

Araştırma Makalesi

Evrişimli Sinir Ağları Yöntemleri ile Nozul Hasar Tespiti**Barış KOL[†], Erdem YAVUZ^{††}**[†] Bursa Teknik Üniversitesi, Bilgisayar Mühendisliği Bölümü, Bursa, Türkiye^{††} Bursa Teknik Üniversitesi, Bilgisayar Mühendisliği Bölümü, Bursa, Türkiye[†] baris.kol16@gmail.com, ^{††} erdem.yavuz@btu.edu.tr

0009-0006-6489-5570, 0000-0002-3159-2497

Atıf/Citation: Kol B., Yavuz E., (2025), Evrişimli Sinir Ağları Yöntemleri ile Nozul Hasar Tespiti, İstanbul Ticaret Üniversitesi Teknoloji ve Uygulamalı Bilimler Dergisi, Cilt 8, No 1, s. 151-167, DOI: 10.56809/icujtas.1637819

ÖZET

Lazer teknolojilerinin kullanımı günümüzde çeşitli sektörlerde oldukça yaygınlaşmış ve özellikle makine sektöründe kullanımı önemli ölçüde artmıştır. Makine sektöründe genellikle metal ve metal olmayan malzemelerin işlenmesinde, sac metal şekillendirme, profil işleme gibi süreçlerde, lazer kesim makineleri kullanılmaktadır. Elde edilen son ürün olan işlenmiş ürünün kalitesinin artırılması adına, lazer kesim makinelerinde karşılaşılan sorunlar incelenmiştir. Lazer kesim makinelerinin lazer kafalarında bulunan ve lazer ışınının çıkış yaptığı son materyal olan nozulda, uzun süreli kullanımlarda veya lazer kafasının sac metale ya da kesme tablasına çarpması sonucunda hasarlar oluştuğu gözlemlenmektedir. Nozulda oluşan bu hasarlar kesim kalitesini doğrudan etkilemektedir. Bu çalışmada kesim sırasında kullanılan nozulun, hasarlı veya hasarsız olarak sınıflandırılması işlemi için Evrişimli Sinir Ağları Yöntemleri kullanılmıştır. Tek katmanlı veya çift katmanlı olan iki farklı tip nozul için uzman kontrolünde hasarlı veya hasarsız olarak etiketleme yapılarak 336 adet nozulun görüntüsü alınmış ve veri seti oluşturulmuştur. Oluşturulan veri seti için nozul tipi tek katman olacak şekilde segmentasyon işlemi yapılarak maskelenmiş, sonrasında tek katmanlı tip olan nozul için merkez daire kontrolü yapılmış, merkez dairesi kesime uygun olan nozullar için çevre hasar kontrolü yapılarak sınıflandırma işlemi gerçekleştirilmiştir. Belirtilen sınıflandırma işlemleri için AlexNet, DenseNet, EfficientNet, ResNet ve VGG evrişimli sinir ağı yöntemleri kullanılmıştır. Belirtilen sınıflandırma yöntemleri, topluluk öğrenmesi (Ensemble Learning) yöntemi ile eğitilerek, nozul sınıflandırma işleminde karar verilmesi sağlanmıştır.

Anahtar Kelimeler: Lazer Kesim Makineleri, Evrişimli Sinir Ağları, Segmentasyon, Topluluk Öğrenmesi

Nozzle Damage Detection with Convolutional Neural Network Methods**ABSTRACT**

The use of laser technologies has become quite widespread in various sectors today and its use has increased significantly, especially in the machinery sector. In the machinery sector, laser cutting machines are generally used in the processing of metal and non-metal materials, in processes such as sheet metal forming and profile processing. In order to improve the quality of the final product, the processed product, the problems encountered in laser cutting machines are examined. It is observed that the nozzle, which is located on the laser heads of laser cutting machines and is the last material from which the laser beam exits, is damaged during long-term use or when the laser head hits the sheet metal or cutting table. These damages to the nozzle directly affect the cutting quality. In this study, Convolutional Neural Network Methods were used to classify the nozzle used during cutting as damaged or undamaged. For two different types of nozzles (single nozzle and double nozzle), 336 nozzle images were taken and a data set was created by labeling them as damaged or undamaged under expert control. For the created data set, the nozzle type was masked by segmentation process as single, then center circle control was performed for the single type nozzle, and peripheral damage control was performed for the nozzles whose center circle was suitable for cutting and classification process was performed. AlexNet, DenseNet, EfficientNet, ResNet and VGG convolutional neural network methods were used for the classification process. These classification methods were trained with the Ensemble Learning method to make a decision in the nozzle classification process.

Keywords: Laser Cutting Machines, Convolutional Neural Networks, Segmentation, Ensemble Learning

Geliş/Received	:	11.02.2025
Gözden Geçirme/Revised	:	04.03.2025
Kabul/Accepted	:	10.03.2025


1. GİRİŞ

Lazer teknolojileri enerji, tıp, otomotiv, gemicilik, havacılık, savunma ve daha pek çok farklı alanda, metal, seramik ve kompozitler, kağıt malzemeler gibi pek çok materyalin işlenmesinde, kaynak, tamir onarım gibi amaçlar için günümüzde yaygın olarak kullanılmaktadır (Karanfil ve Yalçın, 2019; Tung vd., 2024).

Makine sektöründe ise lazer teknolojisi genellikle kaynak, kesme ve delme gibi metal işleme süreçlerinde kullanılmaktadır (Köle vd., 2024). Lazer teknolojinin kullanılmasının en büyük nedenlerinden birisi, diğer işleme metodlarına (oksijen ile kesme, testere, makas vb.) kıyasla daha hızlı olması ve kırılgan veya yumuşak, iletken veya yalıtkan olan pek çok farklı materyali hassas işleyebilme yeteneğidir (Chen vd., 2011).

