



Detection of the cracks in metal sheets using convolutional neural network (CNN)

İlhan Çekiç*^{ID}, Kadir Çavdar^{ID}

Department of Mechanical Engineering, Institute of Science, Bursa Uludağ University, 16059 Görtükle Bursa, Türkiye

Highlights:

- A dataset of sheet cracked images has been gathered
- Classified of cracked and cracked free parts.
- It has been shown that ESA will provide more successful solutions by using transfer functions

Keywords:

- Convolutional neural network,
- sheet metal crack,
- machine learning

Article Info:

Research Article

Received: 02.02.2021

Accepted: 26.01.2022

DOI:

10.17341/gazimmd.873479

Graphical/Tabular Abstract

In this study, crack identification and detection process in sheet metals, which is one of the most important issues especially for sheet metal forming companies, was investigated. Cracks in sheet material, which are frequently seen in mass production, cause vehicle scraps, so the degree of impact and cost are high. Crack tests were performed on 490 different sheets on sheet material in the 0.6-3 mm thickness range, and a crack image dataset was created for sheet material. In addition, 121 non-cracked "accepted-approved" parts were included in the dataset. Due to its superior feature extraction capability, convolutional neural network (CNN) has been widely researched, applied and outperformed other traditional machine learning methods in the field of intelligent fault diagnosis (Figure A). After that, the cracked and non-cracked part data in the sheet material was divided into training and test data, and the accuracy values of the system were tested by optimizing with different parameters. Here, accuracy and verification accuracy rates as 98.5% and 90% were achieved respectively.



Figure A. The graphs: sheet metal cracks rate per production, the results of prediction analysis by using convolutional neural network.

Purpose: The present study aims to predict of sheet metal cracks using with convolutional neural network and to improve accuracy rates with arranging its parameters.

Theory and Methods: Convolutional Neural Network (CNN) is a method in deep learning used for image classification, semantic segmentation, object detection and feature extraction. CNN belongs to the deep neural network type due to its high network depth and is widely applied to image data. CNN is used for image classification or object detection. Here, a training data set was created with cracked and non-cracked pieces collected from the pressshop. The model was created using Python. Using this model, the training set was validated against the items selected for testing.

Results: The CNN model was tested at different learning rates, training and test separation data rates and epoch (cycle). CNN epoch at 100, the accuracy rate of 86.75%; it has an accuracy rate of 98.5% in 2000 epochs. CNN learning rate (epoch at 1000) 0.1% accuracy rate 80.77%; 97.86% at 0.0002.

Conclusion: Here, accuracy rates such as 98.5% accuracy and 90% test data accuracy (validation accuracy) were achieved. These accuracy rates are high values and provide information about the reliability of the model and its ability to detect cracked and cracked free parts. This study will guide efforts to catch defect in the manufacturing sector.



Sac metal çatlaklarının evrişimli yapay sinir ağları ile tespit edilmesi (ESA)

İlhan Çekiç*^{ID}, Kadir Çavdar^{ID}

Bursa Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Makine Mühendisliği Bölümü, 16059 Görükle Bursa, Türkiye

Ö N E Ç I K A N L A R

- Özel bir çatlak sac parça veri seti oluşturuldu
- Çatlak ve çatlak olmayan sac parçaların tasnifi yapıldı
- ESA ile, transfer fonksiyonları kullanılarak daha başarılı çözümler getireceği gösterildi

Makale Bilgileri

Araştırma Makalesi

Geliş: 02.02.2021

Kabul: 26.01.2022

DOI:

10.17341/gazimmfd.873479

Anahtar Kelimeler:

Evrişimli sinir ağları,
sac metal çatlak,
makine öğrenmesi

ÖZ

Bu çalışmada, özellikle sac metal şekillendiren firmaların, en önemli konularından biri olan sac metallerde çatlak tanımlama ve tespit etme işlemi araştırılmıştır. Seri imalatta sıkılıkla görülen sac malzemedenki çatlaklar, araç ıskartalarına neden olduğu için etki derecesi ve maliyeti yüksektir. 0,6-3 mm kalınlık aralığında sac malzeme üzerinde 490 adet farklı sac üzerinde çatlak deneyleri yapılarak, sac malzeme için çatlak resim veri kümesi oluşturulmuştur. Ayrıca 121 adet çatlak olmayan "kabul edilen-onaylanan" parça, veri kümesine dâhil edilmiştir. Üstün özellik çıkarma yeteneği nedeniyle evrişimli sinir ağı (ESA), akıllı hata teşhisini alanında geniş çapta araştırılmış, uygulanmış ve diğer geleneksel makine öğrenme yöntemlerine kıyasla üstün performans göstermiştir. Daha sonra sac malzemedenki çatlaklı ve çatlaksız parça verileri eğitim ve test verilerine ve doğruluk değerlerine bölünmüştür. Burada, doğruluk ve doğrulama doğruluk oranları sırasıyla %98,5 ve %90 olarak elde edilmiştir. VGGNet mimarisi ile doğruluk değerleri, %98,75 ve %90'dır. Bu durum, hem hatalarla ait resim verilerinin hem de sunulan modelin güvenilirliği hakkında bilgi vermektedir. Araştırma sonuçları, seri imalat uygulamalarında çok önemli olan sac malzemedenki çatlak hatalarının tespitinde, temel oluşturacağı için önemlidir.

Detection of the cracks in metal sheets using convolutional neural network (CNN)

H I G H L I G H T S

- A dataset of sheet cracked images has been gathered.
- Classified of cracked and cracked free parts.
- It has been shown that ESA will provide more successful solutions by using transfer functions

Article Info

Research Article

Received: 02.02.2021

Accepted: 26.01.2022

DOI:

10.17341/gazimmfd.873479

Keywords:

Convolutional neural
network,
sheet metal crack,
machine learning

ABSTRACT

In this study, crack identification and detection process in sheet metals, which is one of the most important issues especially for sheet metal forming companies, was investigated. Cracks in sheet material, which are frequently seen in mass production, cause vehicle scraps, so the degree of impact and cost are high. Crack tests were performed on 490 different sheets on sheet material in the 0.6-3 mm thickness range, and a crack image dataset was created for sheet material. In addition, 121 non-cracked "accepted-approved" parts were included in the dataset. Due to its superior feature extraction capability, convolutional neural network (CNN) has been widely researched, applied and outperformed other traditional machine learning methods in the field of intelligent fault diagnosis. After that, the cracked and non-cracked part data in the sheet material was divided into training and test data, and the accuracy values. Here, accuracy and verification accuracy rates as 98.5% and 90% were achieved respectively. Accuracy values with VGGNet architecture are 98.75% and 90%. This gives information about the reliability of both the picture data of the faults and the model presented. The results of the research are important as they will form the basis for the detection of crack defects in sheet material, which is very important in mass production applications.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : *i_cekic@hotmail.com, cavdar@uludag.edu.tr / Tel: +90 549 596 7940

1. Giriş (Introduction)

Günümüzün otomobilinde pek çok sac parça kullanılmaktadır. Bu parçalar üretilirken, hat sonunda operatörler tarafından göz kontrolü ile bu hataların tesbit edilmesi hedeflenir. Göz ile kontroledilerek operatör dikkatsizliği, çatlak çizgisinin görünmez olması, hat içi ışıklandırmaının yetersiz olması vb. nedenler ile çatlak hataları tanımlanamayabilir. Ürünün teslim edildiği son noktada tespit edilen hataların yerine göre (malzeme giriş, hatyanı, yarı mamul ve mamul), azdan başlayarak katlanarak artan parça ayıklama/tarama ve iskarta/kalitesizlik maliyetleri oluşmaktadır. Bu durum firmaları hem maliyet hemde firma kalite hedefleri açısından ciddi olarak etkilemektedir. Şekil 1'de gerçek bir uygulamada karşılaşılan ve tedarik edilen parçalardaki çatlak oluşum miktarları görülmektedir. Buradaki hata miktarları tedarikçiden ana sanayiye giden adetler olup, firmaların kendi içerisinde tespit edilen iç iskarta ve parça taramalarda çıkan adetler bunlara dahil değildir. Bu miktarların ilave edilmesi ile bu değerler sürekli artacaktır. Bu çalışmanın amacı, sac üzerindeki çatlakların tespitidir.

