı Topluluk Sınıflandırıcı	22
3.7. Performans Değerlendirme Metrikleri	22
4. ARAŞTIRMA BULGULARI.....	24
5. TARTIŞMA	28
6. SONUÇ	31
KAYNAKLAR	32
ÖZGEÇMİŞ.....	Hata! Yer işareti tanımlanmamış.

SİMGELER VE KISALTMALAR

BTS: Basamaklandırma ve Topluluk Sınıflandırma
CNN: Evrişimsel Sinir Ağı
CTLDF: Kaskad Derin Öznitelikler
DÖÜ: Derin Öznitelik Üretici
EAS: Ekstra Ağaç Sınıflandırıcı
ELM: Extreme Learning Machine
EnC: Topluluk Sınıflandırıcı
FN: False Negatif
FCN: Tamamen Evrişimli Sinir Ağı
FP: False Pozitif
İÖS: İndirgenmiş Öznitelik Seti
KA: Karar Ağaçları
Knn: k En Yakın Komşu
MÖ: Makine Öğrenmesi
NAS: Nöral Mimari Arama
NB: Naive Bayes
RO: Rastgele Orman
RNN: Tekrarlayan Sinir Ağı
SVM: Destek Vektör Makinesi
TN: True Negatif
TP: True Pozitif
TÖ: Transfer Öğrenme
TÖM: Topluluk Öğrenme Modeli

1. GİRİŞ

Lastik problemleri, yüksek hızlarda seyahat ederken ciddi riskleri olan ve tespiti kolay olmayan bir sorundur. Lastik, bir aracın en önemli güvenlik unsurlarından biridir. Lastik üzerindeki basit kusurlar bile aracın güvenli bir şekilde sürüşünü etkileyebilir ve kazalara neden olabilir. Dolayısıyla, lastik kalitesi aracın güvenli ve sorunsuz bir şekilde hareket etmesini sağlamak adına kritik öneme sahiptir. Ayrıca, lastik yaşlanması, oksidasyon ve çatlama pek dikkat edilmeyen problemler konusunda sürücüler genellikle riskleri göz ardı eder ve düzenli kontroller yapmazlar (Lin, 2023).

Lastiklerin üretimi sırasında çeşitli nedenlerle lastik bileşeni kirlenebilmektedir (Guo et al., 2016). Bu tür kusurlu lastikler yüksek hızlarda lastiğin patlamasına ve hayati risklere sebep olabilirler. İnsan denetimi ile gerçekleştirilen geleneksel yöntemler verimli olmayıp bunun yerine bilgisayarla görü destekli sistemler lastik kalitesinin iyileştirilmesi ve verimlilik açısından kritik bir öneme sahiptirler (Kumar, 2008; Ngan et al., 2011). Bu amaçla geliştirilen sistemlerde doğrudan lastik görüntülerinin kullanıldığı geleneksel görsel tespit yöntemleri (Guo et al., 2016; Zhao & Qin, 2018) olduğu gibi, gelişmiş derin öğrenme teknikleri (R. Wang et al., 2019; Zheng et al., 2020) de olabilir.

Lastikler sürüş sırasında yerle temas eden aracın en önemli parçalarından biri olup lastik yüzeyindeki çatlaklar sürücü güvenliğini olumsuz bir şekilde etkileyebilir. Dolayısıyla lastik problemleri özellikle yüksek hızlarda sürücüler için hayati riskler barındırmaktadır. Bununla birlikte çoğu sürücü, lastik basıncını ya da lastik dış derinliğinin olası risklerinin farkında olsa da aksine lastik ömrüne bağlı ortaya çıkan oksidasyon ve çatlama gibi problemlerin ve risklerin farkında değildirler. Bu noktada, manuel kontroller güvenli olmayıp dijital görüntüler kullanılan, bilgisayar ve yapay zekâ destekli çeşitli platformlara uyumlu uygulamalar oldukça faydalı araçlar olabilmektedirler. Bu tür uygulamalarda kullanılan görüntüler, insan gözünün görme işlevlerini taklit eden bilgisayarlı görü teknolojileri kullanılarak analiz edilir ve işlenirler. Kullanılan analiz yöntemleri istatistiksel, frekans düzlemi ya da model tabanlı yöntemler olabilir (Lin, 2023).

Derin öğrenme yöntemleri, öznetelik çıkarabilme yetenekleri sayesinde başta bilgisayarlı görü olmak üzere sinyal analizi ve doğal dil işleme gibi birçok farklı alanda başarılı bir araç olarak kullanılmaktadır (J. Huang & Kingsbury, 2013; Kaya et al., 2022; Liu et al., 2022; Özaydın & Tekin, 2023; Purwins et al., 2019; Rim et al., 2020; Tung &

Tekin, 2022; D. Wang et al., 2020; S.-H. Wang et al., 2019; Yang et al., 2021). Ancak derin öğrenme yöntemlerinde çoğunlukla büyük veri miktarlarına ihtiyaç duyulmakta ve buna bağlı olarak eğitim süreci zaman almaktadır. Bu noktada ön-eğitilmiş Transfer Öğrenme (TÖ) yöntemleri bu problemin aşılmasında başarılı araçlardır. Bu çalışmada da kullanılması planlanan Xception (Chollet, 2017), VGG16 (Simonyan & Zisserman, 2014), NASNet (Zoph et al., 2018), ResNet50 (He et al., 2016), DenseNet (G. Huang et al., 2017), InceptionV3 (Szegedy et al., 2016) ve MobileNet (Howard et al., 2017) TÖ yöntemleri gibi birçok gelişmiş derin ağılar literatürde yer almaktadır.

Bu tez çalışmasında, lastik yüzeyinde oluşan çatlakları tespit ederek lastik görüntülerden normal ve çatlamış lastiklerin tespit edilmesi için hibrit bir model önerilmektedir. Önerilen model Özaydın ve Tekin tarafında önerilen DeepFeat-E (Özaydın & Tekin, 2023) isimli hibrit modelin modifiye edilmiş halidir. Çalışmada önerilen hibrit modelde ön-eğitilmiş TÖ modellerden elde edilen derin öznetelikler basamaklandırılarak istifleme (Wolpert, 1992) ve oylama (Zhou, 2012) topluluk sınıflandırıcılara uygulanmıştır. Önerilen derin ağlara dayalı hibrit yapay zekâ yaklaşımı, araç lastiklerinde oksidasyona bağlı oluşan problemlerin manuel kontrol kaynaklı değerlendirme sonucu oluşacak olası hatalı değerlendirmelerinin aksine daha kararlı ve doğru tespitler elde edilmesini sağlayabilir. Dolayısıyla yanlış değerlendirmelerden kaynaklı büyük ya da küçük olası birçok riski azaltabilir. Manuel değerlendirmeler bireysel tecrübe ve deneyimlerden etkilenebileceğinden farklı lastik türlerinde ve şartlarda kararlı sonuçlar elde edilememesine neden olacaktır. Aksine derin öğrenme tabanlı sayısal bilgisayar destekli yöntemlerle daha kararlı ve tutarlı sonuç elde edilebilir. Bunun yanında önerilen sistem, lastik problemlerini otomatik olarak belirleyerek araç sahiplerinin zamandan kazanmalarını sağlayabilir ve sürücü ihmallerinden kaynaklı riskleri de minimize edebilir. Bu sayede önerilen hibrit yaklaşım, lastiklerdeki problemleri önceden tespit ederek sürücüler için tehlike oluşturmadan önce önlenmesi ve gerekli tedbirlerin alınmasını sağlayabilir. Önerilen sistemin bireysel araç kullanıcılarından ziyade çok sayıda aracı olan filo, lojistik şirketler ve toplu taşıma hizmeti sağlayan özel şirketler ya da kamu kurumları göz önüne alındığında ciddi bir insan gücü ve zaman tasarrufu sağlayacağı ve ticari potansiyeli olduğu düşünülmektedir.

2. LİTERATÜR BİLGİSİ

Hatalı lastik tespit yöntemleri, kusur tespit algoritmasının türüne bağlı olarak geleneksel görsel tespit yöntemleri ve derin öğrenmeye dayalı yöntemler olarak iki ana kategoriye ayrılabilir. Geleneksel görsel tespit teknikleri, istatistiksel, frekans ve model tabanlı yöntemler olarak gruplandırılabilir.

Literatürde üretim sırasında lastik kusurlarının tespitine yönelik X-Ray görüntülere dayalı yöntemler olduğu görülmektedir. Zhao ve Qin (Zhao & Qin, 2018) yaptıkları çalışmada, üretim bandında iç yapısal lastik hatalarının tespiti için tahribatsız X-Ray ile elde edilen lastik doku görüntülerini kullanmışlardır. Bu görüntülerin özniteliklerini yerel ters fark momenti (local inverse difference moment, LIDM) yöntemle elde etmişlerdir. LIDM özniteliklerini kullanarak Hausdorff mesafesi hesaplanarak kusur özellik haritası (DFM) elde edilmiş ve bu harita üzerinden yüksek hassasiyetle piksel düzeyinde etkili bir kusur tespit algoritması önermişlerdir. Benzer şekilde Guo ve arkadaşları (Guo et al., 2016) tarafından yapılan çalışmada, kaliteli lastik üretimine yönelik üretim sırasında oluşabilen lastik yüzeyindeki anormallikleri tespit etmek için lastik X-Ray görüntülerinin öznitelik benzerliğinden yararlanan etkili bir kusur tespit yöntemi önermişlerdir. Önerilen yöntemde, piksellerin özellik farklılığını değerlendirmek için yerel çekirdek regresyon (LKR, local kernel regression) tanımlayıcısı yardımıyla lastik görüntülerinin öznitelik vektörleri elde edilmektedir. Daha sonra her bir pikselin komşuları arasındaki farklılığın ağırlıklı ortalaması alınarak bozulma derecesi hesaplanarak görüntünün anormallik haritası elde edilmiştir. Son olarak, bu anormallik haritası basit bir eşikleme işlemi ile bölütlenerek kusurların yeri tespit edilmektedir. Önerile yöntemin hem yanak görüntüleri için hem de sırt görüntüleri için başarılı sonuçlar verdiği ifade edilmektedir.

