



AHŞAP HAM MADDELERDE YÜZEY HATASINI BELİRLEMEK İÇİN GÖRÜNTÜ İŞLEME TABANLI KALİTE KONTROL SİSTEMİ

Yaren ÇELİK^{1*}, Berna DENGİZ¹, Selda GÜNEY²

¹ Başkent Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Ankara, Türkiye

² Başkent Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, Ankara, Türkiye

Anahtar Kelimeler

Derin Öğrenme,
Görüntü İşleme,
Ahşap Kusur Tespiti,
Evrşimsel Sinir Ağları,
Sınıflandırma.

Öz

Günümüzde ahşap ham madde malzemeleri birçok endüstride kullanılmaktadır. Ahşap ham madde üzerinde gözden kaçan kusurlar, son ürünü görsel açıdan ve dayanıklılık bakımından etkileyerek satışını engelleyebilir. Kusurlu ham maddeler üzerinde elle veya görsel kontrol zor ve yanıltıcı olabilir. Sürekli gelişen dijital teknoloji ve akıllı sistemler sayesinde, kalite kontrol için otomasyon sistemleri geliştirilmektedir. Böylece üretimin erken aşamalarında kusurlar tespit edilebilmektedir. Son ürünün kusurlu veya hatalı olması engellenebildiğinde iş gücü, malzeme ve zaman kayıpları önlenilecek, maliyetler düşürülebilecektir. Bu çalışmada, özel bir kamera sistemi ile elde edilen görüntüler, görüntü işleme temelli Derin Öğrenme (DÖ) yöntemlerinde kullanılarak ahşap ham maddenin kusurlu olup olmadığı ayrımı yapılmaktadır. Kusurların tespitinde kullanılacak model ayırım odaklı bir yöntem olan Evrşimsel Sinir Ağı (ESA) ile geliştirilmiş olup tercih edilen bir yöntemdir. Çalışmada, ShuffleNet, AlexNet, GoogleNet gibi ESA mimarileri denenmiş ve en uygun mimari belirlenmiştir. Çalışmalar sonucunda, ESA mimarileri arasında kusurlu ve kusursuz ahşap ürünlerini belirlemek için kullanılan başarılı yöntemler olan MobileNet, DenseNet ve Inception mimarilerinin, kalite kontrol sistemleri için daha yüksek doğruluk oranları ile sonuçlandığı görülmüştür. En iyi sonuç ise, Inception-V3 mimarisi ile elde edilmiştir ve test doğruluğu %88,41 olarak belirlenmiştir.

IMAGE PROCESSING-BASED QUALITY CONTROL SYSTEM TO DETERMINE THE SURFACE DEFECT IN WOODEN RAW MATERIALS

Keywords

Deep Learning,
Image Processing,
Wood Defect Detection,
Convolutional Neural Network,
Classification.

Abstract

In modern industries, wood raw materials serve a multitude of purposes across various sectors. Undetected flaws within these materials can significantly impact products, affecting both their visual appeal and durability, leading to compromised marketability. Manual and visual inspection of flawed raw materials is a complex process prone to errors in judgment. The rapid evolution of digital technologies has spurred the creation of automated systems designed for precise quality assessments. This progress enables the early identification of defects during production, thereby preventing the occurrence of defective or substandard end-products. Consequently, this approach reduces labor, material, and time wastage, effectively cutting down associated costs. The present study focuses on distinguishing between defective and intact raw materials using images obtained through a specialized camera system. Deep learning techniques in image processing are employed for this purpose, with a particular emphasis on the Convolutional Neural Network (CNN), a classification method chosen for defect detection. A range of CNN architectures, including ShuffleNet, AlexNet, and GoogleNet, were tested, and the most effective one was identified. The results of these experiments demonstrate that within the realm of CNNs, architectures like MobileNet, DenseNet, and Inception have proven highly successful, leading to improved accuracy in quality control systems. Notably, the Inception-V3 architecture emerges as the top performer, achieving a test accuracy of 88.41%.

Alıntı / Cite

Çelik, Y., Dengiz, B., Güney, S., (2023). Ahşap Ham Maddelerde Yüzey Hatasını Belirlemek İçin Görüntü İşleme Tabanlı Kalite Kontrol Sistemi, Mühendislik Bilimleri ve Tasarım Dergisi, 11(4), 1365-1382.

Yazar Kimliği / Author ID (ORCID Number)

Y. Çelik, 0000 - 0003 - 4894 - 3780
B. Dengiz, 0000-0002-2806-3308
S. Güney, 0000-0002-0573-1326

Makale Süreci / Article Process

Başvuru Tarihi / Submission Date	05.02.2023
Revizyon Tarihi / Revision Date	25.08.2023
Kabul Tarihi / Accepted Date	11.09.2023
Yayın Tarihi / Published Date	30.12.2023

* İlgili yazar / Corresponding author: yarencelik@baskent.edu.tr, +90-312-246-6666/4110.

IMAGE PROCESSING-BASED QUALITY CONTROL SYSTEM TO DETERMINE THE SURFACE DEFECT IN WOODEN RAW MATERIALS

Yaren ÇELİK^{1†}, Berna DENGİZ², Selda GÜNEY³

¹Başkent University, Faculty of Engineering, Department of Industrial Engineering, Ankara, Türkiye

²Başkent University, Faculty of Engineering, Department of Electrical and Electronics Engineering, Ankara, Türkiye

Highlights

- The present study aims to classify defective and non-defective wooden raw materials.
- Images obtained using a specialized camera system were utilized through deep learning techniques in this classification.
- A range of CNN architectures were tested to identify the most effective ones.
- The Inception-V3 architecture became as the top performer, achieving 88.41% test accuracy.

Purpose and Scope

Wooden raw materials have an important role in many modern industries. Undetected defects within these materials impact both the visual appeal and durability of the final product. For this reason, manual and visual inspections are applied in the manufacturing processes. Manual and visual inspection of defective raw materials is a complex process due to it is time-consuming and contains subjective decisions. As soon as the development of digital technologies this process is automated making it possible to identify defects in the products in the early production stage. We aimed to propose a model using deep learning that will automate this process.

Design/methodology/approach

The model to be used in detecting defects was developed with Convolutional Neural Network (ESA), which is a discrimination-oriented method. In the study, ESA architectures such as MobileNet, DenseNet, Inception, ShuffleNet, AlexNet, and GoogleNet were tested and the most suitable architecture was determined. As a result of the studies, it has been seen that MobileNet, DenseNet, and Inception architectures, which are successful methods used to identify defective and perfect wood products among ESA architectures, result in higher accuracy rates for quality control systems. The best result was obtained with the Inception-V3 architecture and the test accuracy was determined as 88.41%.

Findings

For the data set used in this study, preliminary studies were carried out by transfer learning with ready-made DA architectures, and their performances were examined. Finally, an ESA was designed and its results on different parameters were examined. Although the number of layers is reduced in the designed architecture, a lot of data is needed to train the deep network structure from scratch. At the same time, the designed ESA affects learning due to its lower number of layers compared to other architectures that achieve high success in resources. In the studies conducted, the best results were obtained with the Inception-V3 architecture. With this architecture, verification accuracy was achieved as 82.91% and test accuracy as 88.41%. Additionally, MobileNet-V2 and DenseNet-201 architectures have been shown to give promising results.

Research limitations/implications (if applicable)

According to the source research, recent studies carried out to determine the faulty surfaces on the wooden image are shown in this study. However, a direct comparison cannot be made in terms of success because a different data set is used in each study when the studies in this field are examined. According to the results, it is seen that high success can be achieved with this new and original data set for the problem addressed in this study. On the other hand, it is seen that the targets are different for each data set used in the studies presented in the source research. For this reason, a comparison with existing studies in the literature could not be made in this study. It has been seen that the results with an accuracy of over 80% for different success criteria in welding research are interpreted as promising results for studies on wooden images, and the idea has been formed that this success can be improved in future studies.

Originality

This study contributed to the literature by obtaining a model that will distinguish error-free for the special data set obtained by the institute at Instituto Tecnológico de Informática (ITI) in Spain to be used for quality control purposes on the production line. By increasing this data set, the effects on performance can be examined by taking different architectures and different parameters into account in future studies. However, classification performances can be compared by extracting features from different architectures. Additionally, the effects of image enhancement and augmentation techniques on deep networks can be observed.

[†] Corresponding author: yarencelik@baskent.edu.tr, +90-312-246-6666/4110.

1. Giriş (Introduction)

Kalite, bir ürün veya hizmetin belirlenen ya da olabilecek ihtiyaçlarını karşılayan ve tüketicinin isteklerine cevap veren özelliklerinin toplamıdır. Kalite kontrol ise bu özelliklerin elde edildiği bir sürecin etkinliğini azaltacak veya engelleyecek durumlara karşı önlem olarak koruma anlamına gelmektedir. Temel amacı müşterilerin beklentilerinin ve aynı zamanda firmaların amaçlarının en uygun seviyede karşılanabilmesi için üretim planları oluşturup uygulayarak etkin bir sürekliliğin sağlanmasıdır. Kalite kontrol, bir süreçle ilgilendiği için üretimin her aşamasında olduğu kadar, öncesi ve sonrası faaliyetlerinde de etkili olan geniş bir fonksiyondur. Bu fonksiyon ile sunulan ürünün ve üretim sürecinin belli standartlara sahip olması sağlanmaktadır. Böylece üretilen ürünlere ve üreticilerine olan güven artar. Hızlı ve etkili muayenelerle daha az zarar ve masraf ile süreçler korunabilir.

Kalite kontrol ile üretim sürecinde var olan hataların önceden gözlenmesiyle erken aşamalarda düzeltici önlemler alınarak nihai ürünlerin hatalı olması önlenir. Bu sayede işgücü, ham madde ve/veya yarı mamul, zaman gibi birçok üretim unsurunda israf engellenmiş olur. Geçmişte elle veya gözle yapılan kontroller günümüz teknolojisi ile otomatik hale gelmiştir. Bu nedenle gıdadan tekstile kadar birçok endüstride üreticiler her aşamada otomasyona geçmeyi hedeflemektedirler (Kesici ve Yıldız, 2016).


Ahşap endüstrisinde kullanılan ham maddelerin yapılarındaki ve renklerindeki değişiklikler nedeniyle ortaya çıkan anormallikleri elle ve gözle tespit etmek, el ile etiketlemek oldukça öznel ve zaman alıcı bir iştir. Bu zorluklar nedeniyle, malzeme seçimi karmaşık ve zor bir probleme dönüşmektedir. Son yıllarda bu soruna daha hızlı ve hatasız çözüm üretebilmek için Yapay Zeka (YZ) yöntemlerine başvurulmaktadır.