Sac metaldeki çatlak tespiti ile ilgili farklı çalışmalar literatürde mevcuttur. Örneğin Gednay [1] tarafından; sac metale şekil verme mekanığı, çekme testi, şekil verme esnasında meydana gelen şekil değişikliği ve çatlak oluşumu ele alınmıştır. Bir başka çalışmada, tüm şekillendirme sınır diyagramının tahmini için olguya dayalı bir model geliştirilmiştir. Bu model, boyun verme ve sünek hasar teorilerine dayanmaktadır. Önerilen modelde, boşluk çekirdeklenmesi, esdeger plastik şekil değiştirmenin bir fonksiyonu, boşluk büyümesi ise gerilim üç eksenlilikin bir fonksiyonu olarak tanımlanmaktadır [2]. Lazer dalgaları ile yüzey taranarak, plaka üzerinde çatlak benzeri bir kusurun oluşumu, ultrasonik dalga biçimindeki anı bir değişiklik veya lazer ışının doğrudan çatlak üzerine yansıtıldığı dalga biçiminin frekans içeriğindeki artışıyla saptanabilir. Lazerle oluşturulmuş işık dalgaları, kırılma yoluya çatlakların etrafında ve ayrıca çatlakların altında açıkça yayılabilir. Bu durumun oluşma derecesi, frekansa ve levha kalınlığına bağlıdır [3]. Elektromanyetik kaynaklı yüksek yoğunluklu düşük akım darbesi tarafından üretilen akustik emisyon sinyali sayesinde, tüm yapıyı yüklemeden belirli alanları incelemek için ince cidarlı yapılarda küçük kusurlar veya çatlaklar tahrifatsız bir şekilde tespit edilebilir [4]. Sac malzemelerdeki kararsızlık sınıflarını karakterize etmek için form verme sırasında, malzeme davranışını analiz edilir. Nakajima testlerinin sonuçları bir optik ölçüm sistemi kullanılarak incelenir ve form verme limit eğrisi (FLE) için

tanımlanan sınıflara göre uzman görüşlerinin sonuçları dikkate alınarak doku özelliklerine dayalı geleneksel bir desen tanıma yaklaşımı kullanılarak çatlak tespiti yapılabilir [5]. Kırılma mekanlığında mod I ve mod II tarafından çatlak-acılma yoluyla kırılma arasındaki geçiş bölgesindeki göçme alanları araştırılabilir. Geleneksel sac metal testleri ile kesme kırılması oluşturma sınırı farklı kalınlıkta malzemeler için belirlenebilir. Kırılma alanları, tek noktadan deform olasına basit ve karmaşık geometrilerle doğrulanmıştır. Bu farklı geometriler, kırılan ve kırılan olmayan farklı gerilme yolları düzlem gerilimi, kayma ve iki eksenli deformasyon ile elde edilen veriler yardımıyla çatlak analizi yapılabilir [6]. Malzeme parametrelerinin form verme (şekillendirme) sınırı üzerindeki etkilerini dikkate alan akuple edilmemiş yeni bir sünek kırılma kriteri geliştirilebilir ve FLE eğrileri ile sonlu eleman kodları kullanılarak kolayca uygulanabilir. Yeni kriteri doğrulamak için çeşitli deneySEL testler kullanılabilir ve sonuçları da diğer iyi bilinen akuple edilmemiş sünek kırılma kriteri ile karşılaştırılarak çatlak analizleri yapılabilir [7]. Otomotiv firmaları şartnamesinde, genel olarak görsel olarak çatlak olmaması gereği yer almaktadır. Fiat Chrysler Otomobil (FCA) üretim şartnamesinde (şartname numarası 9.50207, 27 Temmuz 2017) preslenmiş parça kabul şartnamesinde, görsel olarak çatlak kabul edilmeyeceği belirtilmiştir. Delikli sacların üretimi, yüksek düzeyde mekanik gerilme ve deformasyon ile bilinir. Bu tür gerilim seviyeleri, işlenmiş tabakalarda çatlak oluşumuna yol açar. Yüksek frekanslı elektromanyetik alan kullanılarak bu çatlak ve hasarlar tespiti edilebilir [8]. Gerilim durumu parametreleri, çeşitli yükleme modları altında çatlak yayılma koşullarını belirlemek için uygulanır. Farklı gerilme durumlarda çatlak büyümesi ve kırılmasının özellikleri simülle edilir ve çatlak büyümeye yönleri ve modlarının, gerilme durumu parametreleri ile ilişkileri tartışılabılır [9]. Bir diğer çalışmada, çelik malzemelerdeki çatlakların tespiti ve 2D görüntüler yardımıyla çatlak derinliklerini tahmin etmek için yüksek 3D ölçüm cihazlarının yerine ekonomik ve kullanıcı dostu yeni bir denetim sistemi geliştirildi. Geri beslemeli geri yayılım sınır ağı kullanılarak çatlak derinliği yaklaşık %81,19 doğrulukta ölçülebilmiştir [10].

Çatlak riskini için yapılan bir çalışmada, Autoform yazılım programı yardımıyla gerçekleştirilen analiz çalışmalarında, yırtılmaya maruz kalacak kritik bölgeler tespit edilerek, geometride bazı iyileştirmeler yapılmıştır. Çalışmanın sonraki aşamasında her iki malzeme için de yırtılmaının gözlemediği bölgede oluşançentik etkisinin giderilmesi için parlatma işlemi, form değişikliği ve sonrasında ısıl işlem ile çatlak



Şekil 1. Tedarik edilen parçalarda karşılaşılan çatlak sayılarının değişimi _ Tofaş A.Ş. üretim verilerinden alınmıştır
(Changes in the number of cracks experienced in the supplied parts)

