



Masif Panel Üretiminde Kullanılan Lameller Üzerinde Derin Öğrenme ile Budak Tespiti ve Segmentasyonu

Merve ÖZKAN^{1*}, Caner ÖZCAN²

¹Karabük Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği, Karabük

²Karabük Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği, Karabük

Özet

Masif panel aynı kalitede lamellerin birleştirilmesiyle oluşturulmaktadır. Lamellerin kalitelerine göre ayrılma işlemi tamamen insan gücüne dayalıdır. Bu sebepten üretim bandında yaşanan sorunlar arasında zamandan kayıp, yanlış sınıflandırma, gibi problemler yer almaktadır. Sınıflandırma işleminin basit bir şekilde uygulanması için insan gücünün yerini alabilecek otomatik bir derin öğrenme ağı sistemi, bu sorunları büyük ölçüde ortadan kaldıracaktır. Çalışma kapsamında kullanılan MASK R-CNN ile lameller üzerindeki sınıflandırmayı etkileyen yapıları verimli ve hızlı bir şekilde algılar ve her bir özellik için kaliteli bir segmentasyon maskesi oluşturur. Bu yapılar arasında birçok öznelik yer almaktadır. Bu yapılardan biri olan budak lamel parçaları üzerinde sınıflandırma esnasında büyük rol oynayan yapılardan biridir. Üretim hattından alınan 656 görsel üzerinde Mask R-CNN ağı kullanılarak budak tespiti gerçekleştirilmiştir. 656 görsel üzerinde 1006 adet etiket ile çalışılmıştır. Eğitim için ayrılan etiket sayısı 889, test için ayrılan etiket sayısı 117 olarak belirlenmiştir. Eğitim aşamasında gerçekleştirilen iterasyon sayısı kademeli olarak artırılmış ve sonuç olarak en iyi iterasyon sayısı 250 olarak belirlenmiştir. Nesne tespiti işlemi için ortalama kesinlik değerlerinin ortalaması (mAP) değeri %84 olarak elde edilmiştir.

Anahtar Kelimeler: Derin Öğrenme, Görüntü Segmentasyonu, Nesne Tespiti, Budak Tespiti

Knot Detection and Segmentation with Deep Learning on Lamellas Used in Solid Panel Production

Abstract

The solid panel is formed by combining lamellas of the same quality. The process of separating the lamellas according to their quality is completely based on human power. For this reason, among the problems experienced in the production line, there are problems such as loss of time, misclassification. An automated deep learning network system that can replace manpower for a simple implementation of the classification process will largely eliminate these problems. With the MASK R-CNN used within the scope of the study, it detects the structures affecting the classification on the lamellas efficiently and quickly and creates a quality segmentation mask for each feature. There are many features among these structures. Knot, which is one of these structures, is one of the structures that plays a major role in classification on lamella pieces. Knot detection was performed using Mask R-CNN network on

Makale Bilgisi

Başvuru:

23/09/2022

Kabul:

29/10/2022

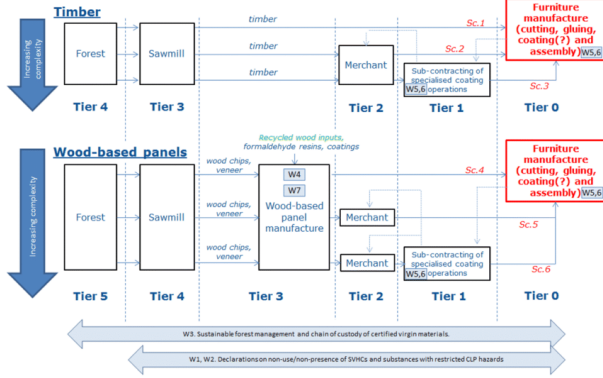
* İletişim e-posta: canerozcan@karabuk.edu.tr

656 images taken from the production line. Worked with 1006 tags on 656 images. The number of tags allocated for training was determined as 889, and the number of tags allocated for testing was determined as 117. The number of iterations performed during the training phase was gradually increased and as a result, the best iteration number was determined as 250. The mean precision values (mAP) for the object detection process were obtained as 84%.