Makine sektöründe lazer kesim işlemlerinde kesimin kalitesi ve kesim süresi oldukça önem taşımaktadır (Yurdakul vd., 2022b). Lazer ışını ve optiksel parametreler kesimin kalitesini doğrudan etkilediği gibi malzemenin yapısı, kesim kafasının konumu, kesim hızı, lazer için kullanılan gazın tipi, kesim parametreleri gibi diğer faktörler de kesim kalitesini doğrudan etkilemektedir (Yalçın ve Karanfil, 2022).

Lazer kesimlerinde kesim kalitesini doğrudan etkileyen bir diğer faktör, lazer kesim kafasında lazerin çıktığı son nokta olan nozuldur (Leidinger vd., 1994). Nozul tipleri tek katman (single) ve çift katman (double) olmak üzere lazer kesim makineleri, eklemeli imalat gibi üretim teknolojilerinde sıklıkla kullanılmaktadır (Anilli vd., 2018). Lazer kesim makinelerinde genellikle kullanılan iki tip nozul Şekil 1’de gösterilmiştir. Solda görülen nozul tek katman nozulun görüntüsü, sağda görülen nozul ise çift katman nozulun görüntüsüdür.




Şekil 1. Tek katman ve çift katman nozul görüntüsü

Lazer kesim işlemi sırasında, ısıl işlem gören malzeme üzerinden sıçrama ve yanma gibi cüruf oluşturabilecek durumlar görülmektedir. Bu durumlar da iş parçasının kalitesini kötü yönde etkilemekte ve hatta bazı durumlarda mekanik olarak sınırlar aşıldığı için lazer kesim işlemine devam edilememektedir. Bu çalışmada kesim kalitesini kötü yönde etkileyecek veya işleme devam edilemeyecek düzeyde hasar alan nozulların, görüntüler üzerinden tespit edilmesi hedeflenmiştir.

Görüntüler üzerinden özniteliklerin çıkarılması, bir görüntü için karar verici unsurların belirlenmesi için Evrişimli Sinir Ağları yöntemleri kullanılmaktadır. LeNet, AlexNet, VGGNet, GoogleNet ve ResNet gibi farklı mimarilere sahip pek çok evrişimli sinir ağı modeli vardır. Bu modeller görüntülerin sınıflandırılması için karar verici bölgelerin analizleri ve bu bölgelerin öğrenilmesi adına geliştirilmiştir (Can ve Eyüpoğlu, 2021). Nesnelerin tespit edilmesi, çok modlu verileri işlemek üzerine, elde edilen öznitelik havuzlarının paylaşılarak öğrenilmesini mümkün kılan FMSNet gibi gelişmiş mimariler de evrişimli sinir ağı yöntemlerini temel alarak oluşturulmuştur (Can ve Eyüpoğlu, 2024). Görüntüler üzerinde özniteliklerin öğrenilmesi ve karar verici mekanizmaların bu denli gelişmesi, endüstriyel üretim süreçlerinde de yapay zekanın daha verimli kullanılabileceğinin habercisi olmuştur. Eğitilebilir ağırlıklı özellik birleştirme (WFF) yöntemini kullanan ve evrişimli sinir ağları yöntemlerini temel alan WFF-Net modelinin, yüzey çatlaklarının öğrenilmesi ve tespit edilmesinde mevcut derin öğrenme yöntemlerinden daha iyi performans sergilediği belirtilmiştir (Xiao vd., 2025).

Gerçek hayatta karşılaşılan hasarlı ve hasarsız nozul görüntüleri alınmış ve veri seti oluşturulmuştur. Tek katman tipli ve çift katman tipli nozullardan oluşan bu veri setinde, hasarlı ve hasarsız 336 adet görüntü bulunmaktadır. Görüntüler ön işleme sokulmuş, çift katman tipte olan tüm nozullar, tek katman tipte indirgenmiştir. Ön işlem için nozul görüntülerinin hasarlı olup olmadığı önemli değildir.

Evrişimli sinir ağları yöntemlerini kullanarak META tarafından geliştirilmiş segmentasyon yöntemi SAM2 modeli ön işleme için kullanılmıştır (Ravi vd., 2024). SAM2 modeli ile her bir görüntü için üç adet maskelenmiş görüntü üretilmektedir. Elde edilen üç görüntüden, doğru bölütlenmiş görüntünün tespit edilmesi için Evrişimli Sinir Ağları yöntemleri ve topluluk öğrenmesi yöntemi ile sınıflandırma yapılmış, doğru segmentasyon görüntüsü tespit edildikten sonra, maskeleye yapılarak orijinal görüntüden kırma işlemi yaparak tek tipte nozula dönüşümü sağlanmıştır. Ön işleme için genel amaç Şekil 2’de solda görülen çift katmanlı nozul görüntüsünün, merkezinde bulunan istenmeyen bölgenin tespit edilerek temizlenmesi ve Şekil 2’de sağda görülen tek katmanlı nozul görüntüsüne dönüşümünün sağlanmasıdır.



Şekil 2. Çift katman tipli nozulun tek katman tipe indirgenmesi

Tek tipe dönüştürülmüş tüm nozullar için lazer çıkışının gerçekleştiği iç deliğin, lazer çıkışını engellemeyecek şekilde doğrusal olup olmadığı kontrolü yapılmıştır. Eğer merkez deliğin dairesellik oranı belirlenen eşik değerinin üzerinde ise çevre hasar kontrolü yapılmış, eğer merkez deliğin dairesellik oranı belirlenen eşik değerinin altında ise doğrudan hasarlı olarak sınıflandırılmıştır.