Doğrudan lastik görüntülerinin kullanıldığı yöntemlerin yanında derin öğrenme yöntemleri olan konvolüsyonel sinir ağı (CNN) modellerinin kullanıldığı çalışmalarda literatürde yer almaktadır. Bu modellerin en belirgin avantajları öznitelik çıkarma kabiliyetleri olarak ifade edilebilir. Wang ve arkadaşları (R. Wang et al., 2019), endüstriyel alanda üretim sırasında lastiklerin görüntülerini X-Ray ışını yardımı ile elde ederek ve tamamen evrişimli sinir ağı (FCN) kullanarak lastik arızalarının tespitini yapmışlardır. FCN piksel bazda tahminler yaptığından ötürü kusurların konumu ve segmentasyonu aynı anda tamamlanır. Yöntemde kullanılan ağ mimarisi 3 aşamadan

oluşur. İlk aşamada lastik görüntü özelliklerini çıkaran geleneksel derin bir ağ yöntemi uygulanmış, ikinci aşamada örnekleme katmanı eklenerek orijinal görüntüler ile aynı boyutta çıktılar elde edilmiştir. Son aşamada ise ölçekli özellik haritası çıktılarına eklenerek doğru kusurlar sonuç olarak elde edilmektedir. Veri setinde orijinal ve kusurlu olmak üzere toplam 914 görsel yer almaktadır. Kullanılan ağ modelinin temel mimarisi olarak VGG16 seçilmiştir. Elde edilen sonuçları doğrulamak için AlexNet, VGG11, VGG13 ve VGG16 ile karşılaştırılmıştır.

Zheng, Z ve ark. (Zheng et al., 2020), lastiklerin iç yapısında gözle görünmeyen hatalarının tespitinin bir başka başarılı yöntemi olan X-Ray görüntülerden lastik kusur tespiti yapmaya çalışmışlardır. Bu çalışmada, otomatik lastik görsel denetimi için VGG16 temelli bir Özlü Anlamsal Segmentasyon Ağı (Concise-SSN) isimli bir model önerilmiştir. Önerilen model ile tamamen piksel bazlı hata tespiti gerçekleştirilmiştir. Model, optimize bir semantik segmentasyon ağı ve tümleşik evrişimli sinir ağı kabiliyetlerini bir araya getirmektedir. Deneysel sonuçlar önerilen modelin FCN, Mask R-CNN, Faster R-CNN, SegNet ve U-net ağlarına kıyasla daha yüksek segmentasyonu ve sınıflandırma performansı gösterdiğini ortaya koymaktadır. Consine-SSN modelinin hatalı lastikleri tespit doğruluk oranı %96,5 olarak elde edilmiştir.

Zhang ve ark. (Zhang et al., 2015), lastik yüzeyindeki kusurlar tespit etmek üzerine yaptıkları araştırmada X-Ray görüntüler kullanarak çok-ölçekli kenar özelliklerini analiz eden dalgacık dönüşümü esasına dayanan bir segmentasyon metodu önermişlerdir. Önerdikleri yöntemde kenar bilgileri yüksek frekans bandında daha büyük katsayılarla temsil edilebilen dalgacık dönüşümü özelliklerini kullanmaktadır. Kenar bilgilerine karşılık gelen daha büyük eğri katsayıları, eşikleme yoluyla seçilmektedir. Bu uygulanan yöntem ile yüksek frekanslı doku verimli bir şekilde filtrelenilebilmekte ve kenar bilgisi korunabilmektedir. Bu çalışmada geleneksel kenar algılama yöntemleri olan Canny, Sobel ve LoG gibi yöntemlerle kıyaslama yapılmış ve önerilen yöntemin bu kenar algılama yöntemlerinden daha iyi performans gösterdiğini ifade edilmiştir.

Li, ve ark. (Li et al., 2021), üretim hatalarından dolayı fabrikaya iade edilen yüksek orandaki lastiklerin oranlarını düşürmek için TireNet yöntemini geliştirilmiştir. X-Ray ile elde edilen lastik görüntüleri özellik çıkarımları yapıldıktan sonra siyam ağı ile görüntüler arasındaki kaybı hesaplamak ve nihai kararı vermek için kullanılmıştır. Hızlı R-CNN sınıflandırıcısına Siyam ağının yapısını ekleyerek model oluşturulmuştur. Yapılan çalışmada 120.000 etiketli lastik görüntüsü kullanılmıştır. Oluşturulan veri seti

kullanılarak önerilen TireNet isimli model, Faster R-CNN, SSD ve YOLO modelleriyle karşılaştırılmıştır. TireNet normal beklenen %2,4 ten daha yüksek performans yakalayarak hata oranını %0,17'e indirerek yüksek oranda başarı elde etmiştir.

Lin (Lin, 2023), oksitlenmeden kaynaklı lastik kusurlarının tespitine yönelik derin öğrenme mimarisine sahip bir model önermiştir. Bu çalışmada, geliştirilmiş ShuffleNet modeli lastik kusurlarını tespit etmek amacıyla kullanılmıştır. Çalışmada kapsamında geliştirilmiş ShuffleNet isimli model normal lastik resimlerini kullanmakta olup, GoogLeNet, geleneksel ShuffleNet, VGGNet ve ResNet modeller ile karşılaştırma amacıyla analizler yapılmıştır. Önerilen modelin lastik kusurlarını etkili bir şekilde tespit edebildiği ifade etmişlerdir.




3. MATERYAL VE YÖNTEM

Bu çalışmada CTLDF+EnC isimli hibrit bir sistem önerilmektedir. Bu sistemde, bir dizi TÖ model çıkışından alınan derin öznitelikler bir araya getirilerek geleneksel makine öğrenme (MÖ) yöntemlerinin topluluk sınıflandırıcı dahilinde değerlendirildiği bir yapıya sahiptir.

3.1. Sistemin Genel Yapısı

Bu hibrit mimari ile lastik görüntülerinden çatlamış ve normal lastikleri tespit etmek hedeflenmektedir. Şekil 3.1’de çalışma kapsamında önerilen sistemin içerdiği dört temel aşama şematize edilmiştir. Çalışmada kullanılan veri seti, oksitlenmiş (çatlamış) ve oksitlenmemiş (normal) olmak üzere 1028 görüntü içermektedir.



Şekil 3.1. Önerilen hibrit sistemin aşamaları

Aşama 1 (Ön işlem): Ön işlem aşaması, başlangıç adımı olarak uygulanmaktadır. Bu aşamada, tüm görsel veriler TÖ modellere uygun bir boyuta (224x224x3) ölçeklendirilir. Ardından veri artırma amacıyla, yatay/dikey öteleme, boyut ölçekleme, yatay/dikey çevirme, açısal döndürme, parlaklık ayarlama gibi görüntü manipülasyon işlemleri uygulanmıştır. Bu işlemler, modelin çeşitli koşullara daha dayanıklı hale gelmesini sağlamak amacıyla uygulanır. Sonrasında, veri seti eğitim ve test alt kümelerine ayrılarak analizlere tabi tutulur ve bir sonraki aşamaya geçiş gerçekleştirilir.

Aşama 2 (Öznitelikler ve İndirgeme): Bu aşamada, çalışma kapsamında kullanılan her bir ön-eğitilmiş TÖ modeline ilişkin elde edilen derin öznitelikler indirgenmektedir. Her TÖ modeli diğerlerinden bağımsız olarak uygulanarak eğitim ve test veri setlerine ait derin öznitelikler çıkarılmakta ve daha sonra indirgenmektedir.

Aşama 3 (Basamaklandırma ve Model Seçimi): Bu aşamada ise, her bir TÖ yönteminden elde edilen indirgenmiş eğitim ve test veri setlerine ait bu derin öznitelikler birleştirilmektedir (basamaklandırma). Ardından eğitim seti kullanılarak en başarılı beş MÖ yöntem seçilmektedir. En iyi beş model seçiminde 10 çapraz doğrulama ve AUC ölçüğü kullanılmaktadır. Daha sonra belirlenen bu en iyi beş MÖ model nihai tahmin yapılma amacıyla sonraki aşama olan topluluk sınıflandırıcı aşamasına geçilmektedir.

Aşama 4 (Topluluk Sınıflandırıcı): Bu aşama son basamak olup bu aşamada, önceki aşamalarda belirlenen en iyi beş MÖ model ve elde edilen basamaklandırılmış derin öznitelikler kullanılarak istifleme ve oylama esaslı topluluk sınıflandırıcılarla normal ve oksitlenmiş lastikler tahmin edilmektedir.

Bu çalışmada önerilen hibrit sistem ve doğrudan TÖ modeller kullanılarak gerçekleştirilen tüm uygulamalar, Tensorflow, Keras ve scikit-learn kütüphaneleri kullanılarak Python programla dili ile gerçekleştirilmiştir. Modeller ve analizler ~3,2GHz hızında 16 CPU'lu AMD Ryzen 7 (5800H) işlemcili, 4GB GDDR6 hafıza/~1,5GHz hızında Nvidia GeForce RTX 3050 GPU ve 16 GB RAM'e sahip kişisel bir bilgisayar ortamında gerçekleştirilmiştir.

3.2. Veri Seti

Çalışma kapsamında herkese açık lastik görüntüleri içeren bir veri seti kullanılmıştır. Bu veri seti, çatlamış (oksitlenmiş) ve normal (oksitlenmemiş) olmak üzere iki kategoride lastik yanakları ve sırt görüntüleri içeren toplam 1028 görüntüden oluşmaktadır (Siegel, 2021). Çalışmada kullanılan veri seti, Görüntülere büyültme (augmentation) ya da herhangi bir ön işlem uygulanmamış olup eğitim ve test setlerine ayrılmış bir şekilde paylaşılmaktadır. Veri seti herkesin erişimine açık olup, Harvard'ın dataverse web sayfası alanından indirilmiştir (Siegel, 2021).

Veri setinin bu çalışmada kullanılan son güncel halinde, 491 normal (oksitlenmemiş) ve 537 çatlamış (oksitlenmiş) lastik görüntüsü yer almaktadır. Tablo 3.1'de çatlamış ve normal lastik görüntü sayılarının eğitim ve test veri setleri arasındaki dağılımları görülmektedir.

Tablo 3.1. Veri seti görüntü dağılımları

	Normal	Çatlamış	Toplam
Eğitim	376	327	703
Test	115	210	325
Toplam	491	537	1028


Tablodan görüldüğü gibi, eğitim setinde 703 ve test veri setinde 325 örnek bulunmaktadır, bu da eğitim-test veri seti oranlarının sırasıyla %68 ve %32 olduğunu göstermektedir. Veri setindeki görüntülerin çözünürlükleri standart olmayıp farklı çözünürlüklere sahiptir. Bu nedenle, ön işleme aşamasında görüntüler standart ölçülere ayarlanmış ve aşırı öğrenmeyi engellemek için yatay/dikey kaydırma, yatay döndürme, ölçekleme, döndürme gibi veri arttırma (augmentation) yöntemleri uygulanmıştır. Şekil 3.2’de veri setin yer alan normal ve çatlamış lastiklere ait örnek görüntüler görülmektedir.