oluşumunun giderilebileceği gösterilmiştir [11]. Bir çatlak potansiyel olarak çatlak büyümeye olayı sırasında ve ayrıca aşınma yüzeylerinin sürtünmesi/kenetleme sırasında akustik emisyon (AE) sinyalleri üretebilir. Çatlaktan gelen her türlü AE sinyali, çatlaklı yapının durumu hakkında faydalı bilgiler sağlar. Böylelikle yapı içerisinde çatlak vb. yapı hataları ses dalgaları ile tesbit edilebilir [12]. İşleme parametreleri (form verme hızı, damgalama boşluğu ve pot basıncı) ile sac sekillendirme işleminin çatlak riski arasındaki ilişki araştırılabilir. Karar destek regresyonu (SVR) modelinin performansları, altı farklı regresyon metriği ile değerlendirilebilir. Buna göre, SVR modelinin en iyi performansa sahip olduğunu ve zirkonyum alaşımının sac sekillendirme prosesinin maksimum incelme oranını ve çatlağı doğru bir şekilde tahmin etme kapasitesine sahip olduğunu göstermektedir [13]. Yayılan çatlak ucunun etrafındaki mekanik koşulların tahmin edilmesi, kazara kırılma sırasında hasarı azaltmak için çok faydalıdır. Bu nedenle büyük ölçekli akma ile çatlak yayılımı için bir kriter oluşturmak sadece endüstriyel alanlar için de oldukça önemlidir. Büyük ölçekli akmaya sahip malzeme kırıklar için, çatlak ucu çevresindeki mikro veya orta ölçekli hasar süreçleri dikkate alınmalıdır. Buna çatlak ucu ve çevre bölgesinin mekanik davranışlarına karar verilebilir [14]. Çelik çatlaklarını tespit etmek ve 2D görüntülerden derinliklerini tahmin etmek için yeni bir sistem geliştirilmiş ve 2D çelik çatlak profillerinin ortalama yoğunlukları, bir öğrenme yapısını eğitmek için lazer mikroskopu ile ölçülen maksimum çelik çatlak derinliği ile birlikte sinir ağına beslenmiştir. En iyi test sonuçları ileri beslemeli geri yayılımda görülmüş olup genel ortalama test hatası %18,81'e eşittir [15]. Bir çatlak, çatlak büyümeye sırasında potansiyel olarak akustik emisyon (AE) sinyalleri üretebilir. AE sinyal üretimi ideal olarak, çatlak yüzeylerinde küçük bir sonlu alana etki eden bir kuvvette benzer şekilde tepeler ve vadiler arasındaki bir nokta etkileşimidir. Örnekler yardımıyla AE sinyallerini uyarmak için titreşirebilir ve statik yükün çatlak ovalama/sıkmasının AE sinyalleri üzerindeki etkisi incelenmiştir. Zaman alanı korelasyonu ve frekans alanı korelasyonu karşılaşıldığında, çatlak ovalama ve sıkmasından kaynaklanan AE sinyallerinin, kaynak özelliklerindeki rastgelelik nedeniyle küçük bir varyasyona sahip olduğu gösterilmiştir [16]. Haddeleme sırasında uygun olmayan proses ve çelik kalitesi nedeniyle, çatlak meydana gelebilir. Çatlak ve diğer sac kusurları için hızlı-ESA (R-CNN) gibi ağ yapıları kullanılabilir. Deneysel sonuçlar, önerilen yöntemle eğitilen derin öğrenme ağ modelinin iyi algılama performansına sahip olduğunu ve ortalama kesinliğin 0,752 olduğunu, yanı orijinal algoritmdan 0,128 daha yüksek olduğunu göstermektedir [17]. Kamera tarafından çekilen görüntüler işlendikten sonra yüzeysel kusurlar tespit edilebilir. Görme tabanlı yöntemlerin dezavantajlarının üstesinden gelmek için, evrişimli sinir ağları (ESA) kullanarak kızılıtesi termal görüntüleme çelik levhalardaki çatlakları tespit etmek için kullanılan bir yaklaşımda doğruluk ve ortalama hassasiyet (mAP) sırasıyla %95,54 ve %92,41'dir [18]. Şekillendirme prosesi başlamadan önce, malzemeye deformasyon uygulandığı zaman pekleşmeden dolayı malzemenin mukavemeti artırılabilimekte ve bu da sac metalin çatlak hasarına karşı direncini artırmaktadır. Hidromekanik sıvama yönteminde öndeşirme yaparak malzemenin erkek kalbin burun radyüslerini saran bölgelerinin pekleşmesiyle yırtılmaya karşı direnci artar, böylece daha yüksek sıvama oranı sınırlarına ulaşılabilir [19]. Al7075-T6 alüminyum sac malzemelerin bükme ile sekillendirilebilirliği, 140°C'ye kadar yüksek bükme açıllarında ve keskin zimba uç yarıçapları için geri esneme değerlerini deneyssel olarak analiz edilebilir. Lazer yöntemiyle bükme bölgesinin ısıtılmasını, yüksek açılarda bükme işlemi sırasında her iki tür malzeme için de çatlak riskini azalttığı görülebilir [20]. Bu nedenlerden biri veya birkaçının bir araya gelmesi ile hata oluşabilir. Ancak, burada önemli olan bir milyondan fazla parçada sadece bir kez çatlak ile karşılaşmasıdır. Seri imalatta, on yıl boyunca sadece bir kez çatlakın görüldüğü ve sonrasında hiçbir çatlak olmuşmayan, pek çok parça ile karşılaşılabilmektedir. Hata analizi yapıldığında, proses

şartları abartılarak (kalıp dayama, kaydırma, pot basıncı artırma vb.) hatanın simülasyonu için yapılan çalışmada, hatanın tekrar olusmadığı pek çok kez tecrübe edilmştir. Bu durum, hatanın tekilliğinden öneML olup hata için farklı sac tiplerinde ve çeşitlilikte veri toplamanın da ne kadar zor olduğunu/olacağının göstergesidir. Bu nedenle, çatlak ile ilgili yapılan bilimsel çalışmaların Autoform gibi analiz programları üzerinden, sanal sinir şartlarının değiştirilmesiyle veya sadece laboratuvar şartlarında tek parça üzerinde yapılan çalışmalarla kısıtlı kaldığı görülmektedir. Evrişimli sinir ağları (ESA) için en önemli konu, pek çok varyasyonu içeren çoklu öğrenme veri ve resimlerin toplanarak veri setinin oluşturulmasıdır. Fakat bu süreç, prosesin kendi doğası gereği, maliyet, pek çok hatanın tekilliği ve teknolojik kısıtlar nedeniyle kolay değildir. Bu nedenle literatürde, bu tip çatlak hatasının ESA ile belirlenmesi, çoklu veri seti içeren çalışmalarla sınırlıdır. Burada sunulan araştırmada, gerçek atölye çalışmasının yanısıra, yıllar boyunca yaşanmış tedarikçi hatalarının verilerinden yararlanarak, öğrenme yüzdesi artırılmıştır. Bu çalışma, sıcak veya soğuk haddelenmiş sac metal çatlakları için yapılmıştır.

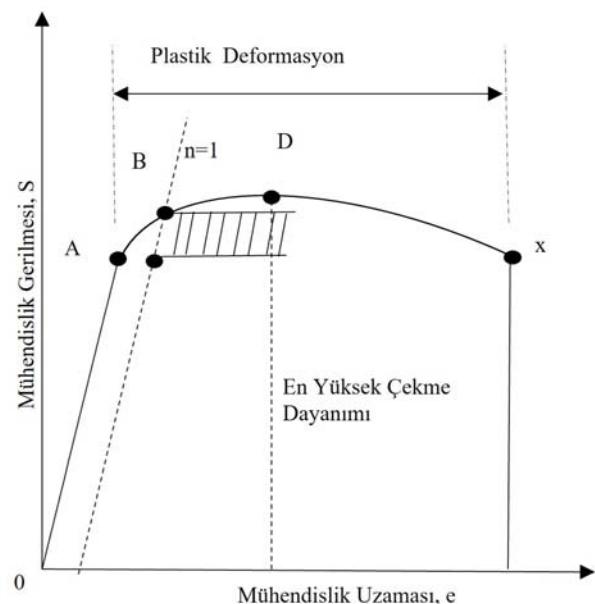
Otomotiv sektöründe, seri imalat koşullarında, sac metaldeki çatlak belirlendikten sonra, parça/yarı mamül/gövde veya komple araç, sac metaldeki çatlak boyutlarına (en, boy, derinlik) bakılmaksızın ıskarta edildiği için, burada sadece çatlak hatasının tespit edilebilmesi çok önemlidir.

2. Deneyel Metod (Experimental Method)

Bu bölümde, öncelikle sac metaldeki şekil değişim mekanığı ile, çatlak teorisini analiz edildikten sonra evrişimli sinir ağları yapısı incelenecektir.

2.1. Şekil Verme (Forming)

Şekillendirme, bir malzemenin kırılmadan veya aşırı incelmeden önce dayanabileceğİ deformasyon miktarının ölçüsüdür. Bu nedenle, bir malzemenin hangi oranda deform olabileceğinin belirlenmesi, yeniden üretilen bir şekillendirme programının tasarlanması için gereklidir. Şekil 2'de gösterilen grafikte, X: çatlak $dP=0$ noktasındaki boyun vermenin başlangıç bölgesi D noktası olmak üzere, taralı alan uzama-sertleşme katsayısını hesaplamak için kullanılır.