Tek tipe indirgeme ve dairesellik hesaplarından sonra, veri setinde bulunan 336 adet nozul, hasarlı ve hasarsız olarak etiketlenmiş ve Evrişimli Sinir Ağları yöntemleri ve topluluk öğrenmesi yöntemi ile yeni modeller eğitilmiştir. Eğitilen yeni modeller nozul görüntülerinin çevre hasarına göre sınıflandırma işlemi gerçekleştirmektedir.

Gerçekleştirilen çözüm ile lazer kesimde kullanılması hedeflenen nozulun kesime uygun olup olmadığının kararı verilmektedir. Bir nozul hasarlı olarak etiketlenirse, makine operatöründen nozul değişikliği beklenirken, hasarsız etiketlenmiş nozul için lazer kesim sürecine devam edilmektedir.

Bu çalışmanın devamı şu şekilde düzenlenmiştir: Kısım 2’de önerilen yöntem için kullanılan metotlar ayrıntılı olarak açıklanmaktadır. Kısım 3 gerçekleştirilen yöntem ve gerçekleştirilme biçimini kapsamlı bir şekilde ele almaktadır. Kısım 4, elde edilen deneysel sonuçları, sonuçlardan elde edilen çıkarımlar ve değerlendirmeleri kapsamaktadır. Kısım 5 ise gerçekleştirilen çalışmanın nihai sonucunu belirtmektedir.

2. MATERYAL VE METOT

2.1. Materyal

Uygulamanın kullanılmasının hedeflendiği makine türü olan lazer kesim makinesine montajlanan bir kameranın merceğine, makine kontrolünün sağlandığı insan - makine arayüzü sayesinde lazer kesim kafası konumlandırılmıştır. Makinenin sınırları doğrultusunda lazer kesim kafasının, makinede bulunan eksenleri ve motorları hareket ettirmek için kullanılan ve bir programlama dili olan G-code yardımı ile Z ekseninde yukarı aşağı hareket edebilmesi sağlanmıştır. Lazer kafası kamera merceğinden uzaklaştırılarak el ile manuel olarak nozulun değiştirilmesi sağlanmıştır. Değişim sonrasında tekrar lazer kesim kafası kameranın merceğine konumlandırılmış ve kameranın erişim arayüzünden görüntü alınması sağlanmıştır. Her bir nozulun görüntüsü bu yöntem doğrultusunda elde edilmiştir.

Veri setinde tek katmanlı ve çift katmanlı tipte olacak şekilde, hasarlı ve hasarsız karışık olarak toplam 336 adet görüntü bulunmaktadır.

Gerçekleştirilen çalışmanın amacı gereği uygulamada iki farklı sınıflandırma aşaması bulunmaktadır. İlk aşama segmentasyon modeli olan SAM2 modelinin ürettiği görüntülerden ihtiyacımız olanın tespit edilmesi ve tek katmanlı nozula indirgenmesi, ikinci aşama ise tek katmanlı nozulun merkez dairesi doğrusal bir daire ise çevre

hasarının tespiti. Bu nedenle ilk aşama için SAM2 modeli her bir görüntü üzerinde çalıştırılmış ve 336 adet nozul görüntüsü için 1008 adet segmentasyon görüntüsü elde edilmiştir.

Belirtilen çalışmanın ikinci aşamasında çevre hasar tespiti için 336 adet nozul görüntüsü kullanılmıştır. Her iki aşama için de elde edilen veri setleri eğitim, doğrulama ve test olacak şekilde üç ana başlık altında bölünmüştür. Görüntüler %70 eğitim, %20 doğrulama ve %10 test olacak şekilde rastgele olarak ayrılmıştır. Segmentasyon için elde edilen 1008 adet görüntü, doğru ve yanlış olacak şekilde etiketlenilirken, çevre hasar tespiti için elde edilen 336 adet görüntüde etiketler hasarlı ve hasarsız olacak şekilde belirlenmiştir.

Çalışmasının iki aşamasında da ayrı ayrı kullanılan iki veri seti için, eğitim, doğrulama ve test olarak ayrılması sonucunda elde edilen veri seti boyutu Tablo 1’de gösterilmektedir.

Tablo 1. Veri seti boyutu

	İlk Aşama	İkinci Aşama
Toplam görüntü sayısı	1008	336
Eğitim görüntü sayısı	704	235
Doğrulama görüntü sayısı	202	67
Test görüntü sayısı	102	34


2.2. Metotlar

Çalışmada kullanılan makine öğrenmesi ve yapay zeka yöntemleri ve model eğitim sonuçlarını değerlendirmede kullanılan tekniklerin anlatıldığı bölümü içermektedir.

2.2.1. Evrişimli Sinir Ağları

Görüntü analizinde derin öğrenme uygulamalarında genellikle kullanılan evrişimli sinir ağı modelleri, görüntülerin sınıflandırması için karar vermede önemli olan öznetelikleri öğrenmek üzere tasarlanmıştır (Akşit vd., 2022; Liu vd., 2015).