**Şekil 3.2.** Örnek lastik görüntüleri, a) Çatlamış ve b) Normal

3.3. Derin Öznitelik ve Topluluk Sınıflandırma Temelli Hibrit Sistem

Bu tez çalışmasında, topluluk öğrenmesiz ön-eğitilmiş TÖ modellerin doğrudan kullanıldığı uygulamalar ve ön-eğitilmiş TÖ modellerinden elde edilen derin özniteliklerin basamaklı/kaskad birleştirilerek topluluk sınıflandırıcılara uygulandığı temelde iki farklı uygulama gerçekleştirilmiştir. İlk grup uygulamalarda ön-eğitilmiş TÖ modeller doğrudan kullanılarak lastik durumları tahmin edilmiştir. İkinci grup uygulamalarda ise Özaydın ve Tekin (Özaydın & Tekin, 2023) tarafından COVID-19 hastalığının teşhisi için önerilen DeepFeat-E isimli hibrit modelin modifiye edilmiş bir versiyonu kullanılmıştır. Önerilen hibrit sistem, Kaskad edilmiş Transfer Öğrenme Derin Öznitelikler Topluluk sınıflandırıcılara uygulandığından CTLDF+EnC (Cascaded Transfer Learning Deep Features + Ensemble Classifiers) olarak isimlendirilmiştir. CTLDF+EnC isimli yeni hibrit modelde DeepFeat-E’nin aksine TÖ’lerin İÖS’leri topluluk sınıflandırıcıya ayrı ayrı girilmeyip birleştirilerek ve tek bir öznitelik seti olarak uygulanmıştır.

Şekil 3.3'te çalışma kapsamında önerilen basamaklandırılmış derin öznitelikler ve topluluk sınıflandırıcılara dayalı CTLDF+EnC isimli hibrit sisteme ilişkin blok diyagram görülmektedir. Şekil 3.3'te görüldüğü gibi, Derin Öznitelik Üretici (DÖÜ) bloğu belirli bir TÖ modeline ait derin özniteliklerinin çıkarılması ve daha sonra öznitelik seçim işlemiyle İndirgenmiş Öznitelik Setinin (İÖS) elde edilmesi süreçlerini içermektedir. Önerilen hibrit sistemde DÖÜ bloğu, çalışma kapsamında kullanılan 9 adet TÖ modele ayrı ayrı uygulanarak her bir TÖ modelin İÖS elde edilmiştir. DÖÜ bloğunda derin öznitelikler çeşitli öznitelik seçim yöntemleri (temel bileşen analizi, lineer diskriminant analizi ve ekstra ağaç sınıflandırıcı) denemiş ve en yüksek başarımlı model seçilerek indirgenme yapılmıştır. En başarılı sonuçlar Ekstra Ağaç Sınıflandırıcı ile elde edildiğinden bu öznitelik seçim yöntemiyle indirgeme yapılmıştır.



Şekil 3.3. Önerilen hibrit sistemin şematik gösterimi

Basamaklandırma ve Topluluk Sınıflandırma (BTS) bloğunda ise çalışma kapsamında kullanılan her bir TÖ'e için elde edilen İÖS'ler basamaklandırılmaktadır. BTS'de basamaklandırılan öznitelikler kullanılarak Topluluk Öğrenme Modeli (TÖM) alt bloğu altında yer alan Model Seçici ile 10 çapraz-doğrulama sonunda 14 farklı MÖ yöntemi arasından en yüksek başarımlı (UAC'a göre) ilk k adet MÖ modeli seçilmektedir ($k = 5$ alınmıştır). Seçilen MÖ yöntemler ve başarı sıralamaları her bir TÖ modelinde değişiklik göstermekle birlikte, genel olarak RF (Random Forest), LDA (Linear Discriminant Analysis), lgbm (Light Gradient Boosting Machine), LR (Logistic Regression), ETC (Extra Trees Classifier), GB (Gradient Boosting) ve xgb (eXtreme Gradient Boosting) MÖ modellerinin seçildiği görülmektedir. Şekil 3.3'te görüldüğü gibi TÖM'de seçilen bu k en iyi MÖ yöntemi Topluluk Sınıflandırıcı alt bloğunda

kullanılmaktadır. Topluluk Sınıflandırıcı alt bloğunda seçilen en iyi k adet MÖ model kullanılarak İstifleme ve oylama (Katı ve Yumuşak oylama) esasına dayalı üç farklı topluluk sınıflandırıcı kullanılarak lastik durumu (Çatlamış ve Normal) tahmin edilmektedir.

3.4. Ön-Eğitilmiş Transfer Öğrenme Modelleri

Transfer öğrenme yöntemleri, makine öğrenimi disiplini içerisinde önemli bir metodoloji olarak kabul edilmekte olup, bu yöntem ön-eğitilmiş bir modelin parametre ve ağırlıklarının yeni bir problemde tekrar kullanılmasını içermektedir. Eğer iki model, benzer görevleri başarıyla yerine getirmek üzere eğitilmişse, bu modeller arasında genelleştirilmiş bilgi paylaşılabilir. Böylece, mevcut modeller yeni problemlere uygulanırken yeniden eğitim gerektirmeyerek, kaynak ihtiyacını ve aynı zamanda etiketli veri boyutu gereksinimini indirgeyerek makine öğrenimini geliştirmeye odaklanmaktadır. Makine öğrenimi algoritmaları, çeşitli sektörlerde karmaşık görevleri başarıyla yerine getirmek için yaygın olarak kullanılmaktadır. Denetimli makine öğrenimi, birçok farklı makine öğrenimi türünden biri olarak öne çıkmakta olup, genellikle popüler bir süreçtir. Bu tür makine öğrenimi yöntemleri, eğitim süreci için yeterli sayıda etiketlenmiş eğitim verilerine ihtiyaç duyar. Ancak, veri kümesinin etiketlerinin doğru bir şekilde ayarlanması uzmanlık gerektirir ve ayrıca bu makine öğrenim yöntemlerinin eğitim süreci genellikle oldukça zaman alıcıdır. Transfer öğrenme yöntemleri, bu süreci hızlandırabilir ve daha az etiketlenmiş veriyle yeni modellerin başarılı bir şekilde eğitilmesini sağlayabilir. Bu nedenle, transfer öğrenimi, makine öğrenimi topluluğunda giderek daha fazla ilgi görmektedir.


Transfer öğrenme yöntemleri, ön-eğitilmiş modellerin yeni bir problem veya uygulamada kullanılmasını sağlayan bir tekniktir ve makine öğrenimi süreçlerinde etkili bir çözüm sunmaktadır. Bu metodoloji, farklı bir makine öğrenimi algoritması türü değil, daha çok modelleri eğitirken kullanılan bir strateji veya yöntem olarak değerlendirilmelidir. Önceki eğitimden elde edilen bilgiler, yeni bir görevin başarılmasına yardımcı olmak için adaptasyona uğratılır. Yeniden kullanılan ön-eğitilmiş modelin farklı problemlerde kullanılabilmesi için yüksek düzeyde bir genelliğe sahip olması gerekir. Transfer öğrenme modelleri, eğitim gerektirmeksizin yeni veya farklı problemlere uygulanabilmeleri sayesinde eğitim için gerekli kaynaklardan ve zamandan tasarruf edilmesini sağlar. Yeniden kullanım sayesinde, kaynak yetersizlikleri ve uzun

eğitim süreleri gibi sorunlar minimize edilir. Transfer öğrenimi, bu avantajlarıyla makine öğrenimi süreçlerinde daha etkili ve verimli çözümler sunmaktadır.

Büyük veri kümelerinin doğru bir şekilde etiketlenmesi, genellikle oldukça zaman alıcı bir süreçtir. Kuruluşların karşılaştığı veriler çoğunlukla etiketsizdir, özellikle de bir makine öğrenimi algoritmasını eğitmek için gerekli olan geniş veri kümeleri düşünüldüğünde. Transfer öğrenimi, mevcut bir etiketli veri kümesi üzerinde eğitilen bir modelin, benzer bir göreve uygulanabilmesini sağlayarak bu zorluğa bir çözüm sunar (J. Lu et al., 2015). Transfer yöntemler, çoğunlukla bir sistemde eğitim aşaması için büyük kaynakların gerekmesi durumunda tercih edilirler. Bu modellerin ön-eğitilmiş yapılarının doğrudan kullanılabilmesi sayesinde modele ilişkin benzer problemlerde bu modeller doğrudan kullanılabilir. Transfer modellerinin bu yönleri modellerin genel amaçlı olmasını sağlamaktadır. Transfer öğrenimi, modellerin sıkı bir şekilde bir eğitim veri kümesine bağlı olmaktan ziyade daha genelleştirilebilir modellerin geliştirilmesine olanak sağlar. Bu sayede geliştirilen modeller, değişen koşullar ve farklı veri setleriyle başa çıkabilirler. Bu çalışmada da dokuz farklı transfer öğrenme modeli lastik kusurlarının tespitinde doğrudan ve önerilen hibrit yapı içerisinde dolaylı olarak kullanılmıştır.

3.4.1. Xception TÖ Modeli

Xception Transfer Öğrenme Yöntemi, derin evrişim işlemlerine dayanan iki aşamalı bir modeldir. İlk evrişim aşamasında, her bir giriş kanalı, uzaysal evrişimde bağımsız olarak işlenir. Ardından yapılan noktasal evrişimde, noktasal evrişimler 1×1 filtreler kullanılarak gerçekleştirilir. Xception, ayrılabilir evrişim katmanlarına dayanan bir evrişimsel sinir ağıdır. Model, girişlerdeki her bir kanala ilişkin bağımsız öznetelik haritaları oluşturarak kanalların uzamsal korelasyonlarını ayrıştırabilmektedir. Xception modeli InceptionV3 TÖ'den esinlenilerek ismini 'Extreme Inception' ifadesinden almıştır (Chollet, 2017). Şekil 3.4'te Xception TÖ modeline ait şematik yapı çizimi görülmektedir (Chen et al., 2021). Bu özgün yapı, giriş verilerini etkili bir şekilde işlemek ve öznetelik haritalarını optimize etmek için tasarlanmıştır.




Şekil 3.4. Xception modelinin şematik yapısı.

Şekil 3.4'ten görülebileceği üzere, Xception modeli doğrusal artık bağlantılara sahip derinliklere ayrılabilir toplamda 36 evrişim katman yığınına sahiptir. Özellik elde etmek için kullanılan Xception ağı, normalleştirilmiş giriş görüntüsünü işlemek için iki standart evrişim işlemi kullanır, bu işlem özellik görüntüsünün uzamsal ve kanal korelasyonlarını ele alır. Modelde, uzamsal ve kanal bilgilerini ayrıştırmak için derinlikleri ayrıştırabilen bir evrişim katmanı kullanılır. Çıkış verilerinin boyutunu indirmek ve seçmek için Max-pooling katmanı kullanılır. Son katmanda yer alan tam bağlantı katmanında ise, öznitelikler kullanılarak sınıflandırma işlemi gerçekleştirilir (Zhu et al., 2022). Bu yapı, Xception modelinin temel mimarisini oluşturur ve özellikle evrişim katmanlarında kullanılan derin ve ayrılabilir yapı, modelin etkili bir şekilde özellik çıkarma ve sınıflandırma yapabilmesine olanak tanır.