Şekil 2. Gerilme-uzama grafiği (Graph of stress-strain) [1]

2.1.1. Süneklik Ölçümü (Ductility Measurement)

Şekil 2'deki A noktası, malzemenin orantı limitini gösterir. Bu noktadan sonra yükleme devam ederse malzemede plastik deformasyon görülür. Oransal limiti hesaplamak zor olduğu için, dengeleyici akma gerilmesi ve yük altında uzama (YAU) olarak bilinen iki pratik ölçüm geliştirilmiştir. Son çekme gerilmesi veya tepe gerilmesi ise grafikteki D noktasıdır. Gerilme-uzama eğrisindeki boyun vermenin başladığı noktası, $dP = 0$ olduğu D tepe noktasıdır. Akma ve çekme dayanımı doğrudan şekil verme ile ilişkili değildir. Ancak, iki gerilmenin büyüklüğü birbirine ne kadar yakın ise metalin çalışma sertliği de aynı oranda artar. Bu durumda, uzama kabiliyeti, yani süneklik azalır.

Süneklik, plastik deformasyon kapasitesini belirleyen bir ölçütür. Toplam uzama ve kopma büzülmesi olmak üzere iki ölçüttü vardır. Toplam uzama; kırılmadaki tek eksenli gerilme miktarıdır ve Şekil 2'de Z noktasındaki uzama olarak tanımlanmıştır. Hem elastik hem de plastik deformasyonu içeren kopmadaki yüzde uzama, Eş. 1 ile verilmiştir:

$$\text{Kopma uzaması (\%)} = e_z = 100x (L_z - L_0)/L_0 \quad (1)$$

Kopma uzaması gibi sünekliğin başka bir ölçüsü olan kopma büzülmesi, Eş. 2 nolu denklemde ifade edilmiştir. Kırılma noktasındaki kesit alanı ölçüerek alandaki azalma Eş. 2 ile hesaplanır:

$$\text{Kopma büzülmesi (\%)} = 100x (A_0 - A_z)/A_0 \quad (2)$$

Genellikle, kesit büzülmesi arttıkça, bir sac malzeme için izin verilen minimum eğilme yarıçapı azalır. Toplam uzama ve kopma büzülmesi, numunenin kesit alanı arttıkça artar. Yüzde kopma uzaması, numunedeki lokal boyun verme nedeniyle artan ölçü uzunluğu ile azalır. B ve D noktaları arasındaki uzama-sertleştirme bölgesindeki gerilme-uzama eğrisinin uzunluğu; gerçek gerilme σ , mukavemet katsayısı K , gerçek uzama ϵ ve n , uzama sertleşme katsayısı olmak üzere Eş. 3 yardımıyla hesaplanır [1].

$$\sigma = K\epsilon^n \quad (3)$$

Deformasyon sertleşmesi (pekleşme) kabiliyetini gösteren n değeri arttıkça boyun verme zorlaşıır ve böylece homojen şekil değiştirme kabiliyeti artar.

2.1.2. Çatlak Nedir? (What's Crack?)

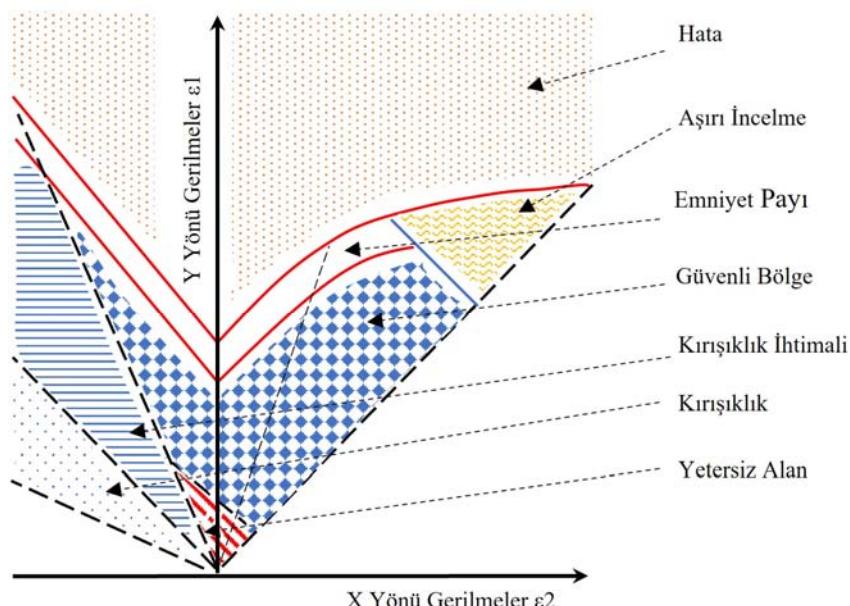
Metaller, elastik ve plastik deformasyon gösteririler. Bununla birlikte farklı metallerin çekme diyagramları da farklıdır. Örneğin yumuşak çelik, elastik deformasyondan plastik deformasyona geçişte sürekli akma noktası gösterir. Seramik, dökme demir ve yüksek mukavemetli malzemelerde, genellikle plastik deformasyon olmuşadan, elastik deformasyonun sonunda kopma olur. Bazı malzemeler ise aşırı oranda homojen plastik deformasyona uğrarlar.

Kırılma çatlak oluşumu ve ilerlemesiyle meydana gelen durum, numunenin gerilme altında iki veya daha çok parçaya bölünmesiyle sonuçlanan bir olaydır. Kırılmanın karakteri, genellikle uygulanan gerilmeye, sıcaklığı ve deformasyon hızına bağlı olarak malzemeden malzemeye değişir. Kırılma, kırılma anındaki deformasyon miktarı, kırılma yüzeyinin kristalografik görünümü ve kırık yüzeyin makro görünümü gibi çeşitli kriterlere göre sınıflandırılır.

İmalatta şekil verme sırasında, soğuk ve sıcak haddelenmiş malzemenin derin çekme işlemi sürecinde oluşan çatlamlar gibi özellikle sac malzemede çatlama olabilir. Son yıllarda artan sac şekillendirme işlemleri sonrasında üretimde karşılaşılan hataların erken tespiti için sonlu elemanlar yazılımı yaygın olarak tercih edilmektedir. Yüzeydeki birim şekil değişimlerinin tespiti ile şekillendirme sınır eğrileri elde edilerek sonlu elemanlar yazılımına malzeme girdileri işlenmesiyle, üretimde karşılaşılacak hataların erken tespitini mümkün kılmaktadır, Şekil 3 [11].

2.2. Evrişimli Sınır Ağı (ESA) İşlemleri (Convolutional Neural Network (CNN) Transactions)

ESA, görüntü sınıflandırma, anlamsal bölümleme, nesne algılama ve özellik çıkarma için derin öğrenmede kullanılan bir yöntemdir. Yüksek ağ derinliği nedeniyle derin sınır ağı türüne dahildir ve yaygın olarak görüntü verilerine uygulanır. ESA, genellikle görüntü sınıflandırması veya nesne tespiti için kullanılır. Nesne algılama



Şekil 3. Şekillendirme sınır eğrileri - FLD (Forming Limit Diagram) [11]

işlemi, ESA ile bilgisayarın bilgi almasını sağlayan evrişim sürecini kullanması ile gerçekleştirilebilir. Evrişimli sınır ağı, çıkarma katmanı ve tamamen bağlı katman özelliği olmak üzere iki ana bölüme ayrılmıştır. Özellik çıkarma, bir evrişimli katman ve bir havuz katmanından oluşur. Diğerlerinin yanı sıra ESA'daki işlemler, aşağıda verilen bölümlerde sıralanmıştır.