Keywords: Deep Learning, Image Segmentation, Object Detection, Knot Detection

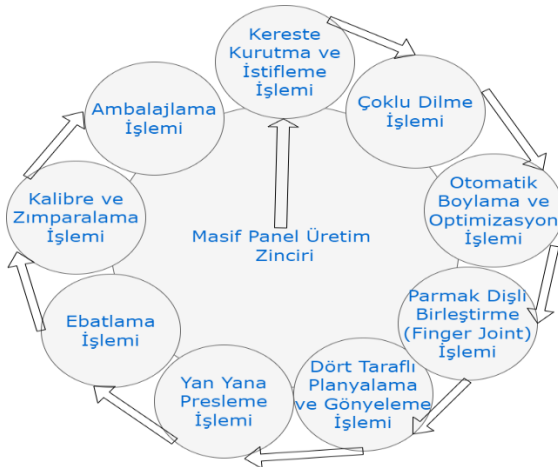
1 Giriş

Endüstriyel orman ürünleri sektöründe üretim gerçekleştiren firmalar ağaç hammaddeli birçok üretim zinciri içerisinde bulunurlar. Bu üretim zinciri tomruğun biçme hattına atılmasıyla başlar, ağacın lata haline gelmesiyle devam eder. Üretilen ürün çeşitlerine göre birçok farklı üretim zinciri aşaması yer almaktadır. Donatello ve diğerleri tomruktan ürün haline getirilen çok çeşitli aşamaları Şekil 1'deki gibi görselleştirmişlerdir [1].



Şekil 1. Ağacın tomruktan ürün haline getirilmesi aşaması

Masif panel üretimi bu üretim zincirlerinden birini oluşturmaktadır. Masif panel üretimi aşamasında gerçekleşen süreçler Şekil 2'de detaylı olarak verilmiştir [2].



Şekil 2. Masif Panel Üretim Zinciri

Çoklu dilme işlemi sonrasında lata haline getirilen parçalar otomatik boylama ve optimizasyon işlemi için hazır hale gelir. Bu işlem Opticut isimli makine tarafından lataları lamellere ayırarak gerçekleştirilir. Bu aşamadan sonra lamellerin kalitelerine göre sınıflandırılması işlemine geçilir. Opticut'ta bir önceki üretim zincirinden gelen latalar insan eli ile kalitesine göre fosforlu kalem yardımıyla çizilir, makineye çizilen lata verilir, çizilen konumlara göre makine içerisinde lata lamellere ayrılır. Opticut'ın çıkışında kalite ayırma birimi yer alır. Burada çalışan insanlar lamel parçalarını sınıflandırmakta ve üretim zincirinde yer alan bir sonraki finger joint isimli makineye göndermektedir. Lameller kalite ayırma biriminin belirlediği ölçütlere göre ayrılır. Bu ölçütleri lamel üzerinde yer alan yapılar belirlemektedir. Ağaç cinslerine göre bu yapılar benzerlik gösterse de tamamen farklı olduğu durumlarda vardır.

Masif panel üretiminde yapraklı, iğne yapraklı ve tropik ağaç türleri kullanılır. Bu çalışmadaki sonuçlar yapraklı ağaç türü grubundan kayın ağacı görüntüleri üzerinde çalışılarak elde edilmiştir.

Kalite ayırma biriminin ele aldığı metrikler arasında yer alan ölçütlerden biri de budaktır. Lamel sınıflandırılırken budağın sınıflandırmaya etkisi; budağın büyüklüğü, sabit budak ya da dağılır budak oluşu ile ölçülür. Kalite ayırma işleminin insan gücüne dayalı olması zaman zaman yanlış parçaların yanlış sınıflandırılmasına sebep olur. Diğer bir dezavantajı ise insanın makine kadar hızlı işlem yapamaması zamandan ve dolayısıyla maddi kazançtan kayıp anlamına gelmektedir. Tüm bu noktalar ele alındığında kalite ayırma işleminin insan gücüne bağımlılığını ortadan kaldırıp derin öğrenme ağları vasıtasıyla ilk aşamada lamel üzerindeki yapıların tespiti sonraki aşamada ise sınıflandırma işleminin makine tarafından yapılıp kalite ayırmada serileşmeye gidilmesi hedeflenmiştir.