3.4.2. NaSNet TÖ Modeli

Nöral Mimari Arama (Neural Architectural Search, NAS) TÖ modeli, Google makine öğrenimi grubu tarafından geliştirilmiş bir yöntemdir. Bu ağ, pekiştirmeli öğrenmeye dayanan bir mimariye sahiptir. NaSNet içinde, alt blokların etkinliği üst blok tarafından gözden geçirilir ve bu incelemelere bağlı olarak ağın ayarlamaları gerçekleştirilir. Ağın mimarisi, bir CNN ve bir denetleyici tekrarlayan sinir ağı blokları içerir (Nigam et al., 2021). NASNet Normal ve İndirgeme olmak üzere temel iki tip hücre yer almaktadır. Her iki hücrede evrişim işlemi gerçekleştirilmekle birlikte indirgeme hücrelerinde çıkış veri boyutu azaltılmaktadır. Bu iki tip hücrenin iç yapısı sabit olmayıp dinamik bir arama uzayı içerisinde aranarak belirlenmektedirler. Bu işlemler RNN (Recurrent Neural Network) tarafından gerçekleştirilmektedir. Şekil 3.5'te RNN tarafından gerçekleştirilen işlemlere ilişki şematik gösterim görülmektedir (Zoph et al., 2018).

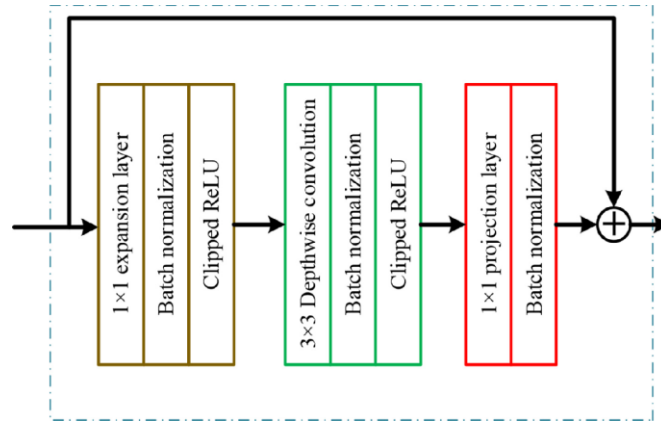


Şekil 3.5. NASNet Mimarisi (Zoph et al., 2018)

Ağın yapısı, turnuva seçim algoritmaları ile performansı düşük hücreler elenerek belirlenir. Ağın arama alanı, hücrelere bölerek ve ardından bu hücreleri bloklara bölerek oluşturulur. Veri kümesinin özelliklerine bağlı olarak hücre ve blok sayısı belirlenir. Bir blok içinde konvolüsyon, havuzlama, haritalama vb. işlemler gerçekleştirilmektedir. NASNet transfer yöntemi, özgün bir ağ mimarisi oluşturarak çeşitli uygulamalarda etkili bir şekilde kullanılmaktadır.

3.4.3. MobileNet TÖ Modeli

MobileNet Transfer Yöntemi, son zamanlarda GPU ve CPU'lardaki hız artışlarıyla birlikte derin öğrenme yöntemlerinde daha geniş bir kullanım alanı bulmaya başlamıştır. Öğrenme algoritmalarındaki gelişmelerle birlikte CNN mimarilerinin eğitimi daha başarılı ve hızlı hale gelmiştir. Bu sayede, klasik MÖ modelleri göre daha başarılı olan VGG, ResNet, AlexNet ve MobileNet gibi TÖ modeller geliştirilmiştir (Nan et al., 2022). Ancak, ağların derinleşmesiyle birlikte büyük veri ve gerekli fiziksel kaynak ihtiyacı, dolayısıyla da hesaplama maliyetleri artmaktadır.



Şekil 3.6. Artık darboğaz bloğu (S.-Y. Lu et al., 2020)

MobileNet, bu bağlamda hesaplama maliyeti ile performans arasında bir denge sağlamak amacıyla geliştirilmiştir. MobileNet, ayrılabilir (separable) ve derinlikli (depthwise) evrişim yapılarını kullanarak sınıflandırma başarısını korurken evrişim katmanlarının parametre sayısını önemli ölçüde azaltmaktadır. Klasik evrişim katmanlarının karmaşıklığı ve hesaplama maliyeti yerine, MobileNet, her bloğun girişini filtreleyen 3x3 derinlikte evrişim katmanından ve ardından bu filtrelenmiş değerleri birleştiren 1x1 noktasal evrişim katmanından oluşan derinlemesine ayrılabilir evrişim bloklarını tercih etmektedir (Michele et al., 2019). MobileNet Transfer Yöntemi, düşük hesaplama maliyetiyle yüksek performans elde etme amacıyla tercih edilen etkili bir derin öğrenme stratejisidir.


Type / Stride	Filter Shape	Input Size	
Conv / s2	3 x 3 x 3 x 32	224 x 224 x 3	
Conv dw / s1	3 x 3 x 32 dw	112 x 112 x 32	
Conv / s1	1 x 1 x 32 x 64	112 x 112 x 32	
Conv dw / s2	3 x 3 x 64 dw	112 x 112 x 64	
Conv / s1	1 x 1 x 64 x 128	56 x 56 x 64	
Conv dw / s1	3 x 3 x 128 dw	56 x 56 x 128	
Conv / s1	1 x 1 x 128 x 128	56 x 56 x 128	
Conv dw / s2	3 x 3 x 128 dw	56 x 56 x 128	
Conv / s1	1 x 1 x 128 x 256	28 x 28 x 128	
Conv dw / s2	3 x 3 x 256 dw	28 x 28 x 256	
Conv / s1	1 x 1 x 256 x 256	28 x 28 x 256	
Conv dw / s1	3 x 3 x 256 dw	28 x 28 x 256	
Conv / s1	1 x 1 x 256 x 512	14 x 14 x 256	
5 x	Conv dw / s1	3 x 3 x 512 dw	14 x 14 x 512
	Conv / s1	1 x 1 x 512 x 512	14 x 14 x 512
	Conv dw / s2	3 x 3 x 512 dw	14 x 14 x 512
Conv / s1	1 x 1 x 512 x 1024	7 x 7 x 512	
Conv dw / s2	3 x 3 x 1024 dw	7 x 7 x 1024	
Conv / s1	1 x 1 x 1024 x 1024	7 x 7 x 1024	
Avg Pool / s1	Pool 7 x 7	7 x 7 x 1024	
FC / s1	1024 x 7	1 x 1 x 1024	
PNN / s1	Classifier	1 x 1 x 5	

Şekil 3.7. MobileNet modeli mimarisi (Ashwinkumar et al., 2022)

3.4.4. DenseNet TÖ Modeli

DenseNet TÖ Yöntemi, Huang ve ark. (G. Huang et al., 2017) tarafından önerilen bir algoritmadır. Bu algoritma, evrişimli ağların girdiye yakın ve çıktıya yakın katmanları kısaltıldığında, daha verimli, doğru ve derin bir şekilde eğitilebileceğini göstermiştir. Bu yaklaşım, ResNet ve benzer diğer ağlarda da kullanılmıştır. DenseNet TÖ modeli ResNet' TÖ'den farklı olarak, öznitelikleri toplama yoluyla birleştirmez, bunun yerine öznitelik haritalarını birleştirmektedir (G. Huang et al., 2018). Bu özelliğiyle DenseNet, önceki modellerden farklı bir strateji benimseyerek ağı öğrenme kapasitesini artırma ve bilgi akışını optimize etme amacını taşımaktadır.

DenseNet ağı, farklı katman sıralamaları ve mimarilerle çeşitlendirilebilir. Diverse modeller arasında DenseNet 121, DenseNet 169 ve DenseNet 201 bulunmaktadır. 3.8'de gösterilen model, 201 dense katman içeren DenseNet201 modelidir ve dört dense ağ bloğundan oluşmaktadır. Bu modelde dense bloklar, evrişim katmanından sonra ortalama havuzlama (Pooling) katmanlarına bağlıdır. Sonraki aşamada ise, dense katmanlar global havuzlama katmanına girilir. Son olarak global havuzlama katmanı sınıflandırma amacıyla tam-bağlantılı bir Softmax katmanına bağlanır ve öznitelik vektörünü oluşturulur.




Şekil 3.8. DenseNet modelinin şematik yapısı

DenseNet ağı, özniteliklerin tekrar tekrar kullanılmasını sağlayan bir mekanizma sunmaktadır, bu süreç bağlantılar aracılığıyla atlamalar (bypass) ve birleştirmeler ile gerçekleştirilmektedir. Derin katmanlarda ortaya çıkan gradyan kaybı eğilimini azaltmak

adına, atlamalar (bypass) katmanları genellikle ağıın derin katmanlarına entegre edilir. Dense mekanizması, her bir katmanın, ardışık katmanlara giriş olarak hizmet etmesini sağlayan özel katmanlardan oluşmaktadır. Bu mekanizma, ağıın parametre sayısını azaltarak, gradyan kaybı problemiyle başa çıkma amacını taşımaktadır (Kong & Cheng, 2022; Yuan et al., 2022).

3.4.5. VGG TÖ Modeli

VGG TÖ modeli, transfer derin öğrenme metotları arasında önemli bir yer tutar. VGG modelleri, ağıın derinliğini artırarak performansı geliştiren modellerdir. Temel olarak, küçük bir evrişim ve havuzlama çekirdeği ile ReLU aktivasyon fonksiyonundan oluşan basit bir yapıya sahiptir. Şekil 3.9.'daki basit VGG modeli, 5 evrişimsel katman, 3 tam bağlantılı katman ve bir softmax çıktı katmanı içerir. Bu katmanları arasında havuzlama (max) kullanılabilir. VGG'deki tüm gizli katmanlarda aktivasyon fonksiyonu olarak ReLU kullanılır (Kong & Cheng, 2022).



Şekil 3.9. VGG ağı mimarisi (Kong & Cheng, 2022)

VGG ağlarının önemli avantajları arasında, sinir ağ yapısını basitleştirmesi sayılabilir. Bu sayede, VGG modelleri, öznetelik çıkarımını basitleştirerek ve transfer öğrenme ile başarı elde ederek önemli bir yöntem olarak kabul edilir.