Görüntü üzerinde öznetelik çıkarmak için her bir görüntüde kernel adı verilen matrisler gezdirilerek önemli bölgeler elde edilmektedir. Elde edilen bölgeler bir havuzda toplanır ve tam bağlantılı katmanlarda bulunan ağırlıklar ile matematiksel işlemler sonucunda görüntü için çıktı üretilir. Üretilen sonuç ile gerçek sonuç arasında farklılıklar hesaplanır ve kayıp değeri elde edilir. Elde edilen kayıp değeri modelde geri besleme yöntemi ile ağırlıklar güncellenerek öğrenme işleminin bir adımı gerçekleştirilir. Bu bir adım veri seti üzerinde bulunan her bir görüntü için tamamlandığında bir çevrim tamamlanmış olunur. Genel yapısıyla yapay sinir ağları ve derin öğrenme yöntemlerinde öğrenme bu şekilde gerçekleştirilir (Kuo, 2016; Ünal vd., 2023). Gerçekleştirilen uygulamada kullanılan evrişimli sinir ağı yapısının temsili Şekil 3’te gösterilmiştir.




Şekil 3. Evrişimli sinir ağı yapısı

2.2.2. Topluluk Öğrenmesi Yöntemi

Gerçekleştirilen çalışmanın iki aşamasında da sınıflandırma için eğitilen AlexNet, DenseNet, ResNet, VGG ve EfficientNet modellerinin, her aşama için oluşturulan veri setlerinde ürettikleri tahminler ile topluluk öğrenmesi yöntemi kullanılarak denetleyici bir model eğitilmiştir.

Topluluk öğrenmesi, birden fazla yapay zeka modelin eğitildiği veri setleri için ürettiği sonuçlardan öğrenerek, karar veren bir yapıdır. Pek çok farklı yöntem bulunmaktadır. Çoğunluğun verdiği karara uyma, önceki modellerin hatalarına odaklanarak öğrenme, birden fazla modelin tahminlerini birleştirerek öğrenme (yığınlama) yöntemleri topluluk öğrenmesi yöntemlerindendir (Sagi ve Rokach, 2018).

Gerçekleştirilen çalışmada yığınlama yöntemi kullanılarak, her bir modelin veri setleri için ürettiği tahminler birleştirilerek, denetleyici bir model eğitilmiştir (Wolpert, 1992). Denetleyici model Lojistik Regresyon yöntemi kullanılarak eğitilmiş ve modellerin performansının artırılması hedeflenmiştir. Topluluk öğrenmesi yöntemlerinden olan yığınlama yöntemi Şekil 4'te gösterilmiştir.



Şekil 4. Topluluk öğrenmesi yığın yapısı

2.3. Değerlendirme Metrikleri

Yapay zeka modellerinin eğitiminin başarılı olup olmadığını analiz etmek için belirli ölçütler kullanılmaktadır. Gerçekleştirilen çalışmada her bir model için eğitim ve doğrulama veri seti üzerinde, kayıp değerleri, doğruluk değerleri, F1 skoru ve karmaşıklık matrisi modelin başarımlarının analizinde kullanılmıştır.

Her bir eğitim verisi ve doğrulama verisi için elde edilen kayıp değerlerini minimum tutmak, doğruluk değerlerini de maksimum tutmak, yapay zeka modellerinin eğitiminin başarılı olduğunu gösteren ilk belirtilerdendir. Bu durumların dışında F1 skoru ve karmaşıklık matrisi tahminlerin gerçek değerler ile karşılaştırılmasıyla elde edilen diğer başarımlar değerlendirme metriklerindendir.

2.3.1. Karmaşıklık Matrisi

Sınıflandırma modellerinin ürettiği sonuçları analiz etmek ve sonuçları bir arada görebilmek için oluşturulan bir matristir. Her bir veri için gerçek sonuçlara göre analiz edilmelidir. Gerçek sonuçların doğru olduğu değerlere karşılık modelin ürettiği doğru (GP) ve yanlışların sayısı (YN), gerçek sonuçların yanlış olduğu değerlere karşılık modelin ürettiği doğru (YP) ve yanlış (GN) sonuçların sayılarının bir arada gösterildiği bir yapıdır.

Karmaşıklık matrisi modelin başarılı olup olmadığını analiz etmek ve modelin ürettiği sonuçlara geniş bir açıdan bakabilmek ve yorumlayabilmek için oldukça önemlidir. Karmaşıklık matrisinin genel yapısı Şekil 5'te gösterilmiştir.

		Gerçek Değer	
		Pozitif (1)	Negatif (0)
Tahmin Edilen Değer	Pozitif (1)	GP	YP
	Negatif (0)	YN	GN

Şekil 5. Karmaşıklık Matrisi

2.3.2. F1 Skoru

F1 skoru, yapay zeka modellerinde duyarlılık ve kesinlik arasında anlamlı bir denge kurmak için analiz edilmesi gereken metriklerden birisidir.

Duyarlılık değeri her bir örnek için gerçek sınıfın, model tarafından doğru tahmin edildiği gerçek pozitif değerlerinin (GP), model tarafından doğru tahmin edilen (GP) ve yanlış tahmin edilen (YN) örneklerin toplamlarına oranı ile hesaplanır. Gerçek pozitif değerlerinin ne kadarını doğru tahmin edildiğinin hesaplanmasıdır. Duyarlılık için uygulanan formül Denklem (1)'de gösterilmiştir.

$$Duyarlılık = \frac{GP}{GP + YN} \quad (1)$$

Kesinlik değeri her bir örnek için gerçek sınıfın, model tarafın doğru tahmin edildiği gerçek pozitif değerlerinin (GP), model tarafın doğru tahmin edilen (GP) ve gerçek sınıfın negatif olduğu durumda modelin pozitif sonucunu ürettiği yanlış pozitif (YP) değerleri toplamına oradadır. Modelin pozitif olarak tahmin ettiklerinin ne kadarının gerçekten doğru olduğunun hesaplanmasıdır. Kesinlik için uygulanan formül Denklem (2)'de gösterilmiştir.