Odun parçalarının taranmış görüntüleri analiz edilerek otomatik ağaç türü tanımlama işlemi gerçekleştirilmiştir ve başarısı %98,7 olarak

ölçümlenmiştir [3]. Doğal ormanlarda ağaç türlerinin tanınmasıyla alakalı sınıflandırma işlemi gerçekleştirilmiş [4], ağaç türleri fiziko-mekanik özellikleri tarafından sınıflandırılmış [5], ayrıca görüntünün hangi ağaç türüne sahip olduğu mekanik özelliklerine bakılarak tespit edilmiştir [6]. Kılınçarslan ve arkadaşları ağaç malzemenin ıslanabilirlik özelliğine göre yapay sinir ağları, destek vektör makineleri, K-en yakın komşu ve Naive Bayes yöntemi ile türünü tespit etmişlerdir [7].

Renkli kütük görüntülerinde enine kesit segmentasyonu hem ahşap kalitesi hem de ahşap izlenebilirliği için önemli bir özelliktir. Decelle ve arkadaşları U-Net, Maske bölgesel evrişimli sinir ağı (Mask R-CNN), RefineNet ve SegNet'i kullanarak en iyi sonuçları elde etmeyi ölçütlemişlerdir [8].

Medium Density Fiberboard'ın (MDF) lifli yapısını inceleyen ve bu karmaşık yapılı levhanın geliştirilmesini destekleyen üç boyutlu görüntü analizi oluşturan model Kibleur ve arkadaşları tarafından çalışılmıştır [9]. Mobilya üretiminde kullanılan panellerin üzerindeki deliklerin derin öğrenme modeli U-Net ile tespiti sağlanmış doğruluk oranı %99 olarak ölçülmüştür. Yapılan bu çalışmadan diğer CNN mimarilerinin verdiği doğruluk oranları da ayrıca listelenmiştir [10]. Panellerin kenarların yapıdırma işleminden kalan tutkalların tespiti işlemi için derin öğrenme mimarisine başvurulmuştur. Inception-ResNet-V2 mimarisi kullanılarak %97 doğruluk oranı elde edilmiştir [11].

Çin'deki orman kaynaklarının eksikliği ve ahşap yüzey kusurlarının düşük tespit verimliliği nedeniyle, masif ahşap panellerin üretimi yüksek değildir. Masif panel üretiminde kullanılan lamellerin üzerindeki nesne tespiti ve segmentasyonu ile ilgili işlemlerin büyük bir oranı hatta neredeyse tamamı Çin'deki bir grup araştırmacı tarafından gerçekleştirilmiştir. Aşağıda bu bilgi ile ilgili tüm detaylara yer verilmiştir.

Solid paneller renklerine göre denetimsiz öğrenme yöntemlerinde K-Means algoritması kullanılarak renk tabanlı sınıflandırılmıştır [12]. Ayrıca paneller renk sınıflandırması açısından Zhuang ve arkadaşları tarafından VGG16, DenseNet121, XGBoost mimarileri kullanılarak başka bir çalışmada ele alınmış ve %97 doğruluk elde edilmiştir [13]. Sınıflandırmada panelin rengi ana unsurdur. Ding ve arkadaşları lameller üzerinde ölü budak, canlı budak, çatlak isimli 3 sınıf üzerinde

sınıflandırma işlemi gerçekleştirmiş yöntem olarak daha hızlı evrişimli sinir ağı (Faster R-CNN) algoritmasından daha kötü başarı oranına sahip olan Single Shot Detector(SSD) algoritmasını kullanmış ve %96,1 başarı sağlamıştır [14]. Yang ve arkadaşları ağaç parçaları üzerinde nesne tespiti gerçekleştirmiştir. Ele aldıkları yapılar arasında ölü budak, canlı budak, çürüme sınıflarını ele almışlardır. Bu çalışmada ulaşılan başarı %96,72 olarak ölçülmüştür [15]. Yang ve arkadaşlarının yaptığı çalışmada ağaç cinsi olarak Çin göknar ve çamı seçilmiştir. 5000'den fazla örnek toplanmış ve veri geliştirme yöntemleriyle veri seti 100.000'ee genişletilmiştir. Bu çalışmada ele alınan sınıflar canlı budak, ölü budak, çürüme, küf, çatlak, küçük delik'tir. SSD modelinden geliştirilen yöntem kullanıldıktan sonra elde edilen hataların ortalama tespit doğruluğu %89,7 ve ortalama tespit süresi 90 ms'dir [16].