Bu çalışmada YZ yöntemlerinden biri olan DÖ mimarilerinin kullanıldığı bir sınıflandırma modeli geliştirilerek bir kalite kontrol sistemi içinde kullanılması önerilmiştir. Kurulması önerilen sistem tasarımı Şekil 1'de gösterilerek sistemde kullanılacak cihaz ve çalışma mekanizması hakkında detaylı bilgi Bölüm 2'de verilmiştir. Bu çalışmada geliştirilen sınıflandırma modeli için kullanılan fotoğraflar Instituto Tecnológico de Informática (ITI) araştırma grubunun izni ile kullanılmış ve ilgili araştırma grubunun elde ettiği modele göre daha yüksek performansla sahip bir model elde edilmiştir. Böylece araştırma grubu tarafından oluşturulan kalite kontrol sistemi içinde kullanılacak sınıflandırma modeli olarak bu çalışmada geliştirilen modelin kullanılması önerilmiştir.

Makalenin üçüncü bölümünde bu alanda yapılan çalışmaların derlendiği kaynak araştırmasına yer verilirken dördüncü bölümünde çalışmada kullanılan materyal ve yöntemlere değinilmiştir. Beşinci bölümde deneysel uygulama ve analiz sonuçlarına, altıncı bölümde ise sonuçlar ve tartışmaya yer verilmiştir.

2. Önerilen Kalite Kontrol Sistemi (Proposed Quality Control System)

Önerilen sistem tasarımı Şekil 1'de verilmiştir. Bu sistem tasarımında Instituto Tecnológico de Informática tarafından geliştirilen ZeroGravity3D cihazın veya bir benzerinin kullanılması önerilmiştir. Üretim hattında kontrol edilmesi gereken noktaya bu cihaz yerleştirilir. Hareket eden hat üzerinden ürünler iki lineer robotik kola (mekanizmayı kontrol eden veya hareket ettiren bir tür motorlu kol) gelir. Biri parçayı cihaza doğru fırlatırken diğeri düşen parçayı alır ve hat üzerine bırakır. Bu sırada atılan ürünün kusurlu veya kusursuz olduğunu ayırt etmek için ZeroGravity3D cihazı ile çekilen görüntüler değerlendirilerek sınıflandırılır. Kusurlu kararı verilen ürün kırmızı renkli kutuya, kusursuz kararı verilen ürün yeşil renkli kutuya ayrıştırılır. Bu ayrımı yapmak için hat üzerinde hareketli bir kol bulunmalıdır. Bu kol sayesinde ürünler hat üzerinde ilgili kutulara yönlendirilebilir.



Şekil 1. Kalite kontrol sistem tasarımı (Quality control system design) (Perez-Cortes vd., 2018)

ZeroGravity3D cihazı, endüstriyel görüş sistemlerinde uzmanlaşmış bir Ar-Ge ekibi tarafından, karşılaştıkları gerçek sorunları çözmek amacıyla endüstri ile iş birliği içinde geliştirilmiştir. Makine görüşüne dayanan bu sistem en fazla 30 mm boyutlarında olan her bir parçanın anında 3 boyutlu fotoğraf çekimine, 800 adet/s'de algılamaya ve birden fazla referansla %100 hat içi incelemeye olanak tanımaktadır. Üzerinde bulunan 16 kamera ile bir ürünün yerçekimsiz ortamda 16 farklı açıdan görüntüsü alınabilmektedir. Bu sayede tek bir açıdan kontrol yerine birden fazla açıdan kontrol ile varsa hatalı görüntünün yakalanması sağlanmış olur.

3. Kaynak Araştırması (Literature Survey)

Değişen ve gelişen teknolojiler nedeniyle YZ yöntemlerinin kullanımı, otomotivden savunmaya tıptan eğitime kadar birçok sektörde yaygınlaşmaya başlamıştır. YZ yöntemlerinden biri olan Yapay Sinir Ağları (YSA), ilk defa 1943 yılında McCulloch ve Pitts, (1943) insan beynindeki hücrelerin çalışma şekline esinlenerek beyninin fonksiyonlarına dayalı bir matematiksel model önermesiyle kullanılmaya başlanmıştır. Ardından gelen iki gelişmeyle bugünkü Derin Sinir Ağlarının (DSA) temelleri oluşturulmuştur. İlk gelişme 1975 yılında Fukushima tarafından, beyin fonksiyonları hakkındaki bilgilerden esinlenilerek ilk karmaşık sinir hücresinin kullanılması ve 1980 yılında ise görüntü işleme memeli beyninin görsel sisteminden esinlenilerek çok güçlü bir model mimarisinin ortaya konulması ile yapılmıştır (Fukushima, 1980). Bununla birlikte Rumelhart vd. (1986) yılında tek ve iki katmanlı sinir ağlarında geri yayılım algoritması kullanmıştır. Diğer etkili gelişme ise Hinton vd. (2006) tarafından DSA olarak bilinen bir tür sinir ağını tanımladığı çalışma ile başlamıştır. Bu çalışmada Derin Ağ (DA) katmanları denetimsiz öğrenme metodu kullanılarak eğitilmiştir. Sinir ağlarının bu gelişmesinden sonra makine öğrenmesi teknolojilerine dayalı YZ sistemleri de yaygınlaşmıştır.

Kaynak araştırmasının bundan sonraki kısmı ahşap ürünlerle ilgili yapılan YZ çalışmalarını kapsamakta olup tablo 1'de verilmektedir.

Tablo 1. Kaynak araştırması (Literature survey)

No	Yıl	Yazar	Çalışma	Veri Seti	Sonuçlar
1	2001	O. Silven, M. Niskanen, H. Kauppinen	Wood Inspection with Non-Supervised Clustering	VTT Building Technology tarafından toplamda yaklaşık 900mb veri ve 1000'den fazla etiketli kusurlu görüntü içeren bir dizi çam ağacı pano görüntülerini içermektedir.	Hem iyimser hem de kötümser seçimlerde, sırasıyla %5 ve %2,5, düşük hatadan kurtulma oranı elde edilmiştir.
2	2005	G.A. Ruz, P.A. Estévez	Image Segmentation Using Fuzzy Min-Max Neural Networks for Wood Defect Detection	Şili Üniversitesi veri tabanından on farklı kusur kategorisine sahip 900 adet ahşap pano görüntüleri kullanılmıştır.	Test veri setinde Alan tanıma oranı (The area recognition rate (ARR)) %94,4 olarak elde edilmiştir.
3	2005	Celso A. França, A. Gonzaga	Classification of Wood Plates by Neural Networks and Fuzzy Logic	Etiketli 199 adet test seti kullanılmıştır.	Bu çalışmada, kalem üretiminde kullanılan ahşap levhaların sınıflandırılmasında uygulanan yeni bir yaklaşımda %73,37 düzeyinde doğruluğa ulaşılmıştır.
4	2006	P. Cavalin, L. S. Oliveira, A. L. Koerich, A. S. Britto Jr	Wood Defect Detection Using Grayscale Images and An Optimized Feature Set	Eğitim için iyi ve kusurlu çam kerestesinden elde edilen 400 görüntüden oluşmaktadır.	Destek vektör makineleri ile %98,7 performansına ulaşılmıştır.
5	2009	Si-Y. Wu, Z. Zhang, L. Feng	Statistical Feature Representations for Automatic Wood Defects Recognition Research and Applications	VTT Building Technology tarafından sağlanan toplam 2106 adet (hatasız 1229 ve kusurlu 879 örnek) eğitim seti ve 30 örnekle test seti kullanılmıştır.	%90'nın üzerinde bir tanımlama oranı (identification rate) elde edilmiştir.
7	2012	A. Mahram, Mahrokh G. Shayesteh, S. Jafarpour	Classification Of Wood Surface Defects with Hybrid Usage of Statistical and Textural Features	Beş tür ahşap budağın renkli görüntülerinden oluşan Oulu Üniversitesi ahşap ve düğüm veri tabanı kullanılmıştır. Bu veri tabanında tüm renkli görseller gri seviyeye dönüştürülmüştür.	GLCM veya LBP sırasıyla %94,37 ve %95,78 ile sonuçlanır. Hibrit GLCM+LBP %100 sınıflandırma doğruluğuna ulaşılmıştır.

Tablo 1. Kaynak araştırması (Literature survey) (devam ediyor)