$$Kesinlik = \frac{GP}{GP + YP} \quad (2)$$

Kesinlik ve duyarlılık değerleri doğrultusunda F1 skoru hesaplanmaktadır. F1 skoru 0 ile 1 arasında değişen bir değerdir. Bu değer ne kadar yüksek ise model o kadar doğru sonuç üretebiliyor çıkarımı yapılırken, F1 skoru ne kadar düşükse model o kadar hatalı sonuç ürettiyor çıkarımı yapılmaktadır. F1 skoru için uygulanan formül Denklem (3)'te gösterilmiştir.

$$F1 \text{ skoru} = 2 \times \frac{Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \quad (2)$$

3. UYGULAMA


Gerçekleştirilen çalışma iki temel aşama ile kurgulanmıştır. İlk aşama lazer kesim makinelerinde lazer ışınının çıkış yaptığı son parça olan nozulların merkez daire kontrolü, ikinci aşama ise nozulun merkez dairesinin belirlenen eşik değerinin üzerinde olduğu, kabul edilir dairesellik oranına sahipse gerçekleştirilen çevre hasar kontrolü aşamalarıdır.

Merkez daire kontrolü, görüntünün bölütlenmesi adımı ve istenen görselin belirlenmesi için sınıflandırma adımı olarak iki aşamada incelenmiştir. Çevre hasar kontrolü aşamasında ise tek katmana indirgenmiş görseller hasarlı

ve hasarsız olarak sınıflandırılması aşaması bulunmaktadır. Genel anlamda iki aşamada da evrişimli sinir ağları yöntemleri ile görüntü sınıflandırılması ve yığınlama ile topluluk öğrenmesi yöntemi büyük önem taşımaktadır.

3.1. Merkez Daire Kontrolü

Merkez dairenin daireselliği bozuk olan nozullar kesim kalitesini kötü yönde etkilenmesi nedeniyle, lazer ışınının çıkış yaptığı merkez dairenin dairesellik oranı, nozul hasarının tespiti için önemli bir ayrımdır. Merkez dairenin daireselliği bozuk olan üç adet nozul örneği Şekil 6'da gösterilmiştir.




Şekil 6. Merkez daire daireselliği bozuk nozul görüntüleri

Merkez dairenin doğru tespit edilebilmesi için çift katmanlı nozullar, tek katmanlı nozullara indirgenmiştir. Bu işlem için segmentasyon (bölütleme) yöntemi kullanılmıştır.

3.1.1. Bölütleme

Bölütleme yöntemi olarak SAM2 modeli tercih edilmiştir. Bölütleme işlemi sonucunda her bir görüntü için üçer adet bölütlenmiş görsel elde edilmiş ve bu görsellerden doğru bölgenin bölütlendiği görseli ayırt etmek için Evrişimli Sinir Ağları yöntemleri kullanılarak sınıflandırma işlemi uygulanmıştır. Nozul görüntüsüne karşılık SAM2 modelin çıktısından elde edilen bölütlenmiş örnek nozul görüntüleri Şekil 7'de gösterildiği gibidir.



Şekil 7. SAM2 Segmentasyon modeli çıktısı

Şekil 7'de görülen bölütlenmiş görsellerden, ortada bulunan nozul görseli, merkez dairenin tespit edilebilmesi için doğru bölütlenen görseldir. Bölütlemeye elde edilen maske, orijinal görüntüden çıkarıldığında, elde edilen yeni görsel tek katmanlı nozul görseli olacaktır. Bu görsellerden seçilmesi gereken doğru görseli belirlemek için sınıflandırma işlemi gerçekleştirilmiştir.

3.1.2. Tek Katman Nozul Görüntüsü Elde Etmek için Sınıflandırma

Sınıflandırma işlemi için beş farklı Evrişimli Sinir Ağı modeli eğitilmiştir. AlexNet, DenseNet, ResNet, VGG, EfficientNet modelleri eğitim, test ve doğrulama olarak ayrıştırılmış veri seti ile yeniden eğitilmiştir (He vd., 2016; Huang vd., 2017; Krizhevsky vd., 2017; Simonyan ve Zisserman, 2015; Tan ve Le, 2019). Her bir model eğitildikten sonra topluluk öğrenmesi yöntemlerinden olan yığınlama yöntemi uygulanmış ve segmentasyon sınıflandırma yönteminin performanslarının artırılması hedeflenmiştir. Lojistik Regresyon yöntemi ile her bir eğitilen model için veri setinden üretilen sonuçlara göre genel bir model eğitilmiştir. Eğitim her bir model için 100 çevrim sürmüştür ancak erken durdurma tekniği kullanılarak öğrenmenin devam etmediği modellerde eğitim

sonlandırılmıştır. Optimizasyon fonksiyonu olarak Stokastik Gradyan İnişi (Stochastic Gradient Descent – SGD) tercih edilmiştir.


Sınıflandırmanın sonucunda doğru görsel tespit edilip, orijinal görselden bölütlenen bölge çıkartılarak, Şekil 2’de gösterildiği gibi tek katmanlı nozul görüntüsü elde edilmiştir.

Elde edilen tek katmanlı nozul görüntüsü üzerinde görüntü işleme yöntemleri kullanılarak, eş merkezli çemberler tespit edilmiş ve görüntünün merkezine en yakın olan ilk çember ayrıştırılmıştır. İlk çember üzerinde dairesellik kontrolü yapılmış ve elde edilen sonuç, belirlenen eşik değerinin altında kaldığında merkez dairenin bozuk olduğu çıkarımı yapıp nozula hasarlı etiketi verilirken, belirlenen eşik değerinin üzerinde kaldığında ise merkez dairenin bozuk olmadığı çıkarımı yapılarak çevre hasar kontrolü aşamasına geçilmiştir.