Wang ve arkadaşları çatlak, budak, solucan deliği, kusursuz yüzey sınıflarında You Only Look Once (YOLO) algoritmasını kullanarak model oluşturmuşlardır. Toplamda 1800 görüntü ile çalışılmıştır [17]. 2021 yılında gerçekleştirilen çalışma budaklar alt sınıflarına ayrılarak çürümüş budak, dağılır budak, köşe budak, kapalı budak, boynuz budak, yaprak budak, sabit budak olarak örneklenmiştir. Bu çalışmada ResNet-34'ü transfer öğrenme ile birleştiren yeni bir TL-ResNet34 yöntemi önerilmiştir. Bu yöntemde sonuçların diğer yöntemlerden daha yüksek bir doğruluk sağladığı gözlemlenmiştir [18].

Türkiye'de 2019 yılında yapılan bir çalışmada masif panel sektörünün kalite ayırma işleminin makine tabanlı yapılmasına katkı sağlayacak bir prototip yayınlanmıştır. Bu çalışmada budak tespiti sağlanmış ve %80 oranında başarı elde edilmiştir [19]. Çalışmada kullanılan veriler halka açık hale getirilmiştir.

2 Materyal metot

Toplamda elde edilen görüntü sayısı 656 adettir. Veriler üzerindeki eğitim i9 10980XE işlemcili ve NVIDIA Quadro RTX 5000 ekran kartına sahip bilgisayar üzerinde gerçekleştirilmiştir.

2.1 Veri

Kastamonu ilinde masif panel üretimi gerçekleştiren bir firmadan alınan özel veri setinden oluşmaktadır. Çalışmada kullanılan ağaç türü kayındır. Veri seti gerçek hayatta oluşabilecek tüm ihtimalleri içerecek şekilde uzman tarafından seçilen görüntülerden oluşmaktadır. Görüntüler

Fujifilm X-S1 12MP kamera vasıtasıyla alınmıştır. Kameranın piksel yoğunluğu 326 dpi, ekran çözünürlüğü ise 783 x 587'dir. Masif panel üretim hattı ortamında görüntü alındığından, görüntü üzerine herhangi bir ışık yansıması düşmemesine dikkat edilmiştir. Şekil 3 veri setinden örnek görüntüleri içermektedir.



Şekil 3. Veri setinden farklı budak görüntüleri

Etiketleme işlemi sonrasında toplam etiket sayısı 1006'ya ulaşmıştır. Bu etiketlerin 889 adedi eğitim aşaması, 117 adedi ise test aşamasında kullanılmak üzere bölümlenmiştir.

2.2 Verilerin etiketlenmesi

Verilerin etiketlenmesi aşaması, görüntü üzerindeki nesnelere işaretlenip, ağa tanımlanabilecek olan farklı formatlarda dosyaların oluşturulmasını sağlayan işlem adıdır. Bu etiketleme işlemi sonrasında ağa sunulacak olan dosya sayesinde ağ görüntü üzerindeki nesnelere tanımlanabilir hale gelmiş olur. Mask R-CNN yapısı, ağa verilecek olan her bir görüntüyü ve bu görüntüler üzerinde oluşturulan etiket bilgisinin JavaScript Object Notation (json) türündeki dosyaya aktarılmış halini eğitim aşamasına geçilebilmesi için bekler. Bu çalışmada etiketleme aracı olarak Makesense.ai kullanılmıştır. Makesense.ai web tarayıcısı üzerinde çevrimiçi kullanılabilen bir araçtır. Mask R-CNN ağına verilmek üzere etiketli json dosyası oluşturulmuştur. Şekil 3'teki görüntüler etiketleme aracı vasıtasıyla Şekil 4'teki görüntülere dönüşmüştür. Şekil 4'te gerçek referans etiketleri yer almaktadır.




Şekil 4. Etiketli veri seti içerisinde rastgele seçilen görüntüler

2.3 Kullanılan yöntem

CNN'ler görüntü analizi için tasarlanmış derin öğrenme ağlarıdır. Sıralı veri analizinde mükemmel kapasiteye sahiptir. CNN'ler girdiyi alır ve çıktıyı segmentasyon ile birlikte sınıflandırır. Sonuçta görüntünün özelliğini çıkarır ve görüntüyü herhangi bir kayba uğratmadan alt boyuta dönüştürür.