3.4.6. Inception TÖ Modeli

Inception (GoogleNet) TÖ modeli, görüntü sınıflandırma amacıyla Google çalışanları Szegedy ve ark. (Szegedy et al., 2015) tarafından 2015 yılında geliştirilmiş evrişimli bir derin sinir ağı mimarisidir. GoogleNet, 2014 yılında Google'da (çeşitli

üniversitelerle iş birliği içinde) gerçekleştirilen bir araştırma sonucunda "Going Deeper with Convolutions" başlıklı araştırma makalesinde önerilmiştir (Szegedy et al., 2016). Modelin temel karakteristiği, giriş katmanlarında evrişim işlemleri paralel bir şekilde yürütmesidir. GoogleNet, 2014 yılındaki ILSVRC isimli yarışmayı kazanarak başarı elde etmiştir. Önceki yıllarda yapılan yarışmaların birincileri olan AlexNet (2012 ILSVRC) ve ZF-Net (2013 ILSVRC) ile kıyaslandığında önemli bir hata oranı düşüşü ve VGG'den (2014 ikincisi) daha yüksek bir başarı elde etmiştir.

GoogleNet'in en önemli özelliği, "Inception" adlı modüllerden oluşan bir yapıya sahip olmasıdır. Bu modüller, farklı boyutlardaki evrişim katmanlarını ve havuzlama katmanlarını içerir. Özellikle, 1x1, 3x3 ve 5x5 boyutlarındaki evrişim katmanları, birleştirilerek paralel olarak çalıştırılır. Bu paralel evrişim işlemleri, görüntülerden çok ölçekte daha iyi öznitelik haritaları sağlamayı amaçlamaktadır (Szegedy et al., 2016). Şekil 3.10. bir Inception modülünün şematik yapısını göstermektedir (Das et al., 2020). Bu mimari, karmaşık yapıları birleştirerek daha etkili ve başarılı bir öğrenme süreci sağlamak amacıyla tasarlanmıştır.


Inception (GoogleNet) Transfer Yöntemi, renkli RGB görüntülerle çalışan bir ağdır ve 224 x 224 boyutunda görüntülerle işlem yapar. Ağın içindeki tüm aktivasyon fonksiyonları ReLU'dur. GoogleNet'in mimarisi Şekil 3.10.'da gösterilmiştir (Szegedy et al., 2016). Bu mimari, çeşitli boyutlardaki görüntüler üzerinde etkili bir şekilde çalışabilen ve ReLU aktivasyon fonksiyonunu kullanarak öznitelik çıkarımı gerçekleştiren bir yapı sunar.



Şekil 3.10. Inception modelinin şematik yapısı.

(a) Inception modülünün temel yapısı, (b) boyut küçültmeli Inception modülü (Szegedy et al., 2016)

AlexNet ve ZF-Net gibi önceki transfer yöntemlerinden farklı bir mimariye sahiptir, özellikle 1×1 evrişim ve küresel ortalama havuzlama gibi benzersiz özellikleri içermektedir (Szegedy et al., 2016). 1×1 boyutundaki evrişim katmanları, modelin hesaplama maliyetini azaltmaya yardımcı olur. Bu, daha hafif ve daha hızlı bir model elde etmeye katkıda bulunur. Mimari aynı zamanda küresel ortalama havuzlama katmanlarını içerir, bu da özellik haritalarının boyutunu azaltarak daha etkili bir öğrenme sağlar. Ağın sonunda diğer TÖ modellerinin aksine tam bağlı katmandan önce küresel ortalama havuzlama katmanı yer alır. 7×7 öznitelik haritalarını 1×1 öznitelik haritalarına dönüştüren bu katman hem parametre sayısını azaltmakta hem de ImageNet veri seti üzerinde başarıyı belirli bir oranda arttırmaktadır (Szegedy et al., 2016). GoogleNet, toplamda 144 katmandan oluşur ve genel mimarisi Şekil 11’de gösterilmiştir.



Şekil 3.11. Inception modelinin mimarisi (Szegedy et al., 2016)


GoogleNet, geniş ve karmaşık yapıları başarıyla birleştirerek sınıflandırma ve tanıma görevlerinde yüksek doğruluk elde etmiş ve derin öğrenme alanındaki gelişmelerde önemli bir kilometre taşı olarak kabul edilmiştir.

3.4.7. ResNet TÖ Modeli

Genel olarak, derin öğrenme metotları sınıflandırma problemlerinde başarılı olsa da ağların eğitimi çeşitli zorluklarla karşılaşabilir. Bu zorlukların başında patlayan (veya yok olan) gradyanlar gelir. Bu durum, bir nöronun eğitim sürecinde ölmesi ve aktivasyon fonksiyonuna bağlı olarak geri dönmemesi anlamına gelir. İkinci bir zorluk ise transfer yöntemlerinin parametrelerinin optimizasyonudur. Ağın derinliği arttıkça, bu parametrelerin sayısı fazla olduğundan eğitim süreci daha karmaşık hale gelir (He et al., 2016). Bu nedenlerle, ResNet, bu zorlukları aşmak ve daha derin ağların eğitimini kolaylaştırmak için öne çıkan bir transfer derin öğrenme yöntemidir.

Zorlu eğitim problemlerini etkili bir şekilde aşmak için önerilen bir yöntem ResNet ağlarıdır (He et al., 2016). ResNet'in temel özelliği, normal evrişim katmanlarına paralel olarak kısayol bağlantılarına sahip olmalarıdır. Bu kısayol bağlantıları, evrişim katmanlarından farklı olarak her zaman aktiftir ve hatanın kolayca geri yayılmasına olanak tanır. ResNet mimarisi, 2015 yılında ILSVRC ve COCO yarışmalarında başarılı olarak birincilik elde eden bir modeldir. Ayrıca bu model sınıflandırma gerektiren diğer yapay zekâ problemlerinde de başarılı bir şekilde kullanılmaktadır. ResNet ağları farklı mimarilere sahiptir, örneğin ResNet18, ResNet34, ResNet50, ResNet101 ve ResNet152. ResNet-50, önerilen mimariler arasında yer alır ve 50 katmandan oluşur. Bu mimaride

1×1 , 3×3 ve 1×1 olmak üzere beş evrişimsel blok bulunmaktadır. 1×1 evrişim blokları, giriş görüntülerini düşük boyuta indirir, 3×3 evrişim blokları ise daha yüksek boyutlu filtreleme işlemini gerçekleştirir. Mimaride global ortalama havuzlama katmanı kullanılarak ayrıca boyut küçültme gerçekleştirilmiştir. ResNet-50 TÖ modeli genel olarak, evrişim, aktivasyon, havuzlama ve tam bağlantılı katmanlardan oluşur. Şekil 3.12.'de ResNet TÖ modelinin genel yapısı görülmektedir.



Şekil 3.12. ResNet Ağı Mimarisi (Wu et al., 2018)

3.5. Ekstra Ağaç Sınıflandırıcı (EAS) ile Öznitelik Seçimi

Çalışma kapsamında gerçekleştirilen uygulamalarda öznitelik seçimi için, TÖ modellerinden elde edilen derin özniteliklerin en uygun olanlarını belirlemek amacıyla EAS (Extra Trees Classifier) kullanılmıştır (Geurts et al., 2006). Burada öznitelik seçimindeki amaç, uygulanacak sınıflandırma yönteminin tahmin sonuçlarına en yüksek düzeyde katkı sağlayacak kritik özniteliklerin seçimidir. Katkısı olmayan ya da düşük olan özniteliklerin elenmesinin, problemin karmaşıklığını azaltarak gerek hesaplama maliyetinin düşürülmesi gerekse model başarısının artırılması gibi katkıları olabilmektedir.

EAS, karar tabanlı bir yöntem olup öznitelik seçimi ve sınıflandırma arasında ortak bir çatı sunmaktadır. Rastgele Orman sınıflandırıcısına oldukça benzeyen bu yöntem, birçok alt-ağaç oluşturma ve rastgele alt kümeler seçme özelliği ile karakterizedir. Ana düğüm ve devamındaki yaprak düğümlerde rastgele bölme işlemleri gerçekleştirilir. Ardından tüm ağaçların tahminleri birleştirilerek çoğunluk kararını belirlemek için kullanılır. Öznitelik seçimi için orman oluşturulurken, Gini metrik değeri her bir öznitelik için ayrı ayrı hesaplanır. Öznitelikler, Gini değerine göre azalan sıralama düzeninde yer alır ve istenen sayıda öznitelik, en önemli öznitelikler arasından seçilebilir.

$$Gini = 1 - \sum_{i=0}^{c-1} p_i(t)^2 \quad (3.1)$$

Burada c bu düğümdeki tekil sınıf sayısını ve $p_i(t)$, t düğümündeki i sınıfına ait frekansı ifade etmektedir.

3.6. Topluluk Sınıflandırma Yöntemleri

Topluluk sınıflandırma yöntemleri, bir karar verici kaynaklı hatalı tahminleri azaltmak amacıyla bunun yerine birden çok karar vericinin kullanılarak başarıyı artırmayı hedefleyen yöntemlerdir. Topluluk sınıflandırıcıda kullanılan sınıflandırıcılar, bir grup geleneksel MÖ modeli içerisinde eğitim veri seti esas alınarak en iyi beş model 10 çapraz-doğrulama işlemi sonrasında AUC metriğine göre seçilmiştir. Böylece TÖ modeller kullanılarak elde edilen ve indirgenerek kaskad edilen derin öznitelikler bu sınıflandırıcılar uygulanmıştır. Bu sınıflandırıcıların ortak topluluk kararı ise İstifleme ve Oylama (Yumuşak ve Katı) topluluk öğrenme stratejileri ile belirlenmiştir. Oylama stratejisinde, çoğunluğun kararı esasına dayalı Katı Oylama ve mevcut sınıflandırıcıların tahmin olasılıklarının ortalamasını esas alan Yumuşak Oylama yöntemleri kullanılmıştır. Bu stratejiler, daha etkili ve güvenilir sınıflandırma sonuçları elde etmeyi amaçlamaktadır.

3.6.1. Oylama Esaslı Topluluk Sınıflandırıcılar

Oylama tabanlı topluluk öğrenme yöntemi, çeşitli makine öğrenimi tekniklerinin sınıflandırma tahminlerini bir araya getirerek topluluğa ait ortak bir tahmin elde etmeyi hedeflemektedir. Bu ortak tahmin, en çok oyu alan tahmin (Katı Oylama) veya tahminlerin olasılıksal ortalamaları (Yumuşak Oylama) gibi yöntemlerle elde edilebilir. Böylece, tek bir modelin potansiyel hatalı tahminlerini dengeleyerek daha yüksek bir doğruluk performansı sunabilir. Örneğin, x örneğinin tahminini yapmak için n adet farklı sınıflandırıcı $\{h_1, h_2, h_3, \dots, h_n\}$ ve k adet sınıf $\{s_1, s_2, s_3, \dots, s_k\}$ arasından seçim yapılabilir (Zhou, 2012).