3.2. Çevre Hasar Kontrolü

Gerçekleştirilen uygulamada, nozulun hasarlı olup olmadığının analizi için ikinci kırılım noktası olan çevre hasar kontrolü aşamasında, tek katmana indirgenen ve uzman kontrolünde hasarlı ve hasarsız olarak etiketlenen nozul görüntüleri, evrişimli sinir ağı modellerinden olan AlexNet, DenseNet, ResNet, VGG ve EfficientNet modellerini eğitmek için kullanılmıştır. Her bir model, tüm veri setinden eğitim için ayrılmış olan 235 adet etiketli görsel ile eğitildikten sonra, eğitilmiş modeller yığınlama yöntemi ve lojistik regresyon yöntemleri ile topluluk öğrenmesi modelinin eğitiminde kullanılmıştır. Şekil 8’de sırasıyla üç tip nozul görüntüsü verilmiştir:


- Hiç kullanılmamış nozul,
- Belirli bir süre kullanılmış ancak kesim kalitesini olumsuz etkilemeyen veya lazer kesim makinesinde arızaya (duruşa) sebep olmayan nozul,
- Kullanılamayacak seviyede hasarlı olan nozul.




Şekil 8. Kullanılmamış, kullanılabilir ve kullanılamaz nozul görüntüleri

4. BULGULAR ve TARTIŞMA


Gerçekleştirilen çalışmanın ilk aşaması için AlexNet, DenseNet, ResNet, VGG ve EfficientNet modellerin eğitiminden elde edilen sonuçlar kayıp, doğruluk grafikleri, F1 skoru ve karmaşıklık matrisi olacak şekilde gruplar halinde Şekil 9-14’te gösterilmiştir.




Şekil 9. AlexNet modeli, (a) kayıp, (b) doğruluk, (c) F1 skoru ve (d) karmaşıklık matrisi verileri




Şekil 10. DenseNet modeli, (a) kayıp, (b) doğruluk, (c) F1 skoru ve (d) karmaşıklık matrisi verileri




Şekil 11. ResNet modeli, (a) kayıp, (b) doğruluk, (c) F1 skoru ve (d) karmaşıklık matrisi verileri



Şekil 12. VGG modeli, (a) kayıp, (b) doğruluk, (c) F1 skoru ve (d) karmaşıklık matrisi verileri



Şekil 13. EfficientNet modeli, (a) kayıp, (b) doğruluk, (c) F1 skoru ve (d) karmaşıklık matrisi verileri




Şekil 14. İlk aşama için, modellere göre F1 skoru

Her bir model için görülen grafikler değerlendirildiğinde, tüm modeller için erken durdurma yöntemi tetiklenmiş ve öğrenme için verilen 100 çevrimden daha az çevrim sayısında eğitim durdurulmuştur. Her modelin, tekil olarak başarılı sonuç verdiği gözlemlenmiştir.

Karmaşıklık matrisi dikkate alınarak kesinlik ve duyarlılık değerleri hesaplandığında elde edilen F1 skorlarına, aynı zamanda kayıp ve doğruluk grafiklerine bakıldığında VGG modeli en başarılı sonucu vermiştir. DenseNet ve ResNet mimarisi diğer modellere göre biraz daha farklıdır. Öznetelik çıkartılırken kendinden önceki tüm katmanlarda bulunan verileri de dahil ederek geri beslemeli öğrenme yöntemi kullanan bu modeller, bu veri seti için en başarılı sonuç veren VGG modelini performans olarak yakalamıştır. EfficientNet model yapısı itibarı ile küçük bir model olması nedeniyle en kötü ikinci model olurken, öğrenme sürecini en kötü geçiren model AlexNet olmuştur.


Eğitilen her bir sınıflandırma modeli, topluluk öğrenmesi yöntemlerinden yığınlama yöntemini besleyerek, lojistik regresyon tekniği kullanılarak denetleyici bir model eğitilmiştir. Eğitilen bu denetleyici model için elde edilen doğruluk değeri, karmaşıklık matrisi ve F1 skoru Şekil 15'te gösterilmiştir.




Şekil 15. Denetleyici model için karmaşıklık matrisi ve model performans metrikleri

Topluluk öğrenmesi yöntemi için karmaşıklık matrisi doğruluk ve F1 skoruna bakıldığında ise topluluk öğrenmesi yöntemi ile gerçekleştirilen nozul görüntülerinden doğru bölütlenen görüntünün tespiti yapan denetleyici modelin, %95 doğruluk değeri ile tüm modellerden daha iyi bir performans gösterdiği görülmektedir. Görüntüler için üretilen tahminlerde hataların azaldığı ve başarılı bir denetleyici modelin geliştirildiği görülmüştür.


Çalışmanın ikinci aşaması olan çevre hasar kontrolü için AlexNet, DenseNet, ResNet, VGG ve EfficientNet modellerinin eğitiminden elde edilen sonuçlar Şekil 16-21'de gösterilmiştir.