Bölgesel tabanlı evrişimli sinir ağı (R-CNN) çoklu nesneye sahip görüntülerde CNN çalıştırılmadığından geliştirilmiştir. 2014 yılında nesne yerleştirme sorununu çözmek için Girshick ve arkadaşları tarafından önerilmiştir. Görüntü yaklaşık 2000 bölge tavsiyesine bölünür ve her bölgeye sırasıyla CNN uygulanır. Bölgelerin boyutu belirlenir ve yapay sinir ağına doğru bölge yerleştirilir. Resimdeki her bir tavsiye bölgesine ayrı CNN uygulandığından eğitim süresi yaklaşık olarak 84 saat sürmekte ve tahmin süresi ise yaklaşık olarak 47 saniyede sonuçlanmaktadır [20]. R-CNN'de görüntü 2000 tavsiye bölgesine bölündüğünden dolayı eğitim işlemi çok uzun sürmektedir. Buna çözüm olarak 2015 yılında hızlı bölgesel tabanlı evrişimli sinir ağı (Fast R-CNN) önerilmiştir [21]. Görüntüyü tavsiye bölgelerine ayırmadan tek bir ileri yaymada CNN mimarisine girdi olarak alır.

Mask R-CNN iki aşamalı bir çerçeveden meydana gelir. İlk aşamada görüntüyü tarar ve öneriler üretir. İkinci aşamada ise önerileri sınıflandırır ve sınırlayıcı kutular, maskeler çizer. Her iki aşamada omurga yapısına bağlıdır.



Şekil 5. Mask R-CNN mimarisi [22]

Mask R-CNN bir görüntüdeki birden çok nesneyi ve çakışan nesnelere algılamak için bağlantı kutuları kullanır. Bu işlem nesne algılamaya hız ve verimlilik sağlar.

Sınırlayıcı kutucuklar belirli bir genişlik ve yüksekliğe sahip önceden tanımlanmış kutucuklardır. Bu kutuların amacı algılanılmak istenen belirli nesne sınıflarının ölçüğünü ve en boy oranını yakalamak için tanımlanmıştır. Bu çalışma mantığıyla bir görüntüdeki birden çok nesneyi tahmin etmek için Mask R-CNN binlerce tahminde bulunur. Arka plan bağlantı kutuları kaldırılarak nihai nesne tespiti yapılır kalanlar güven puanlarına göre filtrelenir ve eşik değerini geçenler tespit edilerek sonuçlarda gösterilir.

Bu çalışmada Mask R-CNN kullanılmasının başlıca sebeplerinden biri diğer ağlardan farklı olarak nesneyi segmente etme işlemini gerçekleştirmesidir. Tahmin edilen budak görüntülerinin büyüklüğü sonraki çalışmalarda kullanılacağı için Mask R-CNN'de bu amaca maskeleyme işlemiyle katkı sağladığından tercih edilmiştir.

3 Deneysel sonuçlar

Eğitim ve test verilerinin toplanması aşaması bu çalışma için fazlaca maliyetlidir. Orman ürünleri sektöründe masif panel üretimi üzerine çalışan firmalardan biri ile görüşüp, firmanın masif panel üretim hattına özel lamel parçalarının görüntülerini eğitimde işleyebilecek hale getirmek süreci tanımlamaktadır. Görüntüler kamera vasıtasıyla tek tek alınmıştır. Bu da veri toplama sürecinin maliyetini kısa da olsa tasvir etmektedir.

Test verisine ait karmaşıklık matrisi Şekil 6'da verilmiştir.

BG	28 20.74%	0.00%	100.00%
budak	18 13.33%	89 65.93%	10.73%
sum_col	18	117	135
	0.00%	76.07%	65.93%
	100.00%	23.93%	34.07%
BG		budak	sum_lin

Şekil 6. Test veri setine ait karmaşıklık matrisi

Eğitimlerdeki dönem sayısı (epoch) sayısı kademeli olarak artırılmış ve son eğitim sonucunda en iyi değere ulaşılmıştır.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (1)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (2)$$

$$\text{F1 Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3)$$

Denklem 1 pozitif olarak tahmin edilen değerlerin gerçekte kaçta kaçının doğru olduğunu gösterir. Denklem 2 pozitif sınıfların kaçta kaçını yakalayabildiğini gösterir. CNN'ler ile çalışırken denklemlerde yer alan her parametreyi ayrı ayrı değerlendirerek modelin başarısıyla alakalı bilgi saptanmalıdır. Yalnızca bir metriğin değerlerinden modelin başarısının ölçülmesi problemin tipine göre hataya sebebiyet verdiği gözlemlenmiştir. Özellikle dengesiz veri setlerinde f1 puanı (f1 score) metriği öncelikli ele alınmalıdır. Sınıflandırıcının gösterdiği performansın ne kadar iyi olduğuna dair bu metrik sayesinde modeller arasında karşılaştırma yapılabilir.

