

Çift Doğrusal CNN Kullanarak Çelik Yüzey Kusurlarının Sınıflandırılması

Emre GÜÇLÜ^{1*}, İlhan AYDIN², Erhan AKIN³

^{1,2,3} Bilgisayar Mühendisliği, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye
¹ eguclu@firat.edu.tr, ² iaydin@firat.edu.tr, ³ eakin@firat.edu.tr

(Geliş/Received: 07/07/2023;

Kabul/Accepted: 13/12/2023)

Öz: Çelik, endüstride oldukça fazla kullanılan yapı malzemelerinden biridir. Çelik üreticileri arasındaki rekabetin artmasıyla birlikte çelik ürünlerin yüzey kalitesi daha önemli bir hale gelmiştir. Çelik yüzeylerde oluşabilecek kusurlar tespit edilemediğinde daha büyük sorunlara neden olabilmektedir. Günümüzde, çelik yüzey kusurlarını algılama sistemleri, geleneksel kusur tespit yöntemlerinin yerini almıştır. Yüzey kusurları, sağlam çelik görünümünden farklı olarak anormal görünüme sahiptir. Bu kusurların tespiti için derin öğrenme tabanlı yöntemlerin kullanılması, pahalı yöntemlere göre birçok avantaja sahiptir. Bu nedenle, Endüstri 4.0 ile birlikte çelik ürünler üzerinde oluşabilecek kusurların tespiti için bilgisayarlı görmeye dayalı yöntemler daha yaygın olarak kullanılmaktadır. Bu çalışmada, çelik yüzeylerde oluşabilecek kusurların sınıflandırılması için çift doğrusal evrişim sinir ağı (Bilinear-CNN) kullanılmıştır. Eğitim için kullanılan veri kümesinde kusurlu ve kusursuz veriler birbirine oldukça benzerdir. Çift doğrusal havuzlama yöntemi, daha yüksek dereceli ve uzamsal sırasız bilgileri çıkarabilme yeteneğine sahiptir. Böylece benzer veri kümelerinde yüksek performans elde ettiği gösterilmiştir. Önerilen yöntemin performansı farklı ağlar için değerlendirilmiştir. %98,26 doğruluk oranıyla en yüksek sonucu Bilinear Xception modeli elde etmiştir. Sonuçlar, çift doğrusal evrişimli sinir ağının benzer görüntülerden oluşan veri kümelerini sınıflandırmada yüksek performans elde ettiğini göstermektedir.

Anahtar kelimeler: Çelik yüzey kusurları, Kusur tespiti, Çift doğrusal CNN

Classification of Steel Surface Defects Using Bilinear CNN

Abstract: Steel is one of the most widely used building materials in the industry. With the increasing competition among steel manufacturers, the surface quality of steel products has become more important. Defects that may occur on steel surfaces can cause bigger problems when they are not detected. Today, steel surface defect detection systems have replaced traditional defect detection methods. Surface imperfections have an anomalous appearance as opposed to the appearance of solid steel. Using deep learning-based methods to detect these defects has many advantages over expensive methods. Therefore, with Industry 4.0, computer vision-based methods are more widely used for the detection of defects that may occur on steel products. In this study, bilinear convolutional neural network (Bilinear-CNN) is used to classify defects that may occur on steel surfaces. In the dataset used for training, defect and non-defect data are very similar to each other. The bilinear pooling method is capable of extracting higher order and spatially unordered information. Thus, it has been shown to achieve high performance in similar datasets. The performance of the proposed method has been evaluated for different networks. Bilinear Xception model obtained the highest result with an accuracy rate of 98.26%. The results show that the bilinear convolutional neural network achieves high performance in classifying datasets consisting of similar images.