8	2012	S. Mohan, K. Venkatachalapathy	Wood Knot Classification Using Bagging	Dört budak sınıfına sahip 400 adet ahşap budak görüntüsü kullanılmıştır.	Radyal Temel İşlev (Radial Basis Function) ve Torbalı Rastgele orman (Bagging with Random forest) yöntemleri ile %81 sınıflandırma doğruluğuna ulaşılmıştır.
9	2017	K. Kamal, R. Qayyum, S. Mathavan, T. Zafar	Wood Defects Classification Using Laws Texture Energy Measures and Supervised Learning Approach	Oulu Üniversitesi veri tabanından ahşap düğüm kusurlarına sahip beş farklı sınıftan toplamda 395 görüntü kullanılmıştır.	Ortalama Karesel Hata (MSE) 0,0718 ve ortalama sınıflandırma doğruluğu %90,5 olarak elde edilmiştir.
10	2018	R. Ren, T. Hung, K. C. Tan	A Generic Deep-Learning-Based Approach for Automated Surface Inspection	NEU surface defect, Weld defect, Wood defect ve Micro-structure defect veri setleri olmak üzere 4 farklı veri seti kullanılmıştır.	Sınıflandırma görevlerinde, önerilen yöntem doğruluğu %0,66 - %25,50 oranında artırmaktadır. Segmentasyon görevlerinde önerilen yöntem, yedi hata tipinin tamamında doğrulukları %2,29-%9,86 oranında iyileştirmektedir.
11	2019	T. He, Y. Liu, C. Xu, X. Zhou, Z. Hu, J. Fan	A Fully Convolutional Neural Network for Wood Defect Location And Identification	Altı sınıfa sahip 1200 orijinal görüntü kullanılmıştır.	Ağı değerlendirmek için genel sınıflandırma doğruluğu (OCA), piksel doğruluğu (PA) kullanılmıştır. %99,14 OCA ve %91,31 PA elde edilmiştir.
12	2019	A. Urbonas, V.Raudonis, R. Maskeliunas, R.Damaševicius	Automated Identification of Wood Veneer Surface Defects Using Faster Region-Based Convolutional Neural Network With Data Augmentation And Transfer Learning	Beş kusur sınıfına ait toplam 4729 adet görüntü seti kullanılmıştır.	Önceden eğitilmiş ResNet152 sinir ağı modeli kullanılarak en iyi ortalama doğruluk %80,6'lık elde edilmiştir. Tüm kusur sınıflarını birleştirerek, ahşap yüzey kusurlarını bulmada %96,1'lik bir doğruluk elde edilmiştir.
13	2020	F. Ding, Z. Zhuang, Y. Liu, D. Jiang, X. Yan, Z. Wang	Detecting Defects on Solid Wood Panels Based on An Improved SSD Algorithm	2 tip ahşap için 200'er görüntü olmak üzere toplamda 400 görüntü kullanılmıştır. Ön işleme aşamasından sonra 3 farklı sınıfa ait toplam 500 görüntü kullanılmıştır.	Transfer öğrenme yöntemi, bir hedef tespit algoritması olan tek atış çoklu kutu dedektörünü (SSD) kullanılmış ve algoritmayı iyileştirmek için DenseNet ağı tanımlanmıştır. Üç kusur türü tespit etmek için ortalama kesinlik %96,1 idi.
14	2021	R. Qayyum, K. Kamal, T. Zafar, S. Mathavan	Wood Defects Classification Using Glcm Based Features and PSO Trained Neural Network	Oulu Üniversitesi erişime açık olan ahşap düğüm kusurlarına ait veri seti kullanılmıştır. 3 farklı düğüm kusur tipini içermektedir	PSO bir öğrenme algoritması ile eğitim verileri için Ortalama Karesel Hata (MSE) 0,3483 olarak bulunmuş ve test verileri için %78,26 doğruluk elde edilmiştir.
15	2021	Á. García Faura, D. Štepec, M.Cankar, M. Humar	Application Of Unsupervised Anomaly Detection Techniques to Moisture Content Data from Wood Constructions	Window ve Facade dataset olmak üzere 2 farklı veri seti üzerinde çalışılmıştır.	Gerçek anomalinin tespiti için maksimum F0,5 skoru olan 0,9581 elde edilmiştir. Ayrıca, kesinlik 1 elde edilmiştir ki, bu da tespit edilen tüm numunelerin gerçek anomaliler olduğu anlamına gelir.
16	2021	M. Gao, D. Qi, H. Mu, J. Chen	A Transfer Residual Neural Network Based on Resnet-34 For Detection of Wood Knot Defects	DeneySEL veri seti, Oulu Üniversitesi tarafından sağlanmıştır. DeneySEL örnek olarak 7 sınıfa ait toplam 448 ahşap budak görüntüsü hazırlanmıştır. Eğitim, doğrulama ve test veri kümeleri için sırasıyla 1885, 636 ve 615 görüntü kullanılmıştır.	DeneySEL sonuçlar, TL-ResNet34'ün eğitim veri setinde %99,22 gibi yüksek bir tanıma oranı ve doğrulama veri setinde %2,83 gibi düşük bir eğitim kaybı elde ettiğini göstermiştir. Test veri setine TL-ResNet34 uygulandığında genel doğruluk %98,69'a ulaşmıştır.

Günümüzde firmaların Endüstri 4.0'a geçiş hazırlıkları içinde bulunduğu bu dönemde üretim sektöründe özellikle insan eliyle ve gözü ile yapılan işlemlerin dijital teknolojilerle yapılabilme dönüşümü büyük önem taşımaktadır. Özellikle bu alandaki araştırmaların sayısı gün geçtikçe artmaktadır.

Yapılan çalışmalar incelendiğinde çoğunlukla DÖ yöntemlerinden yararlandığı görülmektedir. Ruz vd. (2005), Şili Üniversitesi veri tabanından elde ettikleri 900 renkli görüntü için Bulanık Enk-Enb Sinir Ağları (Fuzzy Min-Max Neural Networks for Image Segmentation, FMMIS) yöntemini kullanmışlardır. Aynı yıl França ve Gonzaga (2005), yayınladıkları çalışmada 199 plaka için görüntü işleme ve öznetelik çıkarımı gibi farklı ön işlem adımları uygulayarak ileri beslemeli sinir ağlarını kullanmışlardır. Shahnorbanun vd. (2010), 12 farklı kusurlu ve kusursuz

görüntüden oluşan veri setini kullanarak 17 öznitelik için 232 öznitelik vektörü elde etmişlerdir. Spiking Öğrenme Vektör Kuantajı (Spiking Learning Vector Quantization, S-LVQ) mimarisi ile bu öznitelikleri sınıflandırmışlardır. Kamal vd. (2017), Oulu Üniversitesi'nin erişime açık 5 farklı ahşap budak kusurlarına sahip toplam 395 görüntüden oluşan veri setini kullanmışlardır. Çalışmalarında beslemeli geri yayılım sinir ağı, ilk olarak gri seviyeli birlikte oluşum tabanlı öznitelikler ve ikinci olarak yasalara göre doku enerji ölçüleri tabanlı öznitelikler kullanarak ahşap üzerindeki budak kusurlarını sınıflandırmışlardır. Ren vd. (2018), erişime açık 4 farklı veri setini ESA ile sınıflandırmışlardır. Çalışmada öznitelik çıkarımı ile sınıflandırma ve hata bölütleme yapılmıştır. Sınıflandırma işlemlerinde önerilen yöntem, doğruluk değerini artırmıştır. Bölütleme işlemlerinde ise önerilen yöntem üç kusur türünde hata kaçış oranlarını azaltırken yedi kusur türünün tümünde doğruluk değerlerini artırmıştır. He vd. (2019) 6 sınıfa sahip 1200 görüntüyü VGG16 ve Tam ESA'dan oluşan Karma Tam ESA modelini kullanarak sınıflandırmışlardır. Orijinal veri setine çeşitli görüntü işleme yöntemleri uygulanmıştır. Altı tür ahşap kusurunun tanımlanması Karma Tam ESA ile yüksek bir doğrulukla sağlanmıştır. Urbonas vd. (2019) yaptıkları çalışmada 4 farklı kusuru içeren kusurlu ve kusursuz toplam 4729 görüntüyü kullanarak sinir ağı eğitmişlerdir. Çalışmada ahşap kaplama yüzey kalitesinin otomatik analizi için daha hızlı Bölgeye Dayalı ESA (Region Based Convolutional Neural Networks, R-CNN) modelini kullanmışlardır. Sonuçlar, dört sınıftan oluşan ahşap kaplama yüzey kusurunun tanımlanması için, veri artırma ve transfer öğrenme tekniklerinin uygulanabilirliğini göstermiştir. Ding vd. (2020), Akagi ve Pinus sylvestris ağaçlarından elde edilen iki tür ahşap için 3 farklı sınıf kusuru (bütünleşik budaklar, düşer budaklar ve kontrol) içeren 200 × 200 piksel boyutunda toplam 500 görüntü elde etmişlerdir. Bu kusurları tespit etmek için transfer öğrenme yöntemine dayalı bir hedef tespit algoritması kullanılmıştır. Uyguladıkları yöntemde mimari olarak DenseNet ağı seçilmiştir (Ding vd., 2020). Yapılan bir başka çalışmada Gao vd. (2021), Oulu Üniversitesi tarafından sağlanan ve 448 ladin türü ahşap malzemenin içeriğindeki budak için görüntü içeren bir veri setini kullanmışlardır. Bu veri setindeki ahşap budak kusurlarını hızlı ve doğru bir şekilde belirlemek için TL-ResNet-34 transfer artık sinir ağını önermişlerdir. Qayyum vd. (2021), Oulu Üniversitesi erişime açık olan ahşap budak kusurlarına ait veri seti kullanmışlardır. Önerilen sinir ağı yöntemi, 90 farklı ahşap kusur örneğinden gri seviyeli birlikte oluşum matrisine dayalı öznitelikleri çıkarır. Bu öznitelikleri kullanarak kusurları sınıflandırmak için bir Parçacık Sürü Optimizasyonu ile belirlenen parametrelere göre eğitilen ileri beslemeli sinir ağını kullanmışlardır.

Ahşap kusurlarının tespiti için yapılan çalışmalarda DÖ yöntemlerinin yanı sıra geleneksel makine öğrenmesi yöntemleri de kullanılmıştır. Silven vd. (2001), çalışmalarında VTT Building Technology tarafından hazırlanan veri setine 2 aşamalı bir muayene işlemi uygulamışlardır. Her iki aşamadaki sınıflandırmalar, kendi kendini organize eden haritalar (Self-Organizing Map (SOM)) kullanılarak uygulanan denetimsiz kümelemeye dayanmaktadır. Cavalin vd. (2006), çalışmalarında eğitim verileri için çam kerestesinden alınan 400 görüntüye sahip bir veri setini kullanmışlardır. Öznitelik setinin performansını değerlendirmek için Sinir Ağları, Destek Vektör Makineleri ve çok amaçlı genetik algoritmalara dayalı bir özellik seçim algoritması kullanmışlardır. Wu vd. 2009 yılında VTT Building Technology tarafından sağlanan toplam 2106 örneği olan eğitim setini oluşturmuşlardır. Yerel İkili Desen (Local Binary Pattern, LBP) ve Çift Ağaçlı Karmaşık Dalgacık Dönüşümü (Dual-Tree Complex Wavelet Transform, DTCWT) yöntemleri, sınıflandırma işlemlerinde sıklıkla kullanılan Destek Vektör Makineleri (DVM) yöntemi birleştirilerek yeni bir ahşap kusurlarını tanıma yöntemi sunmuşlardır. Mahram vd. (2012), Oulu Üniversitesi tarafından hazırlanmış olan ahşap ve budak veri tabanını kullanarak 5 kusur türü için sınıflandırma algoritması geliştirmişlerdir. Bu sınıflandırma algoritmasında DVM ve k-En Yakın Komşu (k-Nearest Neighbour, k-NN) sınıflandırıcıları kullanılmıştır. Mohan ve Venkatachalapathy (2012) yaptıkları çalışmayı 4 farklı budak türü içeren toplam 400 adet ahşap budak görüntüsü kullanarak gerçekleştirmişlerdir. Bu çalışmada ahşap levhalardaki budakların tespiti ve sınıflandırılması önerilmiştir. Budakların görüntüsüne Hilbert dönüşümü ve Gabor filtreleri uygulanarak önceden işlenmiş ve öznitelikleri çıkarılmıştır. Çıkarılan öznitelikler Naive Bayes, Radyal Temel fonksiyonu ve Torbalama Teknikleri kullanılarak sınıflandırılmıştır. Faura vd. (2021), yaptıkları çalışmada Window ve Facade adıyla erişime açık iki veri setini kullanmışlardır. Bu veri setleri farklı ağaç örneklerinden kaydedilen Nem İçeriği (MC) sinyallerinden oluşmaktadır. Denetimsiz Anomali Algılama (Unsupervised Anomaly Detection, UAD) tekniklerini uygulayarak kusur tespiti yapmışlardır. Deneysel sonuçlar UAD'nin her iki durumda da anomalileri başarılı bir şekilde tespit etmek için uygulanabileceğini göstermektedir.