2.2.1. Veri ön işleme ve veri büyütme (Data preprocessing and data augmentation)

Ön işleme; resimlere uygulanan erozyon, genişleme, açma-kapama, normalizasyon ve veri artırma işlemleridir. Derin öğrenme sınırlarının performansı, genellikle mevcut veri miktarı ile artar. Veri artırma, mevcut eğitim verilerinden yapay olarak yeni eğitim verileri oluşturma tekniğidir. Burada, yeni ve farklı eğitim örnekleri oluşturan öğrenme ile birlikte eğitim verilerinden yararlanarak alana özgü teknikler uygulanır. Görüntü verisi artırma, bilinen en iyi veri büyütme türüdür ve orijinal görüntü ile aynı sınıfına ait olan eğitim veri kümelerindeki görüntülerin dönüştürülmiş sürümlerinin oluşturulmasını içerir. Şekil 4'te verilen örnek uygulamalar ile bu işlem, doğruluk oranını olumsuz etkileyen ezberleyici yaklaşımı önemlere ve modelin daha iyi genelleşmesine yardımcı olur.

2.2.2. Evrişim katmanı (Convolution layer)

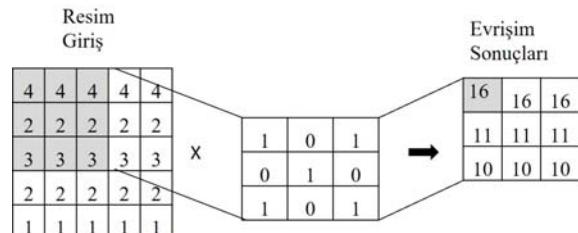
Bu katman, filtre ile görüntü arasında evrişim sürecini yürüterek görüntüdeki dokuyu/desenin bulmaya yarar. ESA'nın temelini oluşturan bu katman dönüşüm katmanı olarak da bilinir. Bu dönüşüm işlemi belirli bir filtrenin tüm görüntü üzerinde dolaştırılması işlemine dayanmaktadır. 2×2 , 3×3 , 5×5 gibi farklı boyutlarda olabilen filtreler, bir önceki katmandan gelen görüntülere konvolusyon işlemini uygulayarak çıkış verisini oluştururlar. Bu konvolusyon işlemi sonucu aktivasyon haritası belirlenir.

Şekil 5'te gösterildiği gibi giriş görüntüsü kullanılarak filtre matris çarpımından sonra elde edilen evrişim katmanın sonuçları, şeklä sağ tarafındadır.

2.2.3. Havuzlama katmanı (Pooling)

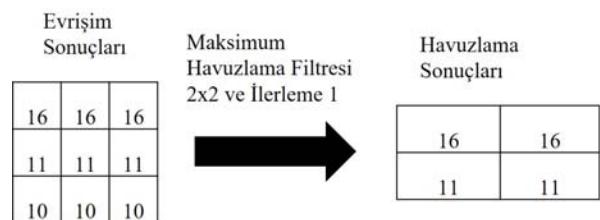
Temel amacı, sonraki konvolusyon katmanı için giriş boyutunu (genişlikxyükseklik) azaltmaktadır. İlk basamakta gerçekleştirilen

konvolusyon işlemi gibi, havuzlama katmanında da belli filtreler tanımlanır. Bu filtreler, görüntü üzerinde belli bir adım atma değerine göre gezdirilerek görüntüdeki piksellerin maksimum değerlerine (maksimum havuzlama) veya değerlerin ortalamasına (ortalama havuzlama) göre işlem yapılır.



Şekil 5. Evrişim katmanı işlemi (Process of convolutional layer)

Şekil 6'daki gibi bu katman, maksimum havuz filtresini 2×2 kullanarak ve 1 adım ilerleyerek veya filtreyi 1 kaydırarak maksimum değere ulaşır.

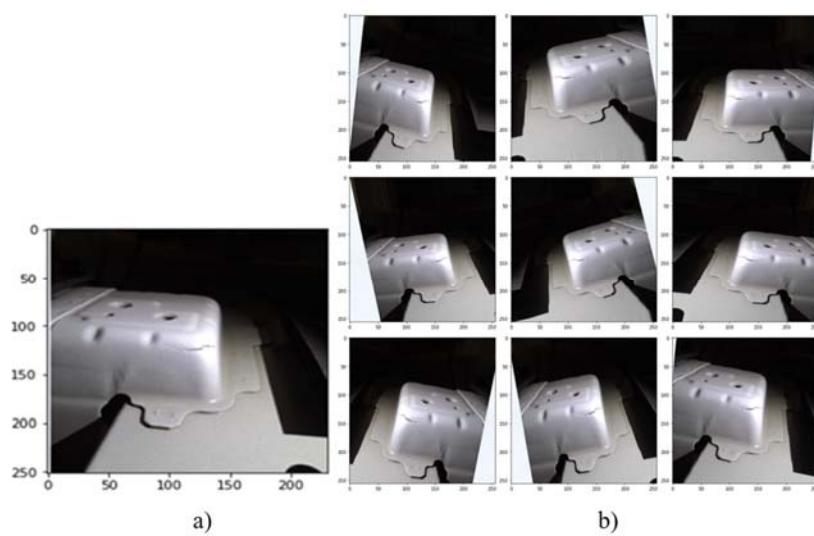


Şekil 6. Havuzlama katmanı işlemi (Process of pooling layer)

Havuzlama katmanından elde edilen sonuçlar, en önemli değerlerdir. Bu katmandaki sonuçlar, bir sonraki süreçte, tamamen bağlı katmana aktarılacaktır.

2.2.4. Tamamen bağlı katman (Fully connected layer)

ESA mimarisinde ard arda gelen evrişimle, ReLu (doğrultulmuş lineer birim) aktivasyon fonksiyonu ve havuzlama katmanından sonra tam



Şekil 4. Veri ön-isleme ve veri çoğaltma a) orijinal b) döndürme oranı, enin değişmesi, akma oranı, yakınlaşma-uzaklaşma oranı, yatay çevirme, doldurma modu gibi farklı parametrelerin uygulandığı örnekler (bu çalışma oluşturulan algoritmanın çıktısından alınmıştır)
(Data pre-processing and data augmentation a) original picture b) the way different parameters such as rotation_range, width_shift and height_shift, rescale, shear_range, zoom_range, horizontal_flip, fill_mode are applied)

bağlantılı katman gelir. Bu katman kendinden önceki katmanın tüm alanlarına bağlıdır. Farklı mimarilerde bu katmanın sayısı değişebilir. ESA mimarisinde en son katmanın üretmiş olduğu matris boyutu $25x25x256=160000x1$ ve tam bağlantılı katmandaki matris boyutu $4096x1$ olarak seçilirse, toplamda $160000x4096$ ağırlık matrisi oluşur. Yani her bir 160000 nöron 4096 nöron ile bağlanmaktadır. Bu nedenle, bu katmana tam bağlantılı katman olarak isimlendirilir.

2.2.5. Sigmoid aktivasyon fonksiyonu (Sigmoid activation function)

Sigmoid, 0 ve 1 aralığı arasındaki değerleri dönüştüren karakteristik "S" şeklinde bir eğriye sahip matematiksel bir işlevdir. Sigmoidal eğri veya lojistik işlev olarak da adlandırılan sigmoid, en yaygın kullanılan doğrusal olmayan aktivasyon fonksiyonlarından biridir.