Topluluk içindeki sınıflandırıcıların çoğunluğunun tahminini örneğin sınıf tahmini olarak kabul edildiği yöntem Katı Oylama (Hard Voting) olarak isimlendirilir.

Bu durumda, Katı Oylama yaklaşımında veri setindeki herhangi bir x örneğinin sınıf şu şekilde tahmin edilir (Zhou, 2012)

$$H(x) = s_{\sum_{i=1}^n h_i^j(x)} \quad (3.2)$$

Tahinlerin olasılıksal ağırlıklarının ortalaması kullanılarak sınıf tahmini yapılan yöntem ise Yumuşak Oylama (Soft Voting) olarak isimlendirilir. Herhangi bir örneğin sınıfı belirlenirken, ortalaması en yüksek sınıf tahmini topluluğun tahmini olarak kabul edilir. Bu durumda, Yumuşak Oylama yaklaşımında veri setindeki herhangi bir x örneğinin sınıf şu şekilde tahmin edilir (Zhou, 2012):

$$H(x) = s_{\sum_{i=1}^n w_i h_i^j(x)} \quad (3.3)$$

Her bir h_i sınıflandırıcısına ait tahminin topluluktaki diğer tahminler içerisindeki ağırlığı w_i değeri ile ifade edilmektedir.

3.6.2. İstifleme Esaslı Topluluk Sınıflandırıcı

Wolpert (Wolpert, 1992) tarafından önerilen İstifleme topluluk sınıflandırma yöntemi, temel olarak iki aşamadan oluşmaktadır. İlk aşamada topluluk sınıflandırıcılarda kullanılan yöntemlerin tahminleri elde edilmekte ve sonraki aşamada bir meta-sınıflandırıcı tarafından bu tahminler işlenerek topluluğa ait nihai tahmin üretilmektedir. Burada, tek bir sınıflandırıcıdan doğabilecek hatalı tahminlerin birden çok sınıflandırıcı tahmini içeren topluluk sınıflandırıcılar yoluyla doğruluklarının artırılması hedeflenmektedir (Wolpert, 1992).

3.7. Performans Değerlendirme Metrikleri

Bu araştırma bağlamında, önerilen hibrit modellerin ve karşılaştırma amacıyla kullanılan transfer öğrenme yöntemlerinin performanslarını analiz edebilmek için genellikle karışıklık matrisi kullanılmaktadır. Veri setindeki örneklere ait gerçek sınıf etiketleri ile kullanılan modellerin tahmin etiketlerine ilişkin, doğru ve yanlış sınıflandırma sayılarını gösteren bir tablo şeklinde sunulmaktadır.

Tablo 3.2. Karışıklık matrisi gösterimi

Gerçek/Tahmin	Çatlamış	Normal
Çatlamış	True Pozitif (TP)	False Pozitif (FP)
Normal	False Negatif (FN)	True Negatif (TN)

Burada;

TP (True Pozitif): Gerçek sınıf etiketleri Çatlamış olan görüntülerin kullanılan model tarafından kaçının doğru tahmin edildiğini ifade eder.

TN (True Negatif): Gerçek sınıf etiketleri Normal olan görüntülerin kullanılan model tarafından kaçının doğru tahmin edildiğini ifade eder.

FP (False Pozitif): Gerçek sınıf etiketleri Normal olan görüntülerin kullanılan model tarafından kaçının Çatlak olarak tahmin edildiği ifade eder.

FN (False Negatif): Gerçek sınıf etiketleri Çatlamış olan görüntülerin kullanılan model tarafından kaçının Normal olarak tahmin edildiği ifade eder.

Çalışma kapsamında kullanılan modellerin performanslarını analiz etmek ve değerlendirmek amacıyla aşağıdaki dört metrik kullanılmıştır (Bohmrah & Kaur, 2021).

$$Başarı = \frac{TP + TN}{TP + TN + FN + FP} \quad (3.4)$$

$$Kesinlik = \frac{TP}{TP + FP} \quad (3.5)$$

$$Hatırlatma = \frac{TP}{TP + FN} \quad (3.6)$$

$$F - Ölçütü = 2 * \frac{Kesinlik * Hatırlatma}{Kesinlik + Hatırlatma} \quad (3.7)$$

4. ARAŞTIRMA BULGULARI

Bu tez çalışmasında önerilen hibrit modelin başarısını ortaya koymak amacıyla öncelikle TÖ modellerinin doğrudan sınıflandırıcı olarak kullanıldığı uygulamalar yapılmıştır. Daha sonra önerilen yöntem kapsamında, TÖ modellerinin öz nitelikleri bir araya getirilerek İstifleme, Yumuşak ve Katı Oylama topluluk sınıflandırıcıların kullanıldığı ayrı bir uygulamalar gerçekleştirilmiştir. Uygulamaların tümünde kullanılan sınıflandırıcılarla, oksitlenmiş (Çatlak) ve oksitlenmemiş (Normal) lastikler tahmin edilmeye çalışılmaktadır.


Tablo 3.3.'da TÖ modellerinin doğrudan kullanıldığı ilk uygulamalara ilişkin eğitim ve test veri setleri üzerinde elde edilmiş başarı ölçütlerinin değerleri sunulmuştur. Bu uygulamalarda en yüksek eğitim ve test doğruluk değerleri sırasıyla 91,89% (Kesinlik: 92,11%, Duyarlılık: 91,66%, f1-ölçütü: 91,82) ve 70,77% (Kesinlik: 74,22%, Duyarlılık: 75,61%, f1-ölçütü: 70,68) ResNet50V2 TÖ modeli ile elde edilmiştir. Diğer taraftan en düşük başarı değerleri ise eğitim ve test veri setleri için sırasıyla 72,69% ve 56,31% ile VGG16 TÖ modeline ait uygulamada elde edilmiştir.

Tablo 3.3. TÖ modellerinin eğitim ve test başarı ölçüt değerleri.

Model İsmi	Eğitim (%)				Test (%)			
	Doğ.	Kes.	Duy.	f1-öl.	Doğ.	Kes.	Duy.	f1-öl.
Xception	89,05	90,41	88,43	88,79	61,23	71,65	69,21	61,04
NASNet	91,18	91,4	90,94	91,09	66,15	71,79	72,04	66,15
MobileNet	87,2	88,41	86,58	86,91	57,54	67,1	65,18	57,32
DenseNet169	86,91	89,11	86,09	86,49	59,38	71,45	67,98	59,01
DenseNet201	90,9	91,2	90,61	90,8	68,92	74,24	74,77	68,91
VGG16	72,69	74,03	73,41	72,61	56,31	54,79	55,18	54,49
InceptionV3	88,19	88,39	87,93	88,08	65,54	71,48	71,56	65,54
ResNet50V2	91,89	92,11	91,66	91,82	70,77	74,22	75,61	70,68
ResNet101V2	90,9	91,8	90,41	90,73	63,08	71,07	70,05	63,03

Aşağıda Şekil 3.13'de en başarılı TÖ olan ResNet50V2 modeline ait eğitim ve test karışıklık matrisleri gösterilmiştir. Şekil 3.13. (a)'da eğitim veri setine ilişkin karmaşıklık matrisinde görüldüğü gibi 327 çatlak lastik görüntüsünden 289'u doğru 38'i yanlış tahmin edilmiştir. Normal lastik görüntülerinin ise 357'si doğru 19'u ise yanlış (toplamda 376) tahmin edildiği görülmektedir. Şekil 3.13. (b)'de test veri setine ilişkin karmaşıklık matrisinde görüldüğü gibi 210 çatlak lastik görüntüsünden 124'i doğru

86'sı ise yanlış tahmin edilmiştir. Normal lastik görüntülerinin ise 106'sı doğru 9'u ise yanlış (toplamda 115) tahmin edildiği görülmektedir.




Şekil 3.13. ResNet50V2 TÖ eğitim ve test karmaşıklık matrisleri

Tablo 3.4.'de.'de CTLDF+EnC isimli önerilen hibrit modelin test veri seti üzerinde elde ettiği başarı değerleri her bir topluluk sınıflandırıcı için ayrı ayrı sunulmuştur. Tabloda görüldüğü gibi tüm TÖ modellerinin derin öznetelikleri topluluk sınıflandırıcılara uygulandığında en yüksek başarı 76,92% doğruluk (Kesinlik: 79,10%, Duyarlılık: 81,36%, f1-ölçütü: 76,75) ile İstifleme topluluk sınıflandırıcılı hibrit modelde (CTLDF+EnC (İstifleme)) elde edilmiştir. Yumuşak CTLDF+EnC (Yumuşak) ve Katı CTLDF+EnC (Katı) oylama yöntemlerine ait hibrit modellerde ise sırasıyla 74,15% (Kesinlik: 77,26%, Duyarlılık: 79,02%, f1-ölçütü: 74,05) ve 72,92% (Kesinlik: 76,60%, Duyarlılık: 78,06%, f1-ölçütü: 72,85) başarı değerleri elde edilmiştir. Topluluk sınıflandırıcıların tümü eğitim veri seti üzerinde 100% başarı oranına ulaşmışlardır.

Tablo 3.4. CTLDF+EnC tabanlı Topluluk sınıflandırıcı performans değerleri.

Model	Eğitim (%)				Test (%)			
	Doğ.	Kes.	Duy.	f1-öl.	Doğ.	Kes.	Duy.	f1-öl.
CTLDF+EnC (İstifleme)	100	100	100	100	76,92	79,1	81,36	76,75
CTLDF+EnC (Yumuşak)	100	100	100	100	74,15	77,26	79,02	74,05
CTLDF+EnC (Katı)	100	100	100	100	72,92	76,6	78,06	72,85

Aşağıda Şekil 3.14.'de her bir topluluk sınıflandırıcıya ait test veri seti karmaşıklık matrisleri görülmektedir. Eğitim veri seti başarıları 100% olduğundan ayrıca sunulmamıştır. Şekil 3.14. (a)'da görüldüğü gibi CTLDF+EnC (İstifleme) modelinde, çatlamış lastik görüntülerinin 135'i doğru 75'i yanlış tahmin edilmiştir. Normal lastik görüntülerinin ise 111'i doğru 4'ü yanlış tahmin edilmiştir. Şekil 3.14. (b)'de CTLDF+EnC (Yumuşak) ve Şekil 3.14. (c)'de CTLDF+EnC (Katı) modelleri için görüldüğü gibi çatlamış lastik görüntülerinin doğru/yanlış tahmin değerleri sırasıyla 134/76 ve 128/82 olarak elde edilmiştir. Normal lastik görüntülerinin doğru/yanlış tahmin sonuçları ise sırasıyla 111/4 ve 110/5 olarak elde edilmiştir.