Kaynak araştırması kapsamında yukarıda verilen bilgiler ışığında ahşap malzeme sınıflandırma çalışmalarında farklı DÖ mimarileri ile yüksek başarılar elde edilebildiği görülmüştür. Bu çalışmalarda başarılı sonuçlar elde edilse de sonuçların gelişmeye açık olduğu da gözlenmiştir. Bu zamana kadar incelenen kaynaklar ışığında, bu çalışmada kullanılan ahşap görüntülerine ilişkin veri setinin ilk kez bu çalışmada kullanıldığı ve probleme özgü elde edildiği görülmektedir. Bu çalışmanın amacı bu özgün veri seti kullanılarak ahşap üretim hattında kullanılacak ham maddenin hatalı olup olmadığını ayırtmak için yapay zekâ yöntemleriyle geliştirilen bir model elde etmektir.

4. Materyal ve Yöntem (Material and Method)

4.1. Veri Seti (Data Set)

Bu çalışmada kullanılan veri seti (görüntüler) Instituto Tecnológico de Informática (ITI) araştırma enstitüsünden elde edilmiştir. Görüntüler 16 kameradan oluşan sıfır yer çekimli 3-boyutlu “ZG3D” isimli cihaz ile çekilmiştir. Cihaz ITI enstitüsünde üretilmiştir. Bu cihaz, birden fazla kamerası ile havadaki bir nesnenin görüntüsünü 3 boyutuyla alabilmektedir. Alınan görüntüler kırıldıktan sonra ilgili alanda depolanmıştır. Ahşap endüstrisinde kalite kontrol faaliyetlerinde kullanılacak bu cihazın daha işlevsel olabilmesi için çevrimiçi sınıflandırma ile bir sistem kurulması hedeflenmektedir. Bu cihaz bir üretim hattına serbest düşüş veya robotik kol beslemeli olmak üzere iki farklı şekilde kurulabilmektedir. Serbest düşme durumunda incelenecek parçalar bir konveyör içinde hareket eder ve ZG3D cihazının çekim alanına düşer, nesne cihazın merkezindeyken tüm kameralar görüntü alır, böylece nesnenin görünmeyen hiçbir yüzeyi kalmaz. Daha sonra nesne başka bir konveyöre düşer. Robotik kolun görevi nesnelerin cihazın altından yukarıya fırlatılmasını sağlamaktır. Böylece nesne cihazın önündeysen yakalanarak görüntüsü alınmakta ve kaydedilmektedir (Perez-Cortes vd., 2018).

Bu şekilde oluşturulan veri seti, ahşap dokulu nesnelere mevcut anormallikleri belirlemek için elde edilmiştir. Bu görüntülerdeki anormal bölgeler el ile etiketlenmiştir. Ayrıca, güvenilirliği artırmak için her görüntü iki farklı ekip tarafından etiketlenmiştir. Ahşap nesnelere çatlak, leke, gözeneklilik ve budak olmak üzere dört olası anormallik içermektedir. Bu dört anormallik türü tek bir etiketle işaretlenmiştir ve anormal durum olarak tanımlanmıştır (Perez-Cortes vd., 2018). Veri seti içerisinde bulunan görüntüler Kırmızı Yeşil ve Mavi (Red Green and Blue, RGB) formatında olup farklı piksel seviyelerine sahiptirler. Bunun sebebi her görüntünün renk tonlarının farklı olmasıdır. Veri seti ITI merkezinden görüntü işlemeye hazır olarak elde edilmiş ve bu nedenle verilerin istatistiksel olarak uygun olduğu varsayılmıştır. Kusursuz ve kusurlu görüntü örnekleri Şekil 2 ve Şekil 3’te verilmiştir.



Şekil 2. Kusursuz görüntü örnekleri (Examples of non-defective images) (Perez-Cortes vd., 2018)




Şekil 3. Kusurlu görüntü örnekleri (Examples of defective images)(Perez-Cortes vd., 2018)

Açık erişimli veri seti dört ana bölümden oluşmaktadır: “Eğitim”, “Doğrulama”, “Test” ve “Tamamı Test”. “Eğitim” ve “Doğrulama” dizinlerinde bulunan tüm görüntüler kusurlu olmayan yani normal görüntülerdir. Ayrıca, “Test” dizini iki klasör içerir: “Görüntüler” ve “Maskeler”. Görüntüler dizini içindeki görüntülerin maskeler dizini içerisinde adı (maskesi) varsa bu görüntü kusurlu yani anormal görüntüdür. Son olarak, “Tamamı test” dizini içindeki görüntüler test aşaması için daha fazla sayıda görüntü içerir. Bu dizin içinde bu görüntüler için ayrıca iki maske dizini bulunmaktadır. Bu dizinler, iki ekip tarafından oybirliğiyle etiketlenen (Ve) ve yalnızca bir ekip tarafından etiketlenen (Veya) görüntüler olarak ayrılır. Bu ayırım ile algoritmaların daha doğru bir şekilde değerlendirilmesine olanak sağlanması hedeflenmiştir. Böylece alanında uzman insanların bile anlayamadığı bölgeler içinde algoritma herhangi bir anormal piksel tespit etse de bu algoritmanın başarısızlığını göstermemektedir. Bu nedenle anormalliklerde fikir birliği olmayan bölgeler değerlendirme ölçütlerinden çıkarılmalıdır. Sonuçta yalnızca bir ekip tarafından etiketlenen bölgelerin yok sayılmasına ve değerlendirme ölçütlerinde iki ekip tarafından oybirliğiyle etiketlenen anormal bölgelerin kullanılmasına karar verilmiştir. Eğitim dizini içerisinde 619 görüntü, doğrulama dizini içerisinde 183 görüntü, test dizini içerisinde 478 görüntü ve tamamı test dizini içerisinde 2398 görüntü bulunmaktadır. Tüm veri 3678 görüntüden oluşmaktadır.

4.2. Önerilen Yöntem (Proposed Method)

Bir üretim hattında üretilen ahşap ham madde üzerinde anormal görüntülerin tespiti için ESA ile ilgili kaynak araştırması yapılarak 7 DÖ mimarisi değerlendirilmiştir. Çalışmada izlenecek yol Şekil 4’te verilmiştir.



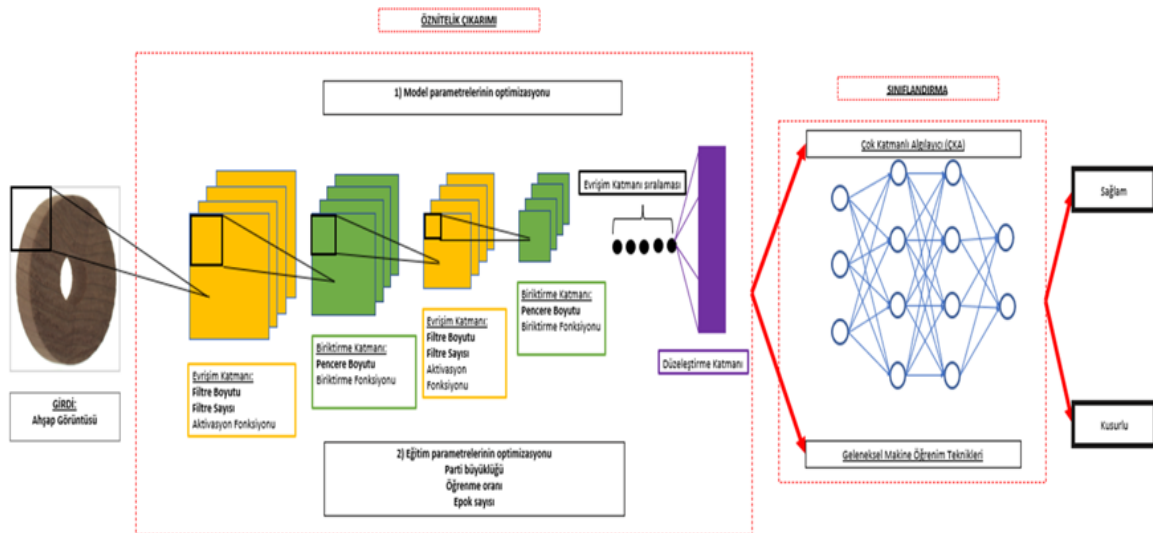
Şekil 4. Akış şeması (Flow chart)

İlk olarak, veri setinde bulunan tüm normal ve anormal görüntüler maskelerine göre etiketlenerek normal ve anormal dizinleri olmak üzere iki gruba ayrılmıştır. Ardından, veri setinin %70'i eğitim ve %30'u test için rassal olarak ayrılmıştır. Eğitim için ayrılan verilerin %70'i eğitimde k, %30'u ise doğrulama amacıyla kullanılmak üzere rastgele bölünmüştür. Hazırlanan verilere ESA ve aktarımlı ESA mimarileri farklı parametre setleri ile uygulanarak en iyi sınıflandırmayı yapan mimariye karar verilmiştir.

4.2.1. Evrişimsel Sinir Ağları (Convolutional Neural Network)

Beynin nesnelere öğrenme yapısından esinlenerek benzer katmanlarla YSA'lar, DA'lara dönüştürülmüştür. ESA'da DA modellerinden biridir. ESA, birincil görsel korteksteki basit ve karmaşık hücreleri anımsatan, evrişim ve alt örnekleme olmak üzere iki temel işlemi değiştiren hiyerarşik modellerdir. ESA, ağırlıkları paylaştığı için, standart çok katmanlı ağlarda olduğu gibi, serbest parametre sayısı giriş boyutlarıyla orantılı olarak artmaz. Bu nedenle ESA, gerçek boyutlu görüntülere iyi ölçeklenir ve birçok nesne tanıma, görüntü işleme vb çalışmaların karşılaştırmasında üstün olduğu bilinmektedir (Masci vd., 2012).

Bu çalışmada, ahşap ham madde üzerindeki anormallikleri sınıflandırmak için ESA yöntemi kullanılmıştır. Bu amaçla yapılan çeşitli uygulamalar izleyen bölümde verilmektedir. ESA'ların temel yapısı Şekil 5'te gösterilmiş ve temel yapı taşları aşağıda kısaca açıklanmıştır:



Şekil 5. Evrişimsel sinir ağı mimarisi (Convolutional neural network architecture)

Bir ESA, bir görüntüyü girdi olarak alabilen, bu görüntüdeki çeşitli özelliklere önem atayabilen ve bu özelliklerin birini diğerinden ayırt edebilen en çok tercih edilen DÖ algoritmasıdır. Gerekli olan ön işlem sayısı, klasik sınıflandırma algoritmaları ile karşılaştırıldığında çok daha düşüktür. Klasik yöntemlerde öznetelikler, yeterli eğitimle elle üretilirken, ESA yapısı gereği bu öznetelikleri öğrenme yeteneğine sahiptir (Toğaçar vd., 2020).