Şekil 7'de herhangi bir sınıflandırma probleminde modelin tahmin ettiği, doğru ve yanlış olarak bölümlendirdiği alanlar yer almaktadır. Bu alanlar kesinlik (precision), geri çağırma (recall) ve f1 score metriklerini belirlemede kullanılmaktadır.



Şekil 8. Modele sunulan veri setinden alınan örneklerin maskelenmiş ve tahmin edilmiş görüntüleri

True Positives (TP)	False Negatives (FN)
False Positives (FP)	True Negatives (TN)

Şekil 7. Sınıflandırma probleminde doğru ve yanlış tahmin edilen alanlar

Doğru sınıflandırılmış pozitif örnek (TP) sayısı ve doğru sınıflandırılmış negatif örnek (TN) sayısı; modelin doğru tahminlediği alanları gösterir. Yanlış sınıflandırılmış pozitif örnek (FP) sayısı ve yanlış sınıflandırılmış negatif örnek (FN) sayısı; modelin yanlış tahminlediği alanları gösterir.

Şekil 8'de veri setinden eğitim öncesinde maskelenen görüntüler ve modelin yaptığı tahminlerin derlenmiş hali yer almaktadır.


Bu çalışma kapsamında elde edilen precision, recall ve f1 score değerleri ise mAP parametresini analiz edebilmek adına Tablo 1'de verilmiştir.

Tablo 1. Farklı epoch sayılarında elde edilen mAP değerleri ve eğitim süreleri.

Epoch Sayısı	Precision	Recall	F1 Score
50	0.74	0.79	0.76
100	0.75	0.74	0.74
150	0.80	0.77	0.79
200	0.80	0.67	0.73
250	0.83	0.76	0.79

Mask R-CNN ağının başarısını gösteren metrik mAP değeridir. Ortalama kesinlik (AP) değeri tahmin

edilen veri seti içerisindeki her bir görüntü için precision ve recall değerleri üretir. Veri seti içerisinde rastgele seçilen bir görüntüden alınan precision ve recall eğrisi Şekil 9'da verilmiştir.



Şekil 9. Test setinden örnek olarak seçilen bir görüntünün precision ve recall eğrisi grafiği

Precision ve recall eğrisinin altında kalan alanın ortalaması mAP değerini oluşturmaktadır. Her ne kadar modellerin başarılarını belirlemede metriklerin ayrı bir önemi olsa da mAP değeri precision, recall, f1 score metriklerinin tek bir noktadan ele alınmasını sağladığı için Mask R-CNN ve YOLO gibi ağların başarımlarını kıyaslamada önemli bir ölçüttür.

Sinir ağında kullanılacak olan ağırlıklar belirlendikten sonra sırasıyla 50, 100, 150, 200, 250 epoch ile eğitimler gerçekleştirilmiştir.

Tüm eğitimlerin sonuçlanması yaklaşık olarak 1 gün 23 saat sürmüştür. Tablo 2'de görüldüğü üzere en iyi sonuçlara 250 epoch sayısında mAP değeri %84 olarak ölçülmüştür. Aynı zamanda oluşturulan bu model Tablo 2'de verilen sonuçlara göre

precision, recall ve f1 score parametrelerinin en iyi değerlerini içermektedir.

Tablo 2. Farklı epoch sayılarında elde edilen mAP değerleri ve eğitim süreleri.

Epoch Sayısı	Süre	mAP
50	3 sa 15 dk	0.84
100	5 sa 55 dk	0.78
150	9 sa 7dk	0.83
200	12 sa 26 dk	0.73
250	15 sa 58 dk	0.84

Eşik değerinin (threshold) model tarafından tahmin edilen sonuçlara göre her veri setine özel belirlenmesi önem arz eder. Bu çalışmaya uygun belirlenen threshold değeri, başka veri seti için uygun olmayabilir.

Oluşturulan modelde threshold 0,7 olarak belirlenmiştir. Bu sayede model kendisine gönderilen görüntülerde güven puanı 0.7 ve üzeri olan tahminlemeleri eşiklemektedir. Tahmin değeri 0.7'nin altında olanları sonuçlar arasında göstermeyecektir. Bu sayede yanlış tahminler elenmiş ve mAP değeri artırılmıştır.