Şekil 16. AlexNet modeli, (a) kayıp, (b) doğruluk, (c) F1 skoru ve (d) karmaşıklık matrisi verileri




Şekil 17. DenseNet modeli, (a) kayıp, (b) doğruluk, (c) F1 skoru ve (d) karmaşıklık matrisi verileri




Şekil 18. ResNet modeli, (a) kayıp, (b) doğruluk, (c) F1 skoru ve (d) karmaşıklık matrisi verileri



Şekil 19. VGG modeli, (a) kayıp, (b) doğruluk, (c) F1 skoru ve (d) karmaşıklık matrisi verileri



Şekil 20. EfficientNet modeli, (a) kayıp, (b) doğruluk, (c) F1 skoru ve (d) karmaşıklık matrisi verileri




Şekil 21. İkinci aşama için, modellere göre F1 skoru

Çalışmanın ikinci aşamasında, ilk aşamaya göre veri seti boyutunun daha az olması ve model yapılarının karmaşık olması nedeniyle modellerin çevrim süreleri ortalama 11 çevrim sürmüştür ve ilk aşamada olduğu gibi erken durdurma tekniği ile eğitimin devam etmediği durumlarda, eğitim sonlandırılmıştır.

Karmaşıklık matrisleri ve F1 skorları dikkate alındığında, ikinci aşama için en iyi sonucu üreten evrişimli sinir ağı modeli VGG modeli olmuştur. İlk aşamaya göre daha az veri bulunan ikinci aşamada, geri beslemeli öğrenme yöntemini kullanan DenseNet ve ResNet modelleri en kötü sonucu veren iki model olmuştur. Model yapısı daha az karmaşık olan EfficientNet modeli, veri setinin daha az olduğu durumlarda daha iyi performans gösterdiği gözlemlenmektedir.

İkinci aşama sonucunda elde edilen her bir sınıflandırma modeli, nihai karar olan nozulun hasarlı olup olmadığının kararını verecek, topluluk öğrenmesi yöntemlerinden, yığınlama yöntemi olan denetleyici modeli beslemektedir. Veri seti için üretilen tahmin değerlerini girdi olarak alan denetleyici modelin eğitim sürecinden elde edilen karmaşıklık matrisi ve model performans metrikleri Şekil 22’de gösterilmiştir.



Şekil 22. Denetleyici model için karmaşıklık matrisi ve model performans metrikleri

İkinci aşama olan çevre hasarı kontrolünde, denetleyici model olan topluluk öğrenmesi yönteminin eğitim sırasında elde edilen karmaşıklık matrisi doğruluk ve F1 skoruna bakıldığında ise, nozul görüntülerini hasarlı veya hasarsız olarak sınıflandıran denetleyici modelin %94 doğruluk değeri ile başarılı bir eğitim süreci geçirdiği gözlemlenmiştir.

5. SONUÇLAR

Bu çalışmada lazer kesim makinelerinde, kesim kalitesini kötü etkileyecek ve hatta bazı durumlarda mekanik sınırların aşılması nedeniyle duruşa sebep olabilecek düzeyde hasar almış nozulların tespit edilmesi hedeflenmiştir. Gerçekleştirilen uygulama iki farklı aşama ile ayrılmıştır. İlk aşama tek katman ve çift katman nozul görüntülerinin, bölütleme yöntemi ile merkezin tespit edilmesi ve orijinal görüntüden maskelenmiş bölgenin

çıkartılarak tek katman nozul görüntüsüne dönüştürülerek, görüntünün merkezi ile eş merkezli ilk dairenin dairesellik oranına bakılmasıdır. İkinci aşama ise dairesellik oranının uzman kontrolünde belirlenen eşik değerinin üzerinde olduğu nozullarda çevre hasar kontrolünün yapılmasıdır.

Her iki aşama için de sınıflandırma tekniği kullanılmıştır. İlk aşama için bölütleme işlemi sonucunda elde edilen üç maskelenmiş nozul görüntüsünün, merkez bölgesinin bölütlendiği doğru görseli seçmek için sınıflandırma modelleri kullanılırken, ikinci aşama için çevre hasar kontrolü aşamasında sınıflandırma teknikleri kullanılmıştır.

Sınıflandırma yöntemleri kullanılırken AlexNet, DenseNet, ResNet, VGG ve EfficientNet modelleri, her iki aşama için de toplanmış veri setleri ile eğitilmiş ve eğitilen modellerin görüntüler için ürettiği tahmin değerleri ile topluluk öğrenmesi yöntemlerinden yığınlama tekniği ve lojistik regresyon yöntemi kullanılarak değerlendirici ana model eğitilmiştir.

Eğitilen her bir modelin, ne kadar başarılı olduğunu değerlendirmek adına, eğitim ve doğrulama veri setleri üzerinde kayıp ve doğruluk değerleri izlenmiş, F1 skoru ve karmaşıklık matrisleri ile analiz edilmiştir.

İlk aşamada eğitilen evrişimli sinir ağı modellerinden VGG modeli en başarılı sonucu veren model olurken, eğitim sürecini diğer modellere göre daha kötü geçiren model AlexNet modeli olmuştur. Tüm modellerin, veri seti için ürettiği tahminlerden öğrenen denetleyici modelin doğruluk oranı %95 olmuştur.

İlk aşamaya göre daha az veri bulunan ikinci aşama için VGG modeli en başarılı sonucu verirken, ilk aşama için en kötü model olan AlexNet modeli, veri setinin daha az olduğu durumlarda, daha başarılı sonuç vererek, ikinci en iyi model olmuştur. DenseNet modeli diğer modellere göre en kötü sonuçları üreten evrişimli sinir ağı modelidir. Tüm modeller ilk aşamada olduğu gibi topluluk öğrenmesi yöntemlerinden yığınlama yöntemi ile oluşturulan denetleyici modelin eğitilmesinde kullanılmıştır. İkinci aşamada eğitilen denetleyici modelin eğitim sonucunda doğruluk oranı %94 olmuştur.

Bu çalışmada her iki aşama için de en başarılı evrişimli sinir ağı modeli, VGG modeli olmuştur. Denetleyici modellerin başarımları ilk aşama için %94, ikinci aşama için %95 olmuştur.