Bu çalışmadaki algoritmada aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmıştır [21]:

$$\sigma(z) = \frac{1}{1+e^{-z}} \quad (4)$$

Eş. 4, $\sigma(z)$ sigmoid fonksiyondur. Burada z değeri, sinir ağlarına giriş değeri ile ağırlıklar çarpılır ve bu çarpımlar toplanarak bulunur. Eğer z 'nin değeri pozitif sonsuz giderse, o zaman y 'nın tahmin edilen değeri 1 olur ve negatif sonsuz giderse o zaman y 'nın tahmin edilen değeri 0 olur.

2.2.6. Farklı çatlak tiplerinin, farklı görüntülerdeki parçalar için tahmin edilmesi (Estimating different crack types for pieces with different appearances)

Çatlak olmayan çok sayıda sağlam parça içerisinde, çatlak parçanın görsel olarak kontrol edilmesi oldukça zor bir işlem olduğu için hata olasılığı yüksektir. ESA, oldukça yeterli bir doğrulukta çatlığı belirleyen bir algılama yöntemidir. Farklı konumlardaki parçaların sayısındaki eksiklik veya yetersiz ışık şiddeti gibi olumsuz etkenlerin olması durumunda da, ESA yöntemi ile pek çok parça içerisinde çatlak parça algılanabilir ve çatlak tipleri sınıflandırılabilir. Ancak, sac malzemelerdeki patlak, derin batma, çentik vb. imalat hataları da çatlak hataları şeklinde algılanıp, parçanın uygunsuz olarak değerlendirilmesine neden olabilir.

2.2.7. Farklı çalışma konuları için derin yapılandırılmış evrişimli sinir ağı (ESA) (Deep structured convolutional neural network (CNN) for different study subjects)

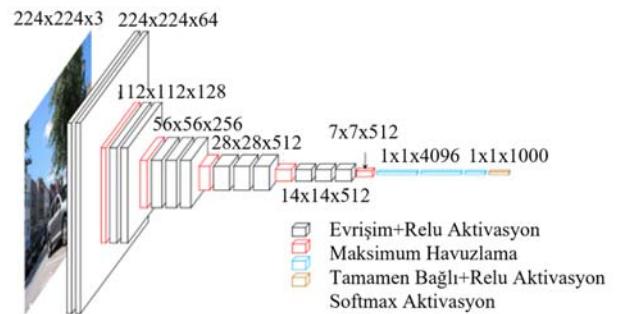
Makine öğrenimi ve nesneleri tanımak için yeni bir teknolojiye ihtiyaç vardır. ESA, nesne algılama ve derinlemesine nesne tanımlamada kullanılan teknik bir yöntemdir. Çatlak parça seçimi, oluşturulan bölüntü kümelerinin güvenilirliğinin garanti edilmesi açısından son derece önemlidir. Veri kümesi için toplanan veriler ile görüntü veri kümesi arasında doğrusal bir ilişki olmadığı için görüntünün sınıflandırılması oldukça zor bir işlemidir. Örneğin aynı olmayan başka bir çatlak tipi ve çatlak türleri ile şekilleri benzerlik gösteren başka çatlak görüntüleri bulunur. ESA, görüntü sınıflandırma ve nesne algılama için çok etkili bir sinir ağı sınıfıdır. ESA modeli kullanılarak çatlak ve çatlak olmayan veri seti sınıflandırması %98,5 doğruluk ile elde edilmiştir. Literatür incelemelerinde, ESA yapısına AlexNet, VGGNet, ResNet, Inception, DenseNet gibi derin evrişimli diğer sinir ağlarının ilave edilmesi ile sistem performansının artırıldığı çalışmalar mevcuttur. Bu çalışmaldaki doğruluk değerleri 0,68 ile 0,99 arasında değişmektedir.

2.2.8. VGGNet Mimarisi (VGGNet Architecture)

Şekil 7'de gösterilen model, 2014 yılında ILSVRC yarışmasında görsel geometri grubu tarafından geliştirilmiş, grafik işlem birimi

(GPU) destekli basit bir evrişimsel sinir ağı modelidir. ILSVRC yarışmasında %89 başarı oranında çalışan derin öğrenme algoritmasıdır. 20.000'den fazla kategoriye ait 14 milyondan fazla resmin bulunduğu veri tabanı eğitim seti (ImageNet training database) üzerinden hesaplanan ortalama görüntü değerlerini çekarr.

ESA modeline VGGNet yapısı eklenmeden önce, algılamadaki doğruluk %98,5 iken VGGNet eklendiğinde, bu doğruluk değeri %98,75'e ulaşmaktadır.



Şekil 7. VGG16 transfer fonksiyonunun yapısı
(Structure of VGG16 transfer function) [22]

2.2.9. Test sonuçları (Test result)

Bu araştırmada, farklı işlem şartlarında, çok sayıda parça üzerinde form verme işlemi yapılmıştır. Bu çalışma sadece sac metal parçalar baz alınarak yapıldığı için bu malzemelerde kapsar. Bu çalışma sonucunda 611 adetlik bir çatlak kütüphanesi oluşturulmuş ve 490 adet çatlak parçayı içeren veri seti örnekleri, Şekil 8'de verilmiştir. Çatlak olmayan 121 adet parçadan oluşturulan ayrı bir veri seti de Şekil 9'da gösterilmiştir.



Şekil 8. Çatlak parça örnekleri (Cracked part samples)



Şekil 9. Çatlak olmayan parça örnekleri (Non cracked part samples)

Resimleri tarayacak sistemin verileri eğitim ve test olmak üzere iki grupta ele alınarak veri bölmeye fonksiyonunda çalıştırılacaktır. Tablo 1'deki veri dağılımasına göre veri toplama fonksiyonundaki gruplar, 5 farklı aşamada eğitilmiş ve test edilmiştir. Eğitilen ve test edilen verilerin yüzdelik değerlerindeki her bir aşamaya karşılık gelen görüntü sayıları sırasıyla, 61 ve 150 görüntü; 489 ve 122 görüntü, 428 görüntü ve 183 görüntü; 367 ve 244 görüntü ile son aşamada ise 305 ve 306 görüntü olarak bölmüştür. Burada, test edilen verilere ilişkin veri böltünlüleri, Tablo 2'de verilmiştir. Tablo 1 ve Tablo 2'deki veri

setlerinin değerlendirme ölçütleri, Tablo 3'teki veri dağılımına göre doğruluk derecesidir.

ESA modelinde, çat�ak resmini tanımak için en iyi sistemin çevrim ve öğrenme oranı test edilmelidir. Veri kümesi, tüm sinir ağı düğümleri üzerinden bir kez ileri ve geri süreç boyunca derlenir. Tablo 4'te çevrim oranı ile yüzde doğruluk değerleri karşılaştırılmıştır.

Tablo 1. Veri dağılımı (Separation of data)

Test Verileri (%)	Eğitim Verileri (%)	Resim Boyutu	Resim Boyutu
1 10	90		
2 20	80		
3 30	70	196x417min 2322*4128max	<4128Kb
4 40	60		
5 50	50		

Tablo 2. Toplam veri seti dağılımı (The total distribution of data set)

Test Sırası	Test Verileri (%)	Eğitim Verileri (%)	Toplam Test Verileri Resim Adedi	Toplam Eğitim Verileri Resim Adedi
1	10	90	61	550
2	20	80	122	489
3	30	70	183	428
4	40	60	244	367
5	50	50	305	306

Tablo 3. Eğitim ve test veri oranlarının doğruluk (%) değerleri ile karşılaştırması

(Comparison of train/test rate- % accuracy)

Öğrenme oranı: 0,0002 Çevrim sayısı: 1000	Doğruluk (%)
Eğitim/test oranı	
%90 öğrenme verisi, %10 test verisi	97,73
%80 öğrenme verisi, %20 test verisi	97,86
%70 öğrenme verisi, %30 test verisi	95,61
%60 öğrenme verisi, %40 test verisi	96,32
%50 öğrenme verisi, %50 test verisi	97,55

Öğrenme oranı, sistemin en yüksek doğruluk değerini belirleyen önemli parametrelerden birisidir. Tablo 5' den görüleceği üzere, sistem ile öğrenme oranı arasında ters orantılı bir ilişki oluşurken öğrenme oranı, zaman (t) ile doğrusal olarak değişmektedir. Bunun nedeni ise öğrenme oranının değeri ne kadar düşük ise hata/kayıp

değeri azalacağından tespit edilen değerin doğruluk oranının artmasıdır. ESA modelinin temel yapısı, Tablo 6'da verilmiştir.