4 Tartışma ve sonuç

Literatürde yer alan çalışmalar incelendiğinde derin öğrenme ağlarıyla birçok nesne tespit işlemi yapılmıştır. Fakat elma, patates, yaya yolu gibi nesnelerin sınıflandırılması bir tarafa bırakılıp, ağaç malzemelerin sınıflandırılması, üzerindeki yapıların tespiti konusu ele alındığında literatürde yeterli çalışma olmadığı görülmektedir.

2019 yılında Kılıç ve arkadaşları tarafından yapılan çalışmada hasar tespiti gerçekleştirilmiştir. Bu çalışmada hasarlı ve hasarsız olarak 2 ayrı sınıf oluşturulmuştur, test esnasında 100 adet görüntü kullanılmıştır [19]. Çin'de Orman varlıklarının az olması ve orman üzerinden üretilen ürünlerdeki kusurlu kısımların optimize edilmesi ve bu alanda daha fazla ürün üretimi düşüncesi ile yola çıkmıştır. Yang ve arkadaşlarının yaptığı çalışmada sabit budak, dağılır budak ve çürüme şeklinde sınıflandırma yapılmıştır. Bu çalışmada sarıçam, köknar ve dişbudak ağaçlarından alınan örnekler ile deneyler gerçekleştirilmiştir [15].

Literatürde benzerlerine rastlanan çalışmalardan ziyade bu çalışma kayın ağacı ve Kastamonu ilinde masif panel üretimi gerçekleştiren firmaya özel veri seti üzerinde yapılan çalışmalara ait sonuçları içermektedir.

Masif panel üretimi gerçekleştiren firmadan alınan kayın ağacı lamel görüntüleri üzerinde Mask R-CNN mimarisi kullanılarak model oluşturulmuştur. 656 görüntü üzerinde 1006 etiket ile çalışılmıştır. Sinir ağı eğitim veri setinin adedini 889, test veri setinin adedini 117 olarak belirlemiştir. Kademeli olarak artırılan epoch sayıları sonucunda en iyi modelin 250 epoch ile oluştuğu görülmüştür. Modelin mAP değeri %84 olarak ölçülmüştür. Modelin sadece mAP değeri değil, precision, recall ve f1 score parametreleri de bu epoch sayısında en iyi değerlere ulaşmıştır.

Başarısızlıkla sonuçlanan görüntüler ele alındığında ağaç üzerine düşen küçük ağaç parçası kalıntıları model tarafından yer yer budak olarak algılanmıştır. Ağaç üzerinde oluşan ufak zedenlenmeler model tarafından yine budak olarak tespit edilmiştir. Ağaç parçası kalıntısı sorununu çözebilmek için lamel parçalarının temiz halinin görüntüsü modele verilerek doğruluğun daha yüksek oranda ölçülmesi hedeflenmektedir.

Masif panel sektöründe kusurlu yapıları ayırt edebilecek, firmalara özel çözümler üretebilecek bir sinir ağı henüz yer almamaktadır. Bu çalışma da yalnızca budak kusurunun tespiti ele alınmıştır. Sonraki çalışmalarda lamel parçaları üzerinde sınıflandırmayı etkileyen diğer etmenlerin ayırt edilmesi üzerine gidilecektir.

Ayrıca gelecekteki çalışmalarda yapraklı, iğne yapraklı ve tropik ağaç türlerinin tamamıyla çalışılması planlanmıştır.

Teşekkür

Çalışma, Karabük Üniversitesi Bilimsel Araştırma Projeleri Birimi vasıtasıyla KBÜBAP-22-YL-096 kodlu proje kapsamında desteklenmektedir.

Kaynaklar

- [1] Donatello S, Cordella M, Kaps R, Kowalska M, Wolf O. Are the existing EU Ecolabel criteria for furniture products too complex? An analysis of complexity from a material and a supply chain perspective and suggestions for ways ahead. *International Journal of Life Cycle Assessment*. 2020;25(5):868-882. doi:10.1007/s11367-019-01601-1
- [2] Bilgin Y. *Türkiye'de Masif Panel Sektörünün Yapısal Durumu ve Ağaç İşleri Endüstrisindeki Kullanım Olanakları*. 2010.
- [3] Fabijańska A, Danek M, Barniak J. Wood species automatic identification from wood core images with a residual convolutional neural network. *Computers and Electronics in Agriculture*. 2021;181:105941.