KAYNAKLAR

- Akşit, N., Aydın, M. A., & Zaim, A. H. (2022). Siber güvenlikte klavye davranış analizi. *İstanbul Ticaret Üniversitesi Teknoloji ve Uygulamalı Bilimler Dergisi*, 5(1), 109-122.
- Anilli, M., Demir, A. G., & Previtali, B. (2018). Additive manufacturing of laser cutting nozzles by SLM: processing, finishing and functional characterization. *Rapid Prototyping Journal*, 24(3), 562-583.
- Can, F., & Eyüpoğlu, C. (2021, October). Convolutional neural network architectures used in computer vision. In *2021 5th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)* (pp. 305-311). IEEE.
- Can, F., & Eyupoglu, C. (2024). FMSNet: A multi-stream CNN for multi-stereo image classification by feature map sharing. *IEEE Access*, 12, 105566-105572.
- Chen, M. F., Ho, Y. S., Hsiao, W. T., Wu, T. H., Tseng, S. F., & Huang, K. C. (2011). Optimized laser cutting on light guide plates using grey relational analysis. *Optics and Lasers in Engineering*, 49(2), 222-228.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).
- Karanfil, U., & Yalçın, U. (2019). Real-time monitoring of high-power fibre-laser cutting for different types of materials. *Ukrainian journal of physical optics*, (20, № 2), 60-72.
- Köle, A., Ayan, Y., ve Kahraman, N. (2024). Markalama ve Kesme İşlemleri İçin Karbondioksit (CO₂) Lazer Makinesi Tasarımı, Üretimi ve Test Çalışmaları. *Politeknik Dergisi*, 27(2), 1-1.

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.

Kuo, C. C. J. (2016). Understanding convolutional neural networks with a mathematical model. *Journal of Visual Communication and Image Representation*, 41, 406-413.

Leidinger, D., Penz, A., Schuoecker, D., Deinzer, G., Geiger, M., Haensel, A., & Herbig, N. (1994, September). Nozzle design and simulation of gas flow for the laser cutting process. In *Laser Materials Processing: Industrial and Microelectronics Applications* (Vol. 2207, pp. 469-479). SPIE.

Liu, T., Fang, S., Zhao, Y., Wang, P., & Zhang, J. (2015). Implementation of training convolutional neural networks. *arXiv preprint arXiv:1506.01195*.

Ravi, N., Gabeur, V., Hu, Y.-T., Hu, R., Ryali, C., Ma, T., Khedr, H., Rädle, R., Rolland, C., Gustafson, L., Mintun, E., Pan, J., Alwala, K. V., Carion, N., Wu, C.-Y., Girshick, R., Dollár, P., ve Feichtenhofer, C. (2024). Sam 2: Segment anything in images and videos. *arXiv preprint arXiv:2408.00714*.

Sagi, O., & Rokach, L. (2018). Ensemble learning: A survey. *Wiley interdisciplinary reviews: data mining and knowledge discovery*, 8(4), e1249.

Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.

Tan, M., & Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning* (pp. 6105-6114). PMLR.

Tung, T. T., Tan, T. M., & Minh, T. V. (2024). A laser cutting machine prototype. *Engineering, Technology & Applied Science Research*, 14(1), 12944-12949.

Ünal, A., Ünal, E., & Güler, D. (2023). EVRİŞİMLİ SİNİR AĞLARI KULLANARAK OPTİK KARAKTER TANIMA. *Journal of Business in The Digital Age*, 6(1), 1-12.

Wolpert, D. H. (1992). Stacked generalization. *Neural networks*, 5(2), 241-259.

Xiao, H., Zhang, W., Zuo, L., Wen, L., Li, Q., & Li, X. (2025). WFF-Net: Trainable weight feature fusion convolutional neural networks for surface defect detection. *Advanced Engineering Informatics*, 64, 103073.

Yalçın, U., & Karanfil, U. (2022). Developing a Real-Time Working Method That Improves Process Efficiency in High-Power Fiber Laser Systems. *Micromachines*, 13(9), 1552.

Yurdakul, M., Tükel, T., İç, Y. T., Ülke, İ., Balcı, A., & Güneş, S. (2022). Bir imalat firmasında en iyi ürün kalitesi için lazer ile kesim parametrelerinin en iyilenmesi. *Journal of Turkish Operations Management*, 6(1), 977-996.

TEŞEKKÜR ve BEYANLAR

Bu çalışma, Durmazlar Makine A.Ş.'nin değerli destekleri olmadan gerçekleştirilemezdi. Bu çalışmanın yürütülmesi ve tamamlanması sürecinde sağladıkları değerli destekler için Durmazlar Makine A.Ş.'ye içten teşekkürlerimi sunarım. Özellikle veri toplama ve test aşamasında sundukları altyapı ve olanaklar ile maddi ve manevi katkıları, araştırmanın başarılı bir şekilde gerçekleştirilmesine önemli ölçüde katkı sağlamıştır. Desteklerinden dolayı Durmazlar Makine A.Ş. yönetimine ve proje sürecinde emeği geçen tüm çalışanlarına şükranlarımı sunarım.

Not: Bu makale, Bursa Teknik Üniversitesi Mühendislik ve Doğa Bilimleri Enstitüsü, Bilgisayar Mühendisliği Tezli Yüksek Lisans Programı'nda, Doç. Dr. Erdem YAVUZ danışmanlığında, Barış KOL tarafından yürütülecek olan, "Evrışimli Sinir Ağları Yöntemleri ile Nozul Hasar Tespiti" başlıklı yüksek lisans tezinin ön çalışmalarından yararlanılarak hazırlanmıştır.