Şekil 3.14. Topluluk sınıflandırıcı test karmaşıklık matrisleri

Çalışma kapsamında önerilen TÖ modellerinin derin özniteliklerini kullanan hibrit modellerin sınıflandırma başarılarını ne ölçüde arttırdığı ortaya koymak ve önerilen derin öznitelikler temelli modellerin avantajını daha açık göstermek için Tablo 3.5 oluşturulmuştur. Tabloda, TÖ Model (TÖM) sütunu topluluk sınıflandırıcı kullanmadan

doğrudan TÖ modellerle elde edilen doğruluk değerlerini ve sonraki sütunlar TÖ modellerden elde edilen tüm öznitelikler kullanılarak İstifleme Hibrit Model (İHM), Yumuşak oylama Hibrit Model (YHM) ve Katı oylama Hibrit Model (KHM) topluluk sınıflandırıcılarla elde edilen sırasıyla test doğruluk değerlerini ve iyileştirme miktarlarını göstermektedir. Tablo 3.5.'de görüldüğü gibi çalışma kapsamında önerilen İHM, YHM ve KHM Topluluk sınıflandırıcıların tamamı TÖ modellerinin başarı ölçütünün üzerine çıkarak ve daha yüksek doğru tahmin yapılmasını sağladıkları görülmektedir.

Tablo 3.5. Hibrit modellerin test başarılarının iyileştirme miktarlarının karşılaştırması.

Model	İyileştirme Farkı (%)			
	TÖM	İHM	YHM	KHM
Xception	61,23	15,69	12,92	11,69
NASNet	66,15	10,77	8	6,77
MobileNet	57,54	19,38	16,61	15,38
DenseNet169	59,38	17,54	14,77	13,54
DenseNet201	68,92	8	5,23	4
VGG16	56,31	20,61	17,84	16,61
InceptionV3	65,54	11,38	8,61	7,38
ResNet50V2	70,77	6,15	3,38	2,15
ResNet101V2	63,08	13,84	11,07	9,84

Tablo 3.5.'de görüldüğü gibi en İHM, YHM ve KHM ile elde edilen doğruluk değerleri olan sırasıyla 76,92%, 74,15% ve 72,92% ile TÖ modellerin doğruluk değerleri farkları incelendiğinde en yüksek iyileştirme farklarının sırasıyla 20,61%, 17,84%, 16,61% olarak VGG16 TÖ modeli ile oluştuğu görülmektedir. Diğer taraftan en düşük iyileştirme farklarının ise sırasıyla 6,15%, 3,38% ve 2,15% olarak ResNet50V2 TÖ modeli ile gerçekleştiği görülmektedir. TÖ modellerin doğrudan kullanıldığı ilk grup uygulamalarda en yüksek başarının elde edildiği model ResNet50V2 olduğunda iyileştirme farkları düşük çıkmıştır. Tablo 3.5.'de görüldüğü gibi önerilen İHM, YHM ve KHM hibrit modelleri ResNet50V2'nin doğruluğunu önemli ölçüde arttırmıştır.

5. TARTIŞMA

Genel olarak araç sürücüleri lastik diş derinliği ve lastik hava basıncının öneminin farkında olmakla birlikte birçoğu lastik oksidasyonunun oluşturabileceği risklerin farkında değildir. Oysa lastik oksidasyonu ve buna bağlı çatlaklar sürüş güvenliğini etkileyen önemli riskler barındırmaktadırlar. Bu amaçla bu tez çalışmasında, ön-eğitilmiş evrimsel sinir ağı modeli türlerinden transfer öğrenme yöntemleri kullanılarak lastiklerde çatlakların tespit edilmesi amaçlanmaktadır.

Dünya Sağlık Örgütüne (DSÖ) göre dünyada her yıl çok sayıda ölümcül trafik kazası olmakta ve bu kazaların büyük çoğunluğu lastik kusurlarından kaynaklanmaktadır (Erdogan, 2009). Bu kusurlarının araç kullanıcıları tarafından manuel tespitinin zorlukları ve hataya açık olması göz önüne alındığında yapay zekâ destekli sistemler bu noktada oldukça faydalı araçlardır. Bu amaçla bu çalışmada lastik kusurlarının tespitinin araç kullanıcıları tarafından kolaylıkla ve hızlı bir şekilde yapılmasına olanak tanıyacak yapay zekâ destekli model önerilmektedir. Çalışma kapsamında önerilen modelde, lastik görüntülerinden ön-eğitilmiş dokuz TÖ model kullanılarak her birinden elde edilmiş derin öznitelikler biraya getirilerek topluluk sınıflandırıcılara uygulanmıştır. Topluluk sınıflandırıcı olarak kullanılan İstifleme, Yumuşak ve Katı oylama yöntemleri elde edilmiş olan derin özniteliklere göre seçilmiş en iyi beş klasik MÖ algoritmasını kullanmaktadırlar. Dolayısıyla bu çalışmada CTLDF+EnC (İstifleme), CTLDF+EnC (Yumuşak) ve CTLDF+EnC (Katı) olmak üzere derin özniteliklere ve topluluk sınıflandırıcılara dayalı üç farklı hibrit model önerilmektedir.

Literatürde lastik kusurlarının tespitine yönelik yapılan çalışmalarda amaç kontrolün tahribatsız bir şekilde yapılmasıdır. Tahribatsız muayene (NDT, Nondestructive testing) teknikleri arasında, lazer makaslama (Cai & He, 2012), ultrasonik yöntemler (Dos Reis & Warmann, 1996), elektromanyetik darbe (Roemer & Ida, 1991) gibi yöntemler sayılabilir. Bu yöntemler yüzey veya iç kusurlarını test etmek için yapısını kontrol amaçlı kullanılsa da bu yöntemler pahalı ve uygulaması zor olup uygun yöntemler değildirler. Bunun yanında gerek geleneksel görsel tespit yöntemlerine dayalı olan çalışmalar (Guo et al., 2016; Zhao & Qin, 2018) gerekse derin öğrenme yöntemlerine dayalı çalışmalar (R. Wang et al., 2019; Zheng et al., 2020) genelde X-Ray görüntüler kullanılan çalışmalardır. Ayrıca bu çalışmaların neredeyse tamamı üretim bandına yönelik çalışmalardır. Aksine bu çalışmada ise kullanıma bağlı yıpranmış ya da

oksitlenmiş lastik kusurlarının tespiti amaçlanmaktadır. Ayrıca buradaki çalışmada pahalı yöntemler ve düşük kontrast ve parlaklık özelliklerine sahip X-Ray görüntüler yerine doğrudan dijital kameraya sahip herhangi bir dijital cihaz ile elde edilmiş görüntüler kullanıldığından daha ucuz ve etkin bir yapı önerilmektedir.

Literatürde yapılmış çalışmaların büyük çoğunluğu endüstriyel kullanım amacıyla X-Ray görüntülerle gerçekleştirilmiştir. Aksine buradaki çalışmada kullanılan görüntüler herhangi bir sayısal kamerayla elde edilebilecek sayısal lastik görüntülerinden oluşmaktadır. Literatürde sayısal görüntülerin kullanıldığı çalışmalar neredeyse yok denecek kadar çok az olup çalışmaların büyük çoğunluğunda X-Ray görüntüler kullanılmıştır. Bu tez çalışmasına benzer şekilde elde edilmiş görüntülerin sadece Lin (Lin, 2023) tarafından yapılan çalışmada kullanıldığı görülmektedir. Ancak bu çalışmaya ait veri setine ulaşamadığı ve paylaşılmadığı için burada önerilen hibrit modellerin başarısı bu veri seti üzerinde denenememiştir. Dolayısıyla her çalışmanın kendine özgü veri setlerine sahip oldukları göz önüne alındığında modellerin başarılarının veri seti bağımlı olduğu değerlendirilmektedir. Ancak Tablo 3.3'da yer alan bilinen genel TÖ modelleri ile yapılan uygulamalar ile kıyaslama yapıldığında önerilen hibrit modellerin başarı ölçütlerini önemli ölçüde arttırdıkları görülmektedir (bakınız Tablo 3.5.).

Bu çalışmada önerilen sistemde en yüksek test doğruluk değerleri CTLDF+EnC (İstifleme) hibrit modeli kullanılarak 76,92% (Kes.: Kesinlik: 79,1%, Duy.: 81,36%, f1-öl.: 76,75) olarak elde edilmiştir. Diğer hibrit modeller CTLDF+EnC (Yumuşak) ve CTLDF+EnC (Katı) mimarileri test veri seti doğruluk değerleri sırasıyla 74,15% (Kes.: Kesinlik: 77,26%, Duy.: 79,02%, f1-öl.: 74,05) ve 72,92% (Kes.: Kesinlik: 76,6%, Duy.: 78,06%, f1-öl.: 72,85) olarak elde edilmiştir. Dolayısıyla önerilen hibrit yaklaşımın kabul edilebilir makul bir doğruluğa sahip olduğu söylenebilir.

Tez çalışması kapsamında önerilen hibrit modellerin, Tablo 3.3 ve Tablo 3.5.'de görüldüğü gibi TÖ modellerin doğrudan kullanıldığı uygulamalarda elde edilen performanslara kıyasla daha başarılı oldukları ve tahmin doğruluklarının artmıştır. Buna göre Tablo 3.3'da görüldüğü gibi TÖ modelleri doğrudan kullanıldığında en yüksek doğruluk ResNet50V2 ile 70,77% olarak elde edilmiştir. Tablo 3.4.'de en yüksek doğruluk değerinin CTLDF+EnC (İstifleme) yöntemiyle elde edildiği ve ResNet50V2'e kıyasla doğruluk değerini +6,15% arttırdığı görülmektedir. Tablo 3.3. ve Tablo 3.5.'de görüldüğü gibi topluluk TÖ modellerinin tamamı önerilen hibrit sınıflandırıcılardan daha düşük doğruluk değerlerine sahip olup önerilen hibrit sistemin başarıyı önemli ölçüde

arttırdığı söylenebilir. Sonuç olarak, önerilen hibrit modellerin lastik problemlerinin tespitinde TÖ modellerinden daha başarılı olduğu ve makul seviyede bir başarıya sahip olduğu görülmektedir.