Genel olarak bir ESA yapısındaki öznetelik çıkarma katmanı (evrişim bloğu), evrişim katmanı, aktivasyon işlemi ve biriktirme katmanını içerir ve yüksek boyutlu verilerden düşük boyutlu özelliklerin çıkarılmasını sağlar. Evrişim katmanı, çekirdek (filtre) ve girdi (görüntü) arasındaki evrişim sürecini gerçekleştirerek özellik haritaları

oluşturur. Evrişim katmanının çıktısı, filtre boyutu, filtre sayısı, adım ve dolgu gibi parametrelere dayanır. Her evrişim katmanından sonra seçilen aktivasyon fonksiyonu uygulanır ve bu katman ağı doğrusal olmayan bir yapıya dönüştürerek öğrenmeyi hızlandırır. Biriktirme diğer bir adıyla havuzlama, her bir özellik haritasının boyutunun küçültülmesi anlamına gelen bir alt örnekleme tekniğidir. Biriktirme katmanı, sonraki ağ katmanları için hesaplama yükünü azaltır. Son aşamada ağı sonunda tam bağlantılı katmanlar kullanılır ve bu katmanlar geleneksel sinir ağı mimarisinden oluşur. Tam bağlantılı katman, önceki katmanlarda çıkarılan öznelikleri kullanarak sınıflandırma sonucunu vermeyi amaçlar (Karaca vd., 2021).

İnsan beyni yapısı gereği, bilerek veya bilmeden geçmiş deneyimlerine dayanarak karşılaştığı yeni durumlara cevap verir. Makine öğrenmesinde de karşımıza çıkan bu yaklaşıma aktarımlı öğrenme (transfer öğrenme) denilmektedir. Aktarımlı öğrenmede geçmişte karşılaşılan durumların bilgileri saklanarak yeni gelen durumda bu bilgilerden yola çıkarak karar verilir (Fırıldak ve Talu, 2019). Bu yaklaşımla büyük verilerin işleme gereksinimi ve işlemci kapasitelerinin gelişmesi ihtiyaçları ortaya çıkmıştır. Bu ihtiyaç doğrultusunda farklı derin sinir ağ mimarileri geliştirilmiştir. Bu mimariler girdi verisinden farklı katmanlarda farklı özelliklerin keşfedildiği öğrenme işlemi kendisi yapmaktadır. Temelde ESA yapısına sahip olan bu mimarilerin bazı farklı yapısal özellikleri bulunmaktadır. ESA'lar görüntü sınıflandırma, segmentasyon, video işleme, nesne tanımlama vb. birçok problemde başarılı sonuçlar elde ettiği için DSA mimarileri de bu problemlere uygulanarak başarılı sonuçlar elde edilmiştir (İnik ve Ülker, 2017; Ser ve Bati, 2019).

Çalışmada kullanılan mimariler ve girdi boyutları Tablo 2'de verilmiştir.

Tablo 2. Derin sinir ağ mimarilerinin girdi boyutları (Input size of deep neural network architecture)

Derin Ağ Mimarileri	Girdi Boyutları
ESA	(360 x 360 x 3) ve (224 x 224 x 3)
AlexNet	227 x 227 x 3
GoogleNet	224 x 224 x 3
SqueezeNet	227 x 227 x 3
Inception - V3	299 x 299 x 3
ShuffleNet	224 x 224 x 3
DenseNet-201	224 x 224 x 3
MobileNet - V2	224 x 224 x 3

Derin öğrenme ilk kez 1998 yılında Yann LeCun'nun yaptığı çalışma ile ortaya çıkmıştır. Yayılması 2012 yılında ImageNet yarışmasını AlexNet modelinin kazanması ile olmuştur. AlexNet mimarisi 1000 nesneyi sınıflandıracak şekilde tasarlanmış ve nesne tanımadaki hata oranı %15,4'e indirilmiştir. Bu mimarinin ilk beş katmanı evrişim katmanından ve son üç katmanı ise tam bağlantılı katmandan oluşmaktadır. Bu katmanlar arasında biriktirme ve aktivasyon katmanları bulunmaktadır. Ayrıca bu mimari giriş ve çıkış katmanlarını da içermektedir. Girdi görüntü boyutu 227x227x3, kullanılan filtrelerin boyutu 11x11, filtre sayısı 96 ve adım uzunluğu 4 olarak belirlenmiştir (Krizhevsky vd., 2017; Russakovsky vd., 2015).

GoogleNet ardışık olarak evrişim ve biriktirme katmanlarını istifleyen yapılardan uzaklaşan ilk ESA mimarilerinden biridir. 22 katmanlı yapısı birbirine paralel bağlı Inception modüllerini içermektedir. Bu ağ mimarisinde diğer mimarilerden farklı olarak ağı derinliği ve genişliği artarken hesaplama ve bellek maliyeti ile ağı ezberleme olasılığı azaltılmıştır. GoogleNet 2014 yılında yapılan ImageNet yarışmasını nesne tanımadaki %6,67 hata oranı ile kazanmıştır (Deng vd., 2009; Szegedy vd., 2015).

Mobil cihazlarda iyi performans göstermeyi hedefleyen ESA mimarisidir. Darboğaz katmanları (bottleneck structure) arasında artık bağlantıların (residual connection) olduğu ters çevrilmiş yapıdadır. 32 filtrelili evrişim katmanı ve 19 artık darboğaz katmanından oluşan MobileNet-V2, 53 katman derinliğine sahiptir. ImageNet veritabanı ile önceden eğitilmiş bu ağ mimarisi çok çeşitli görüntüler için öznelikleri öğrenebilir ve çok sayıda nesneyi sınıflandırabilir. Bu mimari 224x224x3 girdi görüntü boyutuna sahiptir (Deng vd., 2009; Sandler vd., 2018).

ImageNet veritabanı üzerindeki görüntülerde eğitilmiş bir başka ESA ise 224x224x3 girdi görüntü boyutuna sahip olan ShuffleNet mimarisidir. Hesaplama maliyetini azaltmak için geliştirilen bu mimari, ilk olarak belirli bir gruptan gelen çıktılardaki bilgi bloke edilirken ikinci durumda kanal karıştırma işlemi kullanılır. Evrişim katmanında bilgi farklı gruplara aktarılır (Deng vd., 2009; Zhang vd., 2018)

ImageNet veritabanından bir milyondan fazla görüntü üzerinde eğitilmiş bir başka ESA SqueezeNet mimarisidir. Önceden eğitilmiş bu ağ mimarisi diğer mimarilerde olduğu gibi çok çeşitli görüntüler için zengin öznelik temsillerini öğrenerek sınıflandırma yapabilir. SqueezeNet, 18 katman derinliğine ve 227x227x3 girdi görüntü

boyutuna sahiptir (Deng vd., 2009; Iandola vd., 2016).

DenseNet-201 mimarisi 201 katman derinliğine sahip olup, ImageNet veritabanındaki görüntüler üzerinde eğitilmiş bir başka ESA'dır. 224x224x3 girdi görüntü boyutuna sahip olan DenseNet-201, önceden eğitilmiş diğer ağlarda olduğu gibi çok çeşitli görüntüler için zengin öznitelikleri öğrenerek sınıflandırır (Deng vd., 2009; Huang vd., 2017).

Inception-V3 48 katman derinliğine sahip olan bir ESA'dır. ImageNet veritabanından önceden eğitilmiş bir başka ağ mimarisidir. Çok çeşitli görüntüler için zengin öznitelikleri öğrenerek sınıflandıran ağ, 299x299x3 bir görüntü girdi boyutuna sahiptir (Deng vd., 2009; Szegedy vd., 2016).

4.2.2. Performans Ölçütleri (Performance Metrics)

Makine öğrenmesi yöntemlerinin ve DA'ların sınıflandırma problemlerindeki performanslarının değerlendirilmesinde birçok ölçüt kullanılmaktadır. Kullanılan ölçütlerle hangi modelin daha doğru sonuçlar ürettiğine karar verilir. Kaynak araştırmasında sıklıkla kullanılan ölçütler karışıklık matrisi adı verilen tabloya dayandırılarak hesaplanmaktadır. Sınıflandırma problemlerinde bir sınıflandırıcı modelin performansını görsel olarak sunan tablo düzenine karışıklık matrisi adı verilir. Bu matriste her sütun tahmin değerlerini, her satır ise gerçek değerleri ifade etmektedir. İki sınıflı bir sınıflandırma problemi için oluşturulan karışıklık matrisi Tablo 3'teki gibidir.

Tablo 3. İki sınıflı karışıklık matrisi (Two-class confusion matrix)

		TAHMİN EDİLEN SINIF	
		POZİTİF	NEGATİF
GERÇEK SINIF	POZİTİF	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	NEGATİF	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Doğru Pozitif (DP), sınıflandırıcı model tarafından pozitif sınıfa ait verilerden doğru sınıflanan sayısını verirken; Yanlış Pozitif (YP), gerçekte negatif sınıfa ait verilerin sınıflandırıcı model tarafından sınıflandırılması sonucunda pozitif olarak etiketlenenlerinin sayısını verir. Doğru Negatif (DN), sınıflandırıcı model tarafından negatif sınıfa ait verilerden doğru sınıflanan sayısını verirken; Yanlış Negatif (YN), gerçekte pozitif sınıfa ait verilerin sınıflandırıcı model tarafından sınıflandırılması sonucunda negatif olarak etiketlenenlerinin sayısını verir.

Karışıklık matrisindeki bu değerler kullanılarak hesaplanan ölçütler ile sınıflandırıcı modelin performansı değerlendirilir. Performans değerlendirmede tek bir ölçüt yeterli olmamaktadır. Bu nedenle dikkate alınacak ölçütler Eşitlik (1-5)'te verilmiştir.