- [4] Xi Z, Hopkinson C, Rood SB, Peddle DR. See the forest and the trees: Effective machine and deep learning algorithms for wood filtering and tree species classification from terrestrial laser scanning. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2020;168:1-16. doi:10.1016/J.ISPRSJPRS.2020.08.001
- [5] As N, Dündar T, Büyüksarı Ü. Classification of wood species grown in Turkey according to some physico-mechanic properties. *İstanbul Üniversitesi Orman Fakültesi Dergisi*. 2016;66(2):727-735. doi:10.17099/jffiu.93670
- [6] İlkuçar M, Kaya Aİ, Çıfci A. Mekanik Özelliklere Göre Ağaç Türlerinin Yapay Sinir Ağları ile Tahmini Predicting wood types in terms of mechanical properties using artificial neural networks. 2018;8(1):75-83.
- [7] Kiliçarslan Ş, Şimşek Türker Y, İnce M. Temas Açısı Değerlerine Bağlı Ağaç Türlerinin Farklı Sınıflandırma Yöntemleri İle Tahmini. *Bartın Orman Fakültesi Dergisi*. 2020;22(3):861-870. doi:10.24011/barofd.697098
- [8] Decelle R, Jalilian E. Neural Networks for Cross-Section Segmentation in Raw Images of Log Ends. Published online 2019:3058259. Accessed May 21, 2022. <https://hal.archives-ouvertes.fr/hal-03058259>
- [9] Kibleur P, Aelterman J, Boone MN, van den Bulcke J, van Acker J. Deep learning segmentation of wood fiber bundles in fiberboards. *Composites Science and Technology*. 2022;221. doi:10.1016/J.COMPSCITECH.2022.109287
- [10] Augustauskas R, Lipnickas A, Surgailis T. Segmentation of drilled holes in texture wooden furniture panels using deep neural network. *Sensors*. 2021;21(11). doi:10.3390/S21113633
- [11] Chen LC. Edge-glued wooden panel defect detection using deep learning. *Wood Science and Technology*. 2022;56:477-507. doi:10.1007/s00226-021-01316-3
- [12] Wang Z, Zhuang Z, Liu Y, Ding F, Tang M. Color classification and texture recognition system of solid wood panels. *Forests*. 2021;12(9). doi:10.3390/f12091154
- [13] Zhuang Z, Liu Y, Ding F, Wang Z. Online color classification system of solid wood flooring based on characteristic features. *Sensors (Switzerland)*. 2021;21(2):1-13. doi:10.3390/s21020336
- [14] Ding F, Zhuang Z, Liu Y, Jiang D, Yan X, Wang Z. Detecting defects on solid wood panels based on an improved SSD algorithm. *Sensors (Switzerland)*. 2020;20(18):1-17. doi:10.3390/s20185315
- [15] Yang Y, Zhou X, Liu Y, Hu Z, Ding F. Wood defect detection based on depth extreme learning machine. *Applied Sciences (Switzerland)*. 2020;10(21):1-14. doi:10.3390/app10217488
- [16] Yang Y, Wang H, Jiang D, Hu Z. Surface detection of solid wood defects based on ssd improved with resnet. *Forests*. 2021;12(10). doi:10.3390/f12101419
- [17] Wang B, Yang C, Ding Y, Qin G. Detection of Wood Surface Defects Based on Improved YOLOv3 Algorithm. Published online 2021.
- [18] Gao M, Chen J, Mu H, Qi D. A transfer residual neural network based on resnet-34 for detection of wood knot defects. *Forests*. 2021;12(2):1-16. doi:10.3390/f12020212
- [19] Kiliç Ö, Mertcan D, Süzek BE. A Quality Control System Prototype for Detecting Knot Defects in the Wooden Panel Manufacturing. *Mugla Journal of Science and Technology*. 2019;24(1):24-33. doi:10.22531/muglajsci.473338
- [20] Girshick R, Donahue J, Darrell T, Malik J. Region-Based Convolutional Networks for Accurate Object Detection and Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2016;38(1):142-158. doi:10.1109/TPAMI.2015.2437384
- [21] Girshick R. *Fast R-CNN*; 2015. <https://github.com/rbgirshick/>
- [22] He K, Gkioxari G, Dollár P, Girshick R. *Mask R-CNN*; 2018. <https://github.com/>