Son olarak bu çalışmayı özgün kılan temel katkılar şu şekilde sıralanabilir. Öncelik bu çalışmada a) lastik görüntülerinden kontrol yapılmasına olanak sağlayan CTLDF+EnC isimli özgün ve yeni bir mimari önerilmektedir, b) mimari TÖ modellerinin derin özniteliklerini ve klasik ML yöntemlerini topluluk sınıflandırıcı dahilinde kullanma gibi güçlü yönleri sahiptir, son olarak c) var olan yöntemlerden farklı olarak pahalı ve uygulaması zor bir görüntüleme yöntemleri yerine oldukça ucuz ve kolay bir görüntüleme tekniği ile çalışmaktadır.



6. SONUÇ

Bu çalışmada, lastik kusurlarının tespiti amacıyla TÖ yöntemlerinden elde edilen derin öznitelikleri ve klasik makine öğrenme yöntemlerini topluluk sınıflandırıcı dahilinde kullanan iki temel katmana sahip CTLDF+EnC isimli yeni ve özgün bir mimari önerilmektedir.

Literatürde yer alan diğer çalışmaların aksine burada önerilen mimaride uygulaması zor ve pahalı görüntüleme teknikleri yerine normal bir dijital kamera kullanılarak elde edilebilen kullanımı kolay ve ucuz sayısal görüntüler kullanılmıştır. Ayrıca bu çalışmada literatürdeki üretim bandında oluşan kusurların tespitine yönelik yapılan çalışmalardan farklı olarak lastiklerin kullanım ömrüne bağlı oluşan oksitlenme, eskime vb. problemler tespit edilmeye çalışılmıştır. Lastik görüntülerinin özniteliklerini elde etmek için ön-eğitilmiş 9 TÖ model kullanılmıştır. Bu 9 TÖ ait öznitelikler önce EAS ile indirgenmiş ve daha sonra bir araya getirilmiştir. Bu 9 TÖ ait birleştirilmiş derin öznitelikler daha sonra klasik makine öğrenme modellerinin yer aldığı bir topluluk sınıflandırıcıya girilmiştir. Topluluk sınıflandırıcı olarak İstifleme, Yumuşak ve Katı oylama yöntemleri kullanılmıştır. Çalışmada kullanılan veri seti üzerinde yapılan uygulamalarda, önerilen yeni mimarinin literatürde yer alan diğer modellere kıyasla tatmin edici bir başarı elde ettiği görülmüştür.

Çalışma kapsamında elde edilen sonuçlar, önerilen mimarinin oksitlenmiş/yıpranmış ve normal lastikleri başarılı bir şekilde tespit edebildiğini ve literatürdeki alternatiflere kıyasla maliyet ve uygulanabilirlik açılarından oldukça avantajlı olduğunu ortaya koymuştur.

KAYNAKLAR

- Ashwinkumar, S., Rajagopal, S., Manimaran, V., & Jegajothi, B. (2022). Automated plant leaf disease detection and classification using optimal MobileNet based convolutional neural networks. *Materials Today: Proceedings*, 51, 480–487.
- Bohmrah, M. K., & Kaur, H. (2021). Classification of Covid-19 patients using efficient fine-tuned deep learning DenseNet model. *Global Transitions Proceedings*, 2(2), 476–483.
- Cai, C., & He, L. (2012). Improved Mach–Zehnder interferometer-based shearography. *Optics and Lasers in Engineering*, 50(12), 1699–1705.
- Chen, Y., Yi, H., Liao, C., Huang, P., & Chen, Q. (2021). Visual measurement of milling surface roughness based on Xception model with convolutional neural network. *Measurement*, 186, 110217.
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1251–1258.
- Das, D., Santosh, K. C., & Pal, U. (2020). Truncated inception net: COVID-19 outbreak screening using chest X-rays. *Physical and Engineering Sciences in Medicine*, 43, 915–925.
- Dos Reis, H. L. M., & Warmann, K. A. (1996). Acousto-ultrasonic non-destructive evaluation of fatigue damage in steel-belted radial tires. *International Journal of Fatigue*, 3(18), 216.
- Erdogan, S. (2009). Explorative spatial analysis of traffic accident statistics and road mortality among the provinces of Turkey. *Journal of Safety Research*, 40(5), 341–351.
- Geurts, P., Ernst, D., & Wehenkel, L. (2006). Extremely randomized trees. *Machine Learning*, 63(1), 3–42.
- Guo, Q., Zhang, C., Liu, H., & Zhang, X. (2016). Defect detection in tire X-ray images using weighted texture dissimilarity. *Journal of Sensors*, 2016.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Identity mappings in deep residual networks. *European Conference on Computer Vision*, 630–645.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv Preprint arXiv:1704.04861*.
- Huang, G., Liu, S., Van der Maaten, L., & Weinberger, K. Q. (2018). Condensenet: An efficient densenet using learned group convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2752–2761.

- Huang, G., Liu, Z., van der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 4700–4708.
- Huang, J., & Kingsbury, B. (2013). Audio-visual deep learning for noise robust speech recognition. *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*, 7596–7599.
- Kaya, Y., Kuncan, F., & Tekin, R. (2022). A new approach for congestive heart failure and arrhythmia classification using angle transformation with LSTM. *Arabian Journal for Science and Engineering*, 47(8), 10497–10513.
- Kong, L., & Cheng, J. (2022). Classification and detection of COVID-19 X-Ray images based on DenseNet and VGG16 feature fusion. *Biomedical Signal Processing and Control*, 77, 103772.
- Kumar, A. (2008). Computer-vision-based fabric defect detection: A survey. *IEEE Transactions on Industrial Electronics*, 55(1), 348–363.
- Li, Y., Fan, B., Zhang, W., & Jiang, Z. (2021). TireNet: A high recall rate method for practical application of tire defect type classification. *Future Generation Computer Systems*, 125, 1–9.
- Lin, S.-L. (2023). Research on tire crack detection using image deep learning method. *Scientific Reports*, 13(1), 8027.
- Liu, J., Capurro, D., Nguyen, A., & Verspoor, K. (2022). “Note Bloat” impacts deep learning-based NLP models for clinical prediction tasks. *Journal of Biomedical Informatics*, 133, 104149.
- Lu, J., Behbood, V., Hao, P., Zuo, H., Xue, S., & Zhang, G. (2015). Transfer learning using computational intelligence: A survey. *Knowledge-Based Systems*, 80, 14–23.
- Lu, S.-Y., Wang, S.-H., & Zhang, Y.-D. (2020). A classification method for brain MRI via MobileNet and feedforward network with random weights. *Pattern Recognition Letters*, 140, 252–260.
- Michele, A., Colin, V., & Santika, D. D. (2019). Mobilenet convolutional neural networks and support vector machines for palmprint recognition. *Procedia Computer Science*, 157, 110–117.
- Nan, Y., Ju, J., Hua, Q., Zhang, H., & Wang, B. (2022). A-MobileNet: An approach of facial expression recognition. *Alexandria Engineering Journal*, 61(6), 4435–4444.
- Ngan, H. Y. T., Pang, G. K. H., & Yung, N. H. C. (2011). Automated fabric defect detection—A review. *Image and Vision Computing*, 29(7), 442–458.
- Nigam, B., Nigam, A., Jain, R., Dodia, S., Arora, N., & Annappa, B. (2021). COVID-19: Automatic detection from X-ray images by utilizing deep learning methods. *Expert Systems with Applications*, 176, 114883.

- Özaydın, B., & Tekin, R. (2023). A Hybrid Model Based on Deep Features and Ensemble Learning for the Diagnosis of COVID-19: DeepFeat-E. *Turkish Journal of Science and Technology*, 18(1), 183–198.
- Purwins, H., Li, B., Virtanen, T., Schlüter, J., Chang, S.-Y., & Sainath, T. (2019). Deep learning for audio signal processing. *IEEE Journal of Selected Topics in Signal Processing*, 13(2), 206–219.
- Rim, B., Sung, N.-J., Min, S., & Hong, M. (2020). Deep learning in physiological signal data: A survey. *Sensors*, 20(4), 969.
- Roemer, L. E., & Ida, N. (1991). Location of wire position in tyre belting using Bayesian analysis. *NDT & E International*, 24(2), 95–97.
- Siegel, J. (2021, September 9). *Oxidized and non-oxidized tire sidewall and tread images*. Harvard Dataverse. <https://doi.org/https://doi.org/10.7910/DVN/Z3ZYLI>
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv Preprint arXiv:1409.1556*.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). Going deeper with convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1–9.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2818–2826.
- Tung, H., & Tekin, R. (2022). New Feature Extraction Approaches Based on Spatial Points for Visual-Only Lip-Reading. *Traitement Du Signal*, 39(2).
- Wang, D., Su, J., & Yu, H. (2020). Feature extraction and analysis of natural language processing for deep learning English language. *IEEE Access*, 8, 46335–46345.
- Wang, R., Guo, Q., Lu, S., & Zhang, C. (2019). Tire defect detection using fully convolutional network. *IEEE Access*, 7, 43502–43510.
- Wang, S.-H., Xie, S., Chen, X., Guttery, D. S., Tang, C., Sun, J., & Zhang, Y.-D. (2019). Alcoholism identification based on an AlexNet transfer learning model. *Frontiers in Psychiatry*, 10, 205.
- Wolpert, D. H. (1992). Stacked generalization. *Neural Networks*, 5(2), 241–259.
- Wu, S., Zhong, S., & Liu, Y. (2018). Deep residual learning for image steganalysis. *Multimedia Tools and Applications*, 77, 10437–10453.
- Yang, X., Zhang, Y., Lv, W., & Wang, D. (2021). Image recognition of wind turbine blade damage based on a deep learning model with transfer learning and an ensemble learning classifier. *Renewable Energy*, 163, 386–397.

- Yuan, J., Liu, H., Liu, W., Wang, F., & Peng, S. (2022). A method for melt pool state monitoring in laser-based direct energy deposition based on DenseNet. *Measurement*, 195, 111146.
- Zhang, Y., Lefebvre, D., & Li, Q. (2015). Automatic detection of defects in tire radiographic images. *IEEE Transactions on Automation Science and Engineering*, 14(3), 1378–1386.
- Zhao, G., & Qin, S. (2018). High-precision detection of defects of tire texture through X-ray imaging based on local inverse difference moment features. *Sensors*, 18(8), 2524.
- Zheng, Z., Zhang, S., Yu, B., Li, Q., & Zhang, Y. (2020). Defect inspection in tire radiographic image using concise semantic segmentation. *IEEE Access*, 8, 112674–112687.
- Zhou, Z.-H. (2012). *Ensemble methods: foundations and algorithms*. CRC press.
- Zhu, Y., JiaYI, H., Li, Y., & Li, W. (2022). Image identification of cashmere and wool fibers based on the improved Xception network. *Journal of King Saud University-Computer and Information Sciences*, 34(10), 9301–9310.
- Zoph, B., Vasudevan, V., Shlens, J., & Le, Q. V. (2018). Learning transferable architectures for scalable image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 8697–8710.