Eğitim veri setiyle eğitilen modelin test veri setindeki verileri sınıflandırırken doğru sınıflandırdıklarının oranıdır:

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (1)$$

Eğitilen modelin gerçekte pozitif sınıfa ait verilerden doğru sınıflandırdıklarının tahmin ettikleri içindeki oranıdır;

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (2)$$

Eğitilen modelin gerçekte negatif sınıfa ait verilerden doğru sınıflandırdıklarının tahmin ettikleri içindeki oranıdır;

$$\text{Özgüllük} = \frac{DN}{DN + YP} \quad (3)$$

Modelin pozitif olarak sınıflandırdıklarının ne oranda doğru sınıfa ait olarak sınıflandırıldığını gösteren orandır;

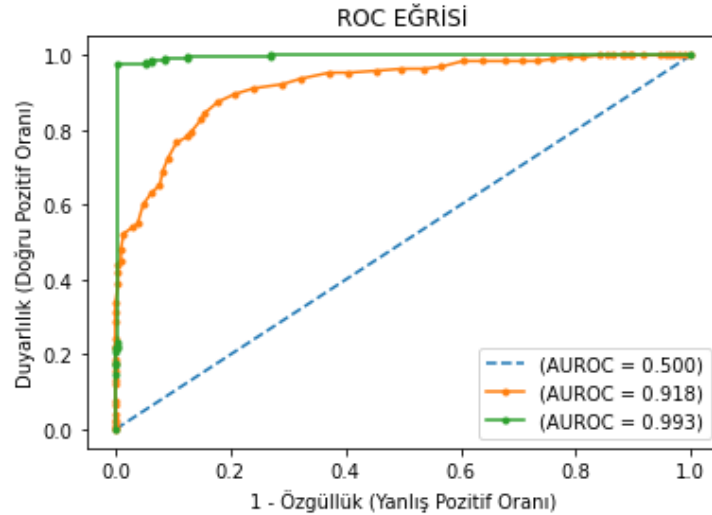
$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (4)$$

Genellikle kesinlik ve duyarlılık tek başına anlamlı karşılaştırma için yeterli olmamaktadır. Bu iki ölçüt bir araya getirilip harmonik ortalaması alınarak daha anlamlı F skor değeri bulunur. Bu değer 0 ile 1 aralığında değer alır, ancak 1'e yakın olması beklenmektedir. β değeri genellikle 1, 0,5 ve 2 değerlerini alır.

$$F_{\beta} \text{ skor} = \frac{(1 + \beta^2) \times (\text{kesinlik} \times \text{duyarlılık})}{\beta^2 + (\text{kesinlik} \times \text{duyarlılık})} \quad (5)$$

%100 doğruluğa, duyarlılığa ve özgüllüğe sahip sınıflandırıcı mükemmel sınıflandırıcı olarak adlandırılır; fakat bu çok sık karşılaşılan bir durum değildir. Duyarlılık ile özgüllük arasında biri artarken diğ erinin azaldığı ters ilişkili bir denge vardır. Bu nedenle en başarılı sınıflandırıcı model seçilirken yüksek doğruluk değerinin yanında duyarlılık ve özgüllük değerlerinde bir denge durumu elde edilmeye çalışılmalıdır.

İşlem Karakteristik Eğrisi (ROC), sınıflandırma, tanı koyma gibi problemlerde performans metriği olarak yalnızca duyarlılık ve özgüllük değerlerini kullanmanın önüne geçmek için geliştirilmiş istatistiksel değerlendirme yöntemidir. İşlem Karakteristik Eğrisi üzerindeki her nokta, farklı değerlere karşılık gelen doğru pozitif (duyarlılık) ve yanlış pozitif (1-özgüllük) değerlerini gösterir. Genellikle düşük yanlış pozitif oranının, yüksek doğru pozitif oranına karşılık gelmesi ve yanlış pozitif oranı azaldıkça doğru pozitif oranının artması beklenmektedir. Bir işlem karakteristik eğrisi altında kalan alan (AUC), testin performansını tek bir değer ile ifadesini sağlayan pratik bir yöntemdir. Bu değer ne kadar büyükse test sonucu o kadar iyi olmaktadır. İşlem karakteristik eğrisi altında kalan alan 0,5'ten 1'e kadar değişim göstermektedir. Şekil 6'da işlem karakteristik eğrisi gösterilmiştir (Fawcett, 2004).



Şekil 6. İşlem karakteristik eğrisi (Receiver operating characteristic curve) (Fawcett, 2004)

5. Deneysel Uygulama ve Analiz (Experimental Application and Analysis)


Bu çalışmada yalnızca iki ekip tarafından anormal olarak oybirliğiyle etiketlenen görüntüler anormal sınıfta kabul edilmiş ve sınıflandırma uygulamaları için veri seti yeniden düzenlenmiştir. İlk olarak, tüm normal ve anormal görüntülerin etiketleri maskelerine göre etiketlenmiştir. Ardından normal ve anormal dizinleri olarak bir araya toplanmıştır. Veri setinde 1855'i anormal, 1823'ü normal olmak üzere toplam 3678 görüntü bulunmaktadır. Veri setinin %70'i eğitim için ve %30'u test için rassal ayrılmıştır. Bu sayede eğitim ve test veri kümeleri hem normal hem de anormal görüntü içeren ahşap ham madde görüntülerinden oluşturulmuştur. Son olarak, eğitim verilerini eğitmek için %70 ve doğrulama için %30 veri rastgele olarak bölünmüştür.

Özetlemek gerekirse, bu çalışmada amaç "normal" bir ahşap dokudan "normal" in ne olduğunu öğrenen ve incelenen bir ahşap dokusunun anormal olup olmadığını çıkararak bir model elde etmektir. Bu nedenle, geliştirilecek yöntemden bir görüntüden anormalliği öğrenerek veri setindeki görüntüleri normal ve anormal olarak

sınıflandırması beklenir. Bu çalışmada ele alınan yaklaşımlar arasında pratik bir endüstriyel perspektif ile problemi çözen en uygun yaklaşım ESA'dır. Bu yaklaşım göz önüne alındığında, yeni bir anormallik algılama süreci oluşturmak, sınıflandırılacak bir dizi nesnenin toplanmasını gerektirir ve bunlar kullanılarak bir ağ eğitilir. Ardından, inceleme altındaki diğer tüm nesnelere ilk kümeyle karşılaştırılır. Normallikten önemli bir sapma olduğunda, nesne otomatik olarak anormal olarak sınıflandırılır.


Kaynak araştırmasında yapılan çalışmalar incelendiğinde model seçimi için çeşitli performans ölçütlerinin dikkate alındığı görülmüştür. Burada önemli olan nokta problem yapısıdır. Eğer incelenen problem sonucunda hassas bir sonuç elde edilecek ise (örneğin; bir hastalığı belirleme) bu durumda birden fazla ölçüt ile modeller karşılaştırılırken çok hassas bir sonuç elde edilmeyecek ise tek bir ölçüt ile modeller karşılaştırılabilir. Sınıflandırma çalışmalarında çoğunlukla tercih edilen ilk ölçüt doğruluk değeri (accuracy) olmaktadır. Bu çalışmada öncelikle modellerin doğruluk değerleri dikkate alınarak farklı yöntemlerle elde edilen modeller karşılaştırılmıştır. Ayrıca her senaryoda elde edilen en yüksek doğruluk değerlerine sahip sonuçlar bir araya getirilerek eğrinin altında kalan alan değerine göre karşılaştırılmıştır. Burada istenilen yüksek doğruluk değerine sahip modelin aynı zamanda eğrinin altında kalan alan değerinin de yüksek olmasıdır.

Bu çalışmada ilk olarak hazır DA mimarileri kullanılmıştır. Kaynak araştırmasında da sıklıkla kullanılan derinlik ve genişlik açılarından farklı 7 mimari, farklı parametre değerleri ile uygulanmıştır. Sonuçlar doğrulama ve test doğruluk ölçütleri dikkate alınarak karşılaştırılmıştır. Parametrelerden öğrenme oranı 0,01, eğitim tur sayısı (epok) 30, doğrulama sıklığı 50 ve optimizasyon yöntemi Momentum ile Stokastik Gradyan İnişi (Stochastic Gradient Descent with Momentum, SGDM) olarak ayarlanmış ve sonuçlar elde edilerek Şekil 7'de gösterilmiştir.




Şekil 7. Derin ağ mimarileri sonuçları – I(Results of deep network architectures -I)

Aynı mimariler öğrenme oranı 0,001'e düşürülerek tekrar uygulanmıştır. Sonuçlar doğrulama ve test doğruluk ölçütleri için karşılaştırılmıştır. Öğrenme oranı düşürüldüğünde GoogleNet, SqueezeNet ve AlexNet ağlarının performans ölçüt değerleri artarken, Inception, ShuffleNet, MobileNet-V2 ve DenseNet-201 ağlarının performans ölçüt değerleri azalmıştır.




Şekil 8. Derin ağ mimarileri sonuçları – II (Results of deep network architectures - II)

Farklı DA mimarileri, doğrulama ve test verileri için elde edilen doğruluk ölçütlerine göre karşılaştırılmıştır. Şekil 7 ve Şekil 8'de bu sonuçlar verilmiştir. Şekiller incelendiğinde en iyi sonucu veren MobileNet-V2 mimarisi, öğrenme oranı ve maksimum epok sayısı parametrelerinin farklı değerleri için uygulanmıştır. Uygulama sonuçları Şekil 9'da sunulmuştur.



Şekil 9. Derin ağ mimarisi mobilenet-V2 sonuçları (Results of mobilenet-V2 from deep network architectures)

DA mimarileri ile yapılan son çalışmada, en yüksek 3 sonuca sahip mimariler dikkate alınmıştır. Bu mimariler DenseNet-201, Inception-V3 ve MobileNet-V2 için doğrulama sıklığı ve maksimum Epok parametreleri sırasıyla 50 ve 30 olarak ayarlanmış ve 4 farklı parametre değeri değiştirilmiştir. Doğrulama ve test doğruluk ölçütlerine bakılarak sonuçlar Şekil 10'da karşılaştırılmıştır.



Şekil 10. Derin ağ mimarileri sonuçları - III (Results of deep network architectures - III)

Aktarımlı öğrenme ile farklı DA mimarileri incelendiğinde bu mimarilerin eğitiminde kullanılan veri sayısı, bu çalışmada kullanılan veri sayısından daha fazla olduğu için derinliği DA mimarilerinden daha az olan bir ESA'nın tasarlamasına karar verilmiştir. Bunun için kullanılacak veriler DA mimarilerinde kullanılan ile aynıdır. Yine verilerin %70'i eğitim, %30'u test için kullanılmıştır. Eğitim için kullanılacak veriler, kullanılan paket program aracılığı ile %70'i eğitim ve %30'u doğrulama olmak üzere rastgele ayrılmıştır. Buradaki tek fark girdi görüntüsünün boyutlarıdır. Aktarımlı öğrenme ile kullanılan DA mimarilerinin yapılarına özel girdi boyutları olduğu için değiştirilemez. Ancak burada girdi boyutları, tasarımı yapan tarafından belirlenebilmektedir. Çok veri kaybı olmaması için 360 x 360 boyutlarına karar verilmiştir. Tasarlanan ESA'da katman sayısına karar verirken katman sayısı kademe kademe artırılarak sonuçlar incelenmiştir. Katman sayısına karar verdikten sonra öğrenme oranı, eğitim tur sayısı (epok) ve optimizasyon yöntemi parametreleri Tablo 4'teki farklı değerleriyle kullanılmıştır.