Tablo 4. Çevrim sayısı- doğruluk (%) karşılaştırması
(Comparison of epoch-% accuracy)

Öğrenme Oranı: 0,0002	
Çevrim	Doğruluk (%)
100	86,75
300	91,88
500	96,15
1000	97,86
2000	98,50

Bu çalışmada, 3.9.6 versiyonunda Python programı kullanılmış ve aşırı öğrenmeyi önlemek için toplu normalleştirme (batch normalization) uygulanmamıştır. Bunun yerine ayışma (dropout) ve erken durdurma (early stopper) yöntemleriyle algoritma normalleştirilmiştir.

Tablo 5. Öğrenme oranı- yüzde doğruluk oranı karşılaştırması
(Comparison of learning rate- % accuracy rate)

Çevrim sayısı: 1000	Eğitim/test veri oranı (%): 80/20
Öğrenme Oranı	% Doğruluk
0,1	80,77
0,01	79,49
0,001	92,31
0,0001	95,73
0,0002	97,86

3. Sonuçlar ve Tartışmalar (Results and Discussions)

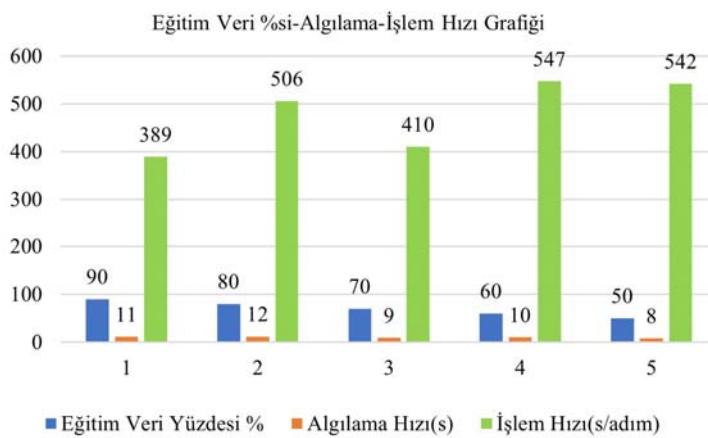
1. Bu çalışmada, farklı eğitim verisi yüzdesine göre, çevrim süresi ve hızı incelenmiştir. Şekil 10'da karşılaştırılan bu veri setine göre, eğitim veri oranı ile zaman ve işlem hızı arasında doğrudan bir ilişki bulunmamaktadır.

2. Farklı çevrim sayısı ile zaman ve hız arasındaki ilişki incelenmiştir. Şekil 11'deki verilere göre, çevrim sayısı ile zaman ve hız arasında da doğrudan bir ilişki yoktur.

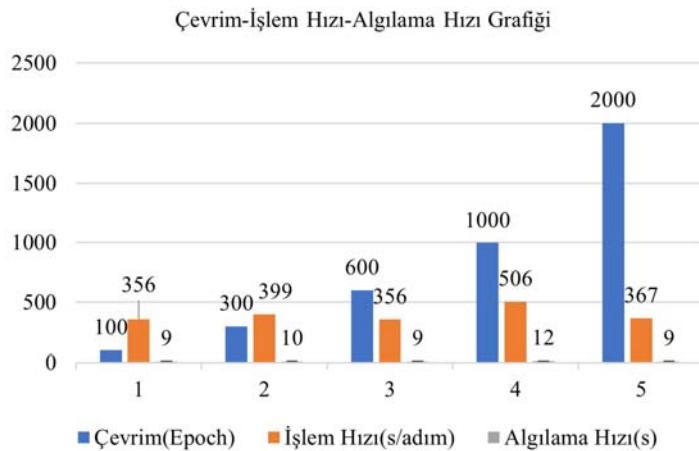
3. VGGNet katmanlı model kullanılarak, farklı çevrim olanları ile doğruluk ve val doğruluk değerleri incelenmiştir. Buna göre, Tablo 7'de çevrim oranı ile doğruluk değeri artmıştır. En yüksek test doğruluk oranı, çevrim oranında 100' de görülmüştür. 4. VGGNet katmanlı model kullanılarak, çevrim oranı 100'de doğruluk ve test doğruluk değerleri incelenmiştir. Buna göre, Tablo 8'de öğrenme oranı düşüğünde değeri artmıştır.

Tablo 6. ESA temel yapısı (CNN baseline structure)

Katman	Katman (tip)	Cıktı (Şekil)	Parametre #	
1 Aktivasyon Rectifier	konv2d_15 (Konv2D)	(None, 62, 62, 32)	896	
	Aktivasyon 25	(None, 62, 62, 32)	0	
	Maksimum havuzlama	Maks. havuzlama 2d_15	(Maks Havuzlama (None, 31, 31, 32	0
2 aktivasyon Rectifier	conv2d_16 (Konv2D)	(None, 29, 29, 32)	9248	
	Aktivasyon 26	(None, 29, 29, 32)	0	
	Maksimum havuzlama	Maks. havuzlama 2d_16	(Maks Havuzlama (None, 14, 14, 32)	0
3 Aktivasyon Rectifier	konv2d_17 (Konv2D)	(None, 12, 12, 64)	18496	
	Aktivasyon_27	(None, 12, 12, 64)	0	
	Maksimum havuzlama	Maks havuzlama 2d_17	(Maks. Havuzlama (None, 6, 6, 64)	0
4 Düzleştirme Rectifier	Düzleştirme_5	None, 2304)	0	
5 Gizli katman	Gizli katman_10	(None, 128)	295040	
6 Aktivasyon Rectifier	aktivasyon_28	(None, 128)	0	
7 Ayrıntılandırma	Ayrıntılandırma5	(None, 128)	129	
8 Aktivasyon Sigmoid	Aktivasyon_29	(None, 1)	0	
Toplam Parametre Sayısı---323,809				



Şekil 10. Eğitim verisi (%)- algılama hızı (s) ve işlem hızı (s/adım) karşılaştırması (bu çalışmada kullanılan algoritmanın çıktısından alınmıştır)
(Comparison of train data % rate-detection speed and process speed)



Şekil 11. Çevrim sayısı-işlem ve algılama hızı karşılaştırması (Comparison of epoch, detection speed and process speed)

Tablo 7. VGG16 fonksiyonu ile çevrim sayısı- doğruluk (%) karşılaştırması
(Epoch number vs. accuracy (%)) with VGG16 function)

Öğrenme oranı	Doğruluk (%)	Val doğruluk (%)
0,1	18,75	12,5
0,01	81,94	82,5
0,001	86,67	90
0,0001	96,77	77,5
0,0002	97,42	92,5

Tablo 8. VGG16 fonksiyonu ile öğrenme oranı sayısı- doğruluk (%) karşılaştırması
(Number of learning rate vs. accuracy (%)) with VGG16 function)

Öğrenme oranı	Doğruluk (%)	Val doğruluk (%)
0,1	18,75	12,5
0,01	81,94	82,5
0,001	86,67	90
0,0001	96,77	77,5
0,0002	97,42	92,5

5. Transfer fonksiyonları ile doğruluk değerleri, çevrim oranı 100'de doğruluk ve test doğruluk değerleri incelenmiştir. Buna göre, Tablo

9'da doğruluk değerine göre Resnet50, test doğruluk değerine göre de VGG16 ile en yüksek doğruluk değerleri elde edilmiştir.