Key words: Steel surface defects, Defect detection, Bilinear CNN

1. Giriş

Çelik ürünlerde oluşabilecek kusurlar, üretim sürecinde ortaya çıkabilecek en önemli sorunlardan biridir. Çelik ürünler üretildikten sonra üretimi bitmiş ürünlerin kalite değerlendirmesi üzerinde çalışılması gereken zor bir işlemdir. Çelik üretimi sırasında kullanılan yöntemlerden dolayı nihai ürünün kalitesi bozulabilmektedir. Özellikle eritme ve biçimlendirme aşamalarında ürün üzerinde kusurlar meydana gelebilmektedir. Ürün yüzeyinde meydana gelebilecek çatlak, göçük, çizik kusurlar ürünün kalitesi hakkında bilgi vermektedir. Kusurlar sadece çeliğin görünümünü etkilemez, aynı zamanda çeliğin dayanımına da zarar verir. İmalatçılar kusurlara zamanında müdahale edemezlerse çelikten üretilen ürünün kalitesi de olumsuz etkilenecektir. Bu nedenle, çelik yüzey kusurlarının tespiti, çelik endüstrisi için temel kalite kontrol görevlerinden biridir. Endüstriyel çelik üretiminde, nihai ürünün kusursuz olmasını sağlamak için ürün yüzeylerinin incelenerek kusur olup olmadığı belirlenmelidir. Genel olarak, üretilen ürünlerdeki farklı kusurlar arasında belirli benzerliklerin olması ve aynı kusurların

* Sorumlu yazar: eguclu@firat.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0002-4566-7517, ² 0000-0001-6880-4935, ³ 0000-0001-6476-9255

görünümünde farklılıklar olması gibi nedenlerden dolayı kusur tespitinin zor bir işlem olduğunu göstermektedir. Çelik yüzeylerde birbirine benzeyen önemli sayıda kusur bilinmektedir [1].

Genellikle, çelik ürünlerin yüzeyi uzman kişiler tarafından manuel olarak incelenir. İnsan müfettişler ürünü inceleyip kusurları belirler ve inceleme sonuçları kusur oluşumunu azaltmak için geri bildirim olarak kullanılır. Bu yöntem, denetim yapan kişinin deneyimine bağlıdır, özeldir ve belirli bir aşamaya kadar güvenilirdir. Ancak manuel denetim sıkıcı ve yorucu bir iştir [2]. Bu nedenle üretilen tüm ürünler insanlar tarafından denetlenemez. Manuel denetimin bu dezavantajları göz önünde bulundurulduğunda denetimin bilgisayar görmesi kullanılarak otomatik hale getirilmesi çelik denetimi için güvenilir, düşük maliyetli, nesnel ve hızlı bir kontrol sistemi sağlayabilir. Bu nedenle, endüstride kusur tespiti için yapılan çalışmalar artarak devam etmektedir. Özellikle bilgisayarlı görme ve derin öğrenme kullanılarak geliştirilen yöntemler, elde edilen yüksek doğruluk oranlarıyla gelecek vaat etmektedir. Bu yöntemler, eğitim için yeterli veri kümesi sağlandığında kusurları tespit etmeyi sağlar.

Son yıllarda, bilgisayarlı görmeye dayalı kusur inceleme teknolojisi, geleneksel yöntemlerin dezavantajlarının üstesinden gelebilmek için temassız ve tam otomatik olarak uygulanabildiği için araştırmacılar tarafından büyük ilgi görmüştür [3-4]. Çelik yüzeylerindeki kusurların tespiti için kullanılan mevcut yöntemler, görüntülerin özelliklerini çıkararak kusur tiplerinin belirlemek için sınıflandırma yapar. Literatür incelendiğinde bu konuda birçok araştırma yapılmıştır. Önce görüntü özellikleri Gabor filtreleri [5], dalgacık filtreleri [6], HOG [7] gibi teknikler kullanılarak çıkartılır, ardından SVM benzeri sınıflandırma yöntemleriyle sınıflandırılır [8].