Tablo 4. Tasarlanan ESA parametreleri ve sonuçları - I (Results and parameters of designed convolutional neural network - I)

	Deneme	Öğrenme Oranı	Katman Sayısı	Maksimum Epok	Doğrulama Doğruluğu	Test Doğruluğu	Optimizasyon Yöntemi
TASARLANAN ESA	1	0,01	3	4	53,37%	49,73%	SGDM
	2	0,01	6	4	55,18%	61,14%	SGDM
	3	0,001	6	4	66,06%	64,76%	SGDM
	4	0,001	9	4	69,3%	72,64%	SGDM
	5	0,0001	9	4	68,78%	70,92%	SGDM
	6	0,0001	9	10	73,58%	74,73%	SGDM
	7	0,0001	9	10	69,17%	78,44%	ADAM
	8	0,0001	9	10	71,63%	75,27%	RMSPROP
	9	0,0001	9	20	72,02%	77,45%	RMSPROP
	10	0,0001	9	20	69,3%	74,37%	ADAM
	11	0,0001	9	20	71,11%	77,17%	SGDM
	12	0,0001	9	100	72,67%	76,54%	SGDM

En iyi sonucu veren mimarinin maksimum epok sayısı artırılarak denemeler yapılmıştır. Epok sayısının artırılmasıyla öğrenme işlemi çok kez tekrarlanır. Bu sayede mimarilerin farklı olasılıkları öğrenmesi ve yeni gelen görüntü için daha doğru sınıflandırma yapması beklenir. Ancak burada önemli olan nokta tasarlanan ağın ezberlemesinin önüne geçmektir. Bu deneme sonuçları doğrulama ve test doğruluk ölçütleri için karşılaştırılmıştır. Sonuçlar Tablo 5'te verilmiştir.

Tablo 5. Tasarlanan ESA parametreleri ve sonuçları – II (Results and parameters of designed convolutional neural network – II)

	Deneme	Maksimum Epok	Doğrulama Doğruluğu	Test Doğruluğu	Optimizasyon Yöntemi
TASARLANAN ESA	1	10	69,17%	78,44%	ADAM
	2	20	69,3%	74,37%	ADAM
	3	30	68,01%	77,81%	ADAM
	4	40	71,63%	76,54%	ADAM
	5	50	71,11%	76,09%	ADAM
	6	60	70,47%	75,27%	ADAM
	7	70	72,67%	77,54%	ADAM
	8	100	74,22%	78,17%	ADAM
	9	150	71,76%	78,17%	ADAM
	10	200	71,76%	79,08%	ADAM
	11	250	71,37%	77,26%	ADAM
	12	300	71,24%	78,53%	ADAM
	13	400	71,37%	76,54%	ADAM

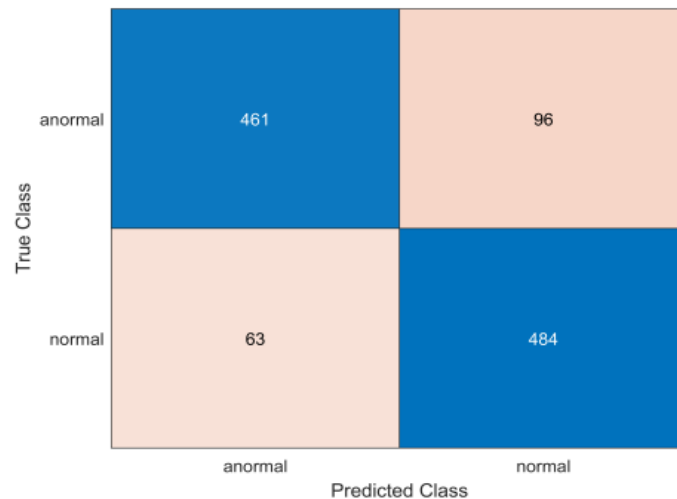
Bir sonraki adımda DA mimarilerinde sıklıkla kullanılan girdi boyutu olan 224 x 224 için denemeler yapılmıştır. Bu denemelerde daha önceki denemelerde en yüksek doğruluk sonucunu veren parametre değerleri, öğrenme oranı 0,0001 ve katman sayısı 9 olarak alınmıştır. Ancak Tablo 6'daki sonuçlar incelendiğinde önceki denemelerden daha iyi sonuç elde edilemediği görülmüştür. Bunun nedeni veri setindeki görüntülerin küçültülmesi ile özellikle kusurlu bölgeleri içeren veri kaybının artmasıdır.

Tablo 6. Tasarlanan ESA parametreleri ve sonuçları – III (Results and parameters of designed convolutional neural network – III)

	Deneme	Maksimum Epok	Doğrulama Doğruluğu	Test Doğruluğu	Optimizasyon Yöntemi
TASARLANAN ESA	1	30	68,78%	76,90%	ADAM
	2	50	67,36%	76,99%	ADAM
	3	70	71,63%	75,27%	ADAM
	4	100	74,09%	74,55%	ADAM
	5	150	70,73%	76,09%	ADAM
	6	200	69,56%	74,64%	ADAM

Kaynak araştırmasında yapılan DÖ çalışmalarında genellikle başarılı sonuçlar elde edilmektedir. Her ne kadar bu mimariler ve tasarlanacak yeni mimarilerin iyi sonuçlar vermesi beklense de bu durum veri setlerinin yapılarına bağlı olarak değişiklik göstermektedir. Bu çalışmada DÖ mimarilerinin uygulanmasının sebebi bu mimarilerin başarılı sonuçlar vermesinin yanında farklı veri setlerine uyum sağlayabilen mimariler olmasıdır.

Tüm sonuçlar incelendiğinde bu çalışmada kullanılan veri setine en uygun derin öğrenme mimarisinin Şekil 10'da sunulan 0,01 öğrenme oranı, 64 parti büyüklüğü ve SGDM optimizasyon yöntemi parametrelerine sahip Inception-V3 mimarisi olduğu görülmüştür. Çalışma kapsamında incelenen 8 mimari içerisinde en iyi sonucu hem doğrulama doğruluğu hem de test doğruluğu ölçütlerinde %80'nin üstünde bir başarıyla vermiştir.

**Şekil 11.** MobileNet-V2 derin ağ mimarisi karışıklık matrisi (Confusion matrix of mobilenet-V2 deep network architecture)

True Class	anormal	478	79
	normal	49	498
		anormal	normal
		Predicted Class	

Şekil 12. Inception-V3 derin ağ mimarisi karışıklık matrisi (Confusion matrix of inception-V3 deep network architecture)

Şekil 11'deki karışıklık matrisinde MobileNet-V2 mimarisinin test görüntüleri içerisindeki normal görüntülerin 63'ü anormal ve anormal görüntülerin 96'sı normal olarak görülmektedir. Şekil 12'deki karışıklık matriste ise Inception-V3 mimarisinin test görüntüleri içerisindeki normal görüntülerin 49'u anormal ve anormal görüntülerin 79'u normal olarak görülmektedir. Bu durumda mimarilerin anormal görüntüleri sınıflandırırken zorlandığı anlaşılmaktadır.

6. Sonuçlar ve Tartışma (Results and Discussion)

Son yıllarda teknolojik gelişmelerle birlikte rekabetin arttığı üretim sektörlerinde kalite kontrol faaliyetlerinde dijital sistemlerin kullanımı daha çok önem taşımaya başlamıştır. Kalite kontrol faaliyetleri ile hem piyasaya sunulan ürünün hem de üretiminin her aşamasının standartlaştırılması sağlanmaktadır. Bu sayede işgücü, ham madde ve/veya yarı mamul ve zaman kayıpları önlenmiş olur. Daha önce gözle ya da elle yapılan kontroller günümüzde dijital teknolojiler ile otomatik hale gelmektedir. Genel olarak, endüstri kullanıcıları, üretim sırasında olası tüm anormallikleri ve bunların görünümünü önceden bilemezler. Ahşap ham madde anormalliklerinin önceden tespit edilmesi ise son derece önemlidir.

Kaynak araştırmasına göre ahşap görüntü üzerindeki hatalı yüzeylerin belirlenmesi amacıyla yapılan tüm çalışmalar Tablo 1'de görülmektedir. Her bir çalışmada farklı veri seti kullanıldığından başarı açısından direkt bir karşılaştırma yapılamasa da bu alanda yapılan çalışmalara bakıldığında bu çalışmada ele alınan problem için bu yeni ve özgün veri seti ile de yüksek başarı elde edilebildiği görülmüştür. Öte yandan kaynak araştırmasında sunulan çalışmalarda kullanılan her veri seti için hedeflerin farklı alındığı görülmektedir. Her veri setine özgü farklı mimariler uygulanmış ve farklı başarı kriterleri dikkate alınmıştır. Bu nedenle bu çalışmada kaynaklarda var olan çalışmalarla bir karşılaştırma yapılamamıştır. Kaynak araştırmasında farklı başarı kriterleri için %80'nin üzerinde elde edilen doğruluğa sahip sonuçların ahşap görüntüler üzerinde yapılan çalışmalar için umut verici sonuç olarak yorumlandığı görülmüş olup ilerleyen çalışmalarda iyileştirilebileceği fikri oluşmuştur.

Bu çalışmada kullanılan veri seti için hazır DA mimarileri ile aktarımlı öğrenme gerçekleştirerek ön çalışmalar yapılmış ve performansları incelenmiştir. Son olarak bir ESA tasarlanmış ve değişik parametrelerde aldığı sonuçlar incelenmiştir. Tasarlanan mimaride katman sayısı azaltılsa da derin ağ yapısının sıfırdan eğitilmesi için çok fazla sayıda veriye ihtiyaç vardır. Aynı zamanda tasarlanan ESA, kaynaklardaki yüksek başarılar elde edilen diğer mimarilerle kıyaslandığında daha az sayıda katman sayısına sahip olması öğrenmeyi etkilemektedir. Bu nedenlerle aktarımlı öğrenme ile daha önceden eğitilmiş ağ parametrelerinin kullanılması, veri sayısının az olduğu uygulamalarda avantaj sağlamaktadır. Bu çalışmada kullanılan veri sayısının az olması nedeniyle derinliği nispeten daha az olan ağların daha başarılı sonuçlar verip vermediği de incelenmiştir. Yapılan çalışmalarda en iyi sonuçlar Inception-V3 mimarisi ile elde edilmiştir. Bu mimari ile doğrulama doğruluğu %82,91 ve test doğruluğu %88,41 olarak elde edilmiştir. Ayrıca MobileNet-V2 ve DenseNet-201 mimarilerinin de umut verici sonuçlar verdiği görülmüştür.