Tablo 9. Transfer fonksiyonları ile doğruluk (%) karşılaştırması
(Accuracy (%)) comparison with transfer functions)

Transfer fonksiyon	Doğruluk (%)	Val doğruluk (%)	Test doğruluk (%)
VGG16	90,32	90	87,5
VGG19	89,03	80	80
Xception	96,56	70	70,37
Inception ResnetV2	89,68	90	87,03
Resnet50	96,79	84,23	84,81
Inception V3	92,99	75	79,62
Resnet152	95,05	80	77,77

4. Simgeler (Symbol)

ESA: : evrişimli sinir ağları
SVR: : karar destek regresyonu

YAU: : yük altında uzama
 e_z : : yüzde kopma uzaması
 σ : : gerçek gerilme
 K: : mukavemet katsayısı
 ε : : gerçek uzama
 n: : uzama katsayısı
 Rectifier: aktivasyon fonksiyonudur (doğrultulmuş lineer birim)

5. Sonuçlar (Conclusions)

Eğitim verilerinde %98,5 test verilerinde ise %87,5 doğruluk oranı elde edilmiştir. Tablo 3'teki eğitim-test seti oranları ve yüzde doğruluk oranı ile mevcut veri seti arasında doğrudan bir ilişki görülmemiştir. Tablo 4'teki verilere göre çevrim sayısı arttıkça, yüzde doğruluk değeri de artmaktadır. Tablo 5'te gösterildiği gibi öğrenme oranlarına göre doğruluk değerleri değişimde ve öğrenme oranı azaldıkça, doğruluk değeri artmaktadır. Farklı transfer fonksiyonları kullanılarak, doğruluk oranının daha da arttığı, Tablo 9'da gösterilmiştir.

Daha sonraki işlemlerde, algoritmada yapılacak farklı ayarlar (ayırışma, öğrenme oranları, farklı optimizasyon ayarları, farklı gizli katmanlar vb.) ile öğrenme oranları ve kayıp fonksiyonları iyileştirilebilir. Ayrıca veri setindeki çatlak ve çatlak olmayan örnek sayısı artırılarak, yüzde doğruluk değeri artırılabilir. Bu öğrenme verileri eğitim datası olarak kullanılarak, çoklu kameralar ile tekrarlanan evrişimsel yapay sinir ağlarında mevcut olan recurrent 3D convolutional neural network-R3DCNN, Fast R-CNN, FasterFaster R-CNN gibi metodlar yardımıyla atölye koşullarında, hat sonunda (inline) hata tespit araştırmaları da yapılabilir.

Kaynaklar (References)

1. Gedney R., Sheet metal formability, Advanced Materials & Processes, 160 (8), 2002.
2. Paul K.S., Manikandan G., Verma K. R., Prediction of entire forming limit diagram from simple tensile material properties, The Journal of Strain Analysis for Engineering Design, 48-386, 2013.
3. Dixon S., Burrows S.E., Dutton B., Fan Y., Detection of cracks in metal sheets using pulsed laser generated ultrasonda and EMAT detection, Ultrasonics, 51, 7–16, 2011.
4. Jin L., Yang Q., Liu S., Zhang C., Li P., Electromagnetic stimulation of the acoustic emission for fatigue crack detection of the sheet metal, IEEE Transactions on Applied Superconductivity, 20 (3), 1848 – 1851, 2010.
5. Affronti E., Jaremenko C., Merklein M., Maier A., Analysis of forming limits in sheet metal forming with pattern recognition methods. Part 1: characterization of onset of necking and expert evaluation, Materials, 11 (9), 1495, 2018.
6. Jawale K., José Ferreira Duarte J.F., Reisa A., Silva M.B., Characterizing fracture forming limit and shear fracture forming limit for sheet metals, Journal of Materials Processing Tech., 255, 886–897, 2018.
7. Dizajia S.A., Darendeliler H., Kaftanoğlu B., Prediction of forming limit curve at fracture for sheet metal using new ductile fracture criterion, European Journal of Mechanics, 69, 255–265, 2018.
8. Dastjerdi M.H., Rubesam M., Ruter D., Himmel J., Kanoun O., Nondestructive testing for cracks in cracks in perforated sheet, 8th International Multi-Conference on Systems, Signals & Devices, Sousse-Tunisia, 22-25 March, 2011.
9. Xue F., Li F., Li J., He M., Yuan Z., Ruiting Wanga, Numerical modeling crack propagation of sheet metal forming based on stress state parameters using XFEM method, Computational Materials Science, 69, 311–326, 2013.
10. Mohamed Y.S., Shehata H.M., Abdellatif M., Awad T.H., Steel crack depth estimation based on 2D images using artificial neural networks, Alexandria Engineering Journal, 58 (4), 1167-1174, 2019.
11. Tuyan M., Demirer A., Sac Kalıplama Prosesinde DD13 ve S355MC Malzemelerin Yırtılma Probleminin İncelenmesi ve Çözümü, Avrupa Bilim ve Teknoloji Dergisi, 20, 872-880, 2020.
12. Joseph R., Bhuiyan M.Y., Giurgiutiu V., Engineering Fracture Mechanics, 217, 2019.
13. Lei C., Mao J., Zhang X., Wang L., Chen D., Crack prediction in sheet forming of zirconium alloys used in nuclear fuel assembly by support vector machine method, Energy Reports, 7, 5922-5932, 2021.
14. Fujimoto T., Nishioka T., International Journal of Mechanical Sciences, International Journal of Mechanical Sciences, 52, 277–286, 2010.
15. Mohamed YS, Shehata HM. Mohamed Abdellatif M., Awad TH., Steel crack depth estimation based on 2D images using artificial neural networks, Alexandria Engineering Journal, 58 (4), 1167-1174, 2019.
16. Joseph R., Bhuiyan Md.Y., Giurgiutiu V., Acoustic emission from vibration of cracked sheet-metal samples, Engineering Fracture Mechanics, 217 (1), 106544, 2019.
17. Zhao W., Chen F., Huang H., Li D., Cheng W., Hindawi Computational Intelligence and Neuroscience, pages 13, 2021.
18. Yang J., Wang W., Lin G., Li Q., Sun Y., Sun Y., Infrared Thermal Imaging-Based Crack Detection Using Deep Learning, IEEE Access, 7, 182060 – 182077, 2019.
19. Halkacı M., İlmeç M., Türköz M., Elmalı A., Avcı S., Dağhan B., Halkacı H.S., Determination of die and process parameters of hydromechanical deep drawing using analogy method, Journal of the Faculty of Engineering and Architecture of Gazi University, 35 (4), 2161-2182, 2020.
20. Karaağac İ., Kabaklı M.O., Demirel M.Y., Experimental investigation of the effects of annealing in Al7075-T6 sheet metal material on formability and springback, Journal of the Faculty of Engineering and Architecture of Gazi University, 36 (3), 319-1329, 2021.
21. Multi-Layer Neural Networks with Sigmoid Function.
<https://towardsdatascience.com/multi-layer-neural-networks-with-sigmoid-function-deep-learning-for-rookies-2-bf464f09eb7f>, Yayın tarihi Temmuz 7, 2017. Erişim tarihi Aralık 9, 2020.
22. VGG in TensorFlow. <https://www.cs.toronto.edu/~frossard/post/vgg16/> Yayın tarihi Mayıs 17, 2016. Erişim tarihi Aralık 9, 2020.
23. İník Ö., Ülker E., Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, Gaziosmanpasa Journal of Scientific Research, 6 (3), 85-104, 2017.