Sonuç olarak bu çalışmada İspanya'da Instituto Tecnológico de Informática (ITI)'da üretim hattında kalite kontrol amacı ile kullanılmak üzere enstitü tarafından elde edilmiş özel veri seti için hatalı-hatasız ayrımını yapacak bir model elde edilerek literatüre katkı sağlanmıştır. Bu veri seti artırılarak ileride yapılacak yeni çalışmalarda farklı

mimariler ve farklı parametreler dikkate alınarak performans üzerindeki etkileri incelenebilir. Bununla birlikte farklı mimarilerden öznelilikler çıkararak sınıflandırma performansları karşılaştırılabilir. Ayrıca görüntü iyileştirme ve çoğaltma tekniklerinin DA üzerindeki etkileri gözlemlenebilir.

Teşekkür (Acknowledgement)

ITI teknik araştırmacısı Javier Perez Soler ve ekibine veri setini paylaştıkları ve tüm sorularımızı yanıtladıkları için teşekkür ederiz.

Çıkar Çatışması (Conflict of Interest)

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir. No conflict of interest was declared by the authors.

Kaynaklar (References)

- Aparecido De França, C., & Gonzaga, A. (2005). Classification of Wood Plates by Neural Networks and Fuzzy Logic Image and Video Processing View project Detection of Architectural Distortion in Mammograms View project. *Computer Science*. <https://www.researchgate.net/publication/266290506>
- Cavalin, P., Oliveira, L. S., Koerich, A. L., & Britto, A. S. (2006). Wood defect detection using grayscale images and an optimized feature set. *IECON Proceedings (Industrial Electronics Conference)*, 3408-3412. <https://doi.org/10.1109/IECON.2006.347618>
- Deng, J., Dong, W., Socher, R., Li, L.-J., Kai Li, & Li Fei-Fei. (2009). ImageNet: A large-scale hierarchical image database. *2009 IEEE Conference on Computer Vision and Pattern Recognition*, 248-255. <https://doi.org/10.1109/CVPR.2009.5206848>
- Ding, F., Zhuang, Z., Liu, Y., Jiang, D., Yan, X., & Wang, Z. (2020). Detecting defects on solid wood panels based on an improved SSD algorithm. *Sensors (Switzerland)*, 20(18), 1-17. <https://doi.org/10.3390/S20185315>
- Faura, Á. G., Štepec, D., Cankar, M., & Humar, M. (2021). Application of unsupervised anomaly detection techniques to moisture content data from wood constructions. *Forests*, 12(2), 1-19. <https://doi.org/10.3390/F12020194>
- Fawcett, T. (2004). ROC Graphs: Notes and Practical Considerations for Researchers. *Pattern Recognition Letters*, 31(8), 1-38. https://www.researchgate.net/publication/284043217_ROC_Graphs_Notes_and_Practical_Considerations_for_Researchers
- Fırıldak, K., & Talu, M. F. (2019). Evrimsel Sinir Ağlarında Kullanılan Transfer Öğrenme Yaklaşımlarının İncelenmesi. *Anatolian Journal of Computer Science - Anatolian Science*, 4(2), 88-95. <https://dergipark.org.tr/pub/bbd/issue/49546/527863>
- Fukushima, K. (1980). Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics* 1980 36:4, 36(4), 193-202. <https://doi.org/10.1007/BF00344251>
- Gao, M., Chen, J., Mu, H., & Qi, D. (2021). A Transfer Residual Neural Network Based on ResNet-34 for Detection of Wood Knot Defects. *Forests* 2021, Vol. 12, Page 212, 12(2), 227. <https://doi.org/10.3390/F12020212>
- He, T., Liu, Y., Xu, C., Zhou, X., Hu, Z., & Fan, J. (2019). A fully convolutional neural network for wood defect location and identification. *IEEE Access*, 7, 123453-123462. <https://doi.org/10.1109/ACCESS.2019.2937461>
- Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A Fast Learning Algorithm for Deep Belief Nets. *Neural Computation*, 18(7), 1527-1554. <https://doi.org/10.1162/NECO.2006.18.7.1527>
- Huang, G., Liu, Z., van der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017, 2017-January*, 2261-2269. <https://doi.org/10.1109/CVPR.2017.243>
- İnik, Ö., & Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104. <https://dergipark.org.tr/pub/gbad/issue/31228/330663>
- Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., & Keutzer, K. (2016, Şubat 24). SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size. *ICLR 2017*. <https://doi.org/10.48550/arxiv.1602.07360>
- Kamal, K., Qayyum, R., Mathavan, S., & Zafar, T. (2017). Wood defects classification using laws texture energy measures and supervised learning approach. *Advanced Engineering Informatics*, 34, 125-135. <https://doi.org/10.1016/J.AEI.2017.09.007>
- Karaca, B. K., Guney, S., Dengiz, B., & Agildere, M. (2021). Comparative Study for Tuberculosis Detection by Using Deep Learning. *2021 44th International Conference on Telecommunications and Signal Processing, TSP 2021*, 88-91. <https://doi.org/10.1109/TSP52935.2021.9522634>
- Kesici, B., & Yildiz, M. S. (2016). Kalite Kontrol Faaliyetlerinde Yapay Zekâ Kullanımı ve Bir Otomotiv Yan Sanayisinde Uygulanması. *Yalova Sosyal Bilimler Dergisi*, 6(12), 307-323. <https://dergipark.org.tr/pub/yalovasosbil/issue/27392/289024>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90. <https://doi.org/10.1145/3065386>
- Mahram, A., Shayesteh, M. G., & Jafarpour, S. (2012). Classification of wood surface defects with hybrid usage of statistical and textural features. *2012 35th International Conference on Telecommunications and Signal Processing, TSP 2012 - Proceedings*, 749-752. <https://doi.org/10.1109/TSP.2012.6256397>
- Masci, J., Meier, U., Ciresan, D., Schmidhuber, J., & Fricout, G. (2012). Steel defect classification with Max-Pooling Convolutional Neural Networks. *Proceedings of the International Joint Conference on Neural Networks*. <https://doi.org/10.1109/IJCNN.2012.6252468>

- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics* 1943 5:4, 5(4), 115-133. <https://doi.org/10.1007/BF02478259>
- Mohan, S., & Venkatachalapathy, K. (2012). Wood Knot Classification using Bagging. *International Journal of Computer Applications*, 51(18), 50-53. <https://doi.org/10.5120/8146-1937>
- Perez-Cortes, J. C., Perez, A. J., Saez-Barona, S., Guardiola, J. L., & Salvador, I. (2018). A System for In-Line 3D Inspection without Hidden Surfaces. *Sensors* 2018, Vol. 18, Page 2993, 18(9), 2993. <https://doi.org/10.3390/S18092993>
- Qayyum, R., Kamal, K., Zafar, T., & Mathavan, S. (2016). Wood defects classification using GLCM based features and PSO trained neural network. *2016 22nd International Conference on Automation and Computing, ICAC 2016: Tackling the New Challenges in Automation and Computing*, 273-277. <https://doi.org/10.1109/ICONAC.2016.7604931>
- Ren, R., Hung, T., & Tan, K. C. (2018). A Generic Deep-Learning-Based Approach for Automated Surface Inspection. *IEEE Transactions on Cybernetics*, 48(3), 929-940. <https://doi.org/10.1109/TCYB.2017.2668395>
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature* 1986 323:6088, 323(6088), 533-536. <https://doi.org/10.1038/323533a0>
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A. C., & Fei-Fei, L. (2015). ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision*, 115(3), 211-252. <https://doi.org/10.1007/S11263-015-0816-Y/FIGURES/16>
- Ruz, G. A., & Estévez, P. A. (2005). Image segmentation using fuzzy min-max neural networks for wood defect detection. *Intelligent Production Machines and Systems-First I* PROMS Virtual Conference: Proceedings and CD-ROM Set*, 183-189. <https://www.researchgate.net/publication/236586295>
- S. Shahnorbanun, S.A.Siti Nurul Huda, A. Haslina, O. Nazlia, & H. Rosilah. (2010). A Computational Biological Network for Wood Defect Classification. *Proceedings of the World Congress on Engineering and Computer Science*, 559-563. http://iaeng.org/publication/WCECS2010/WCECS2010_pp559-563.pdf
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 4510-4520. <https://doi.org/10.1109/CVPR.2018.00474>
- Ser, G., & Bati, C. T. (2019). Derin Sinir Ağları ile En İyi Modelin Belirlenmesi: Mantar Verileri Üzerine Keras Uygulaması. *Yüzüncü Yıl Üniversitesi Tarım Bilimleri Dergisi*, 29(3), 406-417. <https://doi.org/10.29133/YYUTBD.505086>
- Silvén, O., Niskanen, M., & Kauppinen, H. (2003). Wood inspection with non-supervised clustering. *Machine Vision and Applications* 2003 13:5, 13(5), 275-285. <https://doi.org/10.1007/S00138-002-0084-Z>
- 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 Computer Society Conference on Computer Vision and Pattern Recognition, 07-12-June-2015*, 1-9. <https://doi.org/10.1109/CVPR.2015.7298594>
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the Inception Architecture for Computer Vision. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-December*, 2818-2826. <https://doi.org/10.1109/CVPR.2016.308>
- Toğaçar, M., Ergen, B., & Özyurt, F. (2020). Evrimsel Sinir Ağı Modellerinde Özellik Seçim Yöntemlerini Kullanarak Çiçek Görüntülerinin Sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 32(1), 47-56. <https://doi.org/10.35234/FUMBD.573630>
- Urbonas, A., Raudonis, V., Maskeliunas, R., & Damaševičius, R. (2019). Automated Identification of Wood Veneer Surface Defects Using Faster Region-Based Convolutional Neural Network with Data Augmentation and Transfer Learning. *Applied Sciences* 2019, Vol. 9, Page 4898, 9(22), 4918. <https://doi.org/10.3390/APP9224898>
- Wu, S. Y., Zhang, Z., & Feng, L. (2009). Statistical feature representations for automatic wood defects recognition research and applications. *PACIA 2009 - 2009 2nd Asia-Pacific Conference on Computational Intelligence and Industrial Applications*, 1, 19-22. <https://doi.org/10.1109/PACIA.2009.5406462>
- Zhang, X., Zhou, X., Lin, M., & Sun, J. (2018). ShuffleNet: An Extremely Efficient Convolutional Neural Network for Mobile Devices. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 6848-6856. <https://doi.org/10.1109/CVPR.2018.00716>