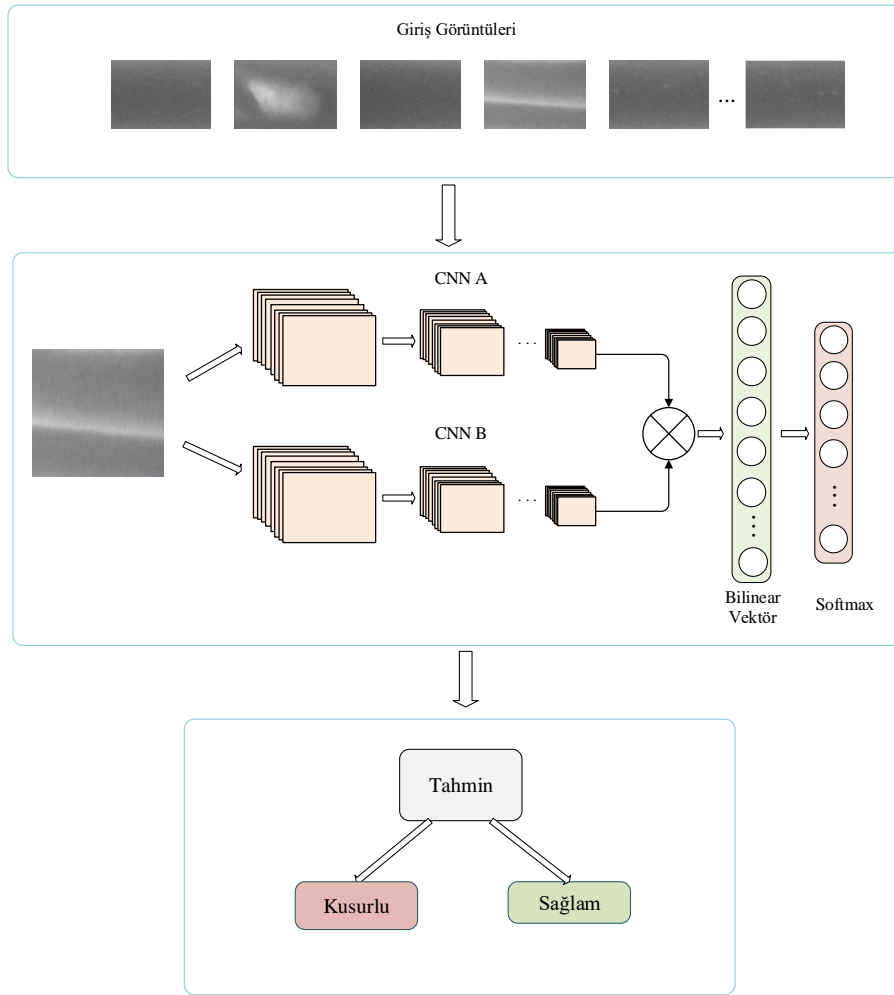
Özellikle derin öğrenmenin gelişmesiyle birlikte Evrişimli Sinir Ağları (CNN) bu alanda kullanılmıştır. Çelik yüzeylerdeki hataların tespiti için görüntü işleme ve derin öğrenme tabanlı analiz algoritmaları oldukça fazla kullanılmaktadır. Makine öğrenmesinin bir alt dalı olan derin öğrenme, çok katmanlı bir öğrenme sürecini kullanarak karmaşık sınıflandırma problemlerini çözebilir. Evrişimli sinir ağları görüntü tanıma görevleri için özel olarak tasarlanmış yöntemlerdir. Evrişimli sinir ağı görüntüdeki tüm bilgileri tutarak nesnelerin doğru bir şekilde sınıflandırılmasını sağlayabilir. [9]'da, çelik yüzey kusurlarının tespiti için gömülü sistem tasarlanarak YOLOv5 ve YOLOv7 algoritmalarının performansları karşılaştırılmıştır. [10]'da, haddelenmiş çelik yüzeylerdeki kusurları tespit etmek ve sınıflandırmak için ResNet50 sinir ağına dayalı sınıflandırıcı kullanılmıştır. [11]'de, çelik üzerindeki kusurları tanıma için evrişimli sinir ağı (CNN) tabanlı yarı denetimli bir öğrenme yöntemi önerilmiştir. Önerilen yöntemde daha az veri kullanılması sağlanmıştır. [12]'de, Derin öğrenmeye tabanlı bir çelik kusur tespit sistemi önerilmiştir. Çalışmada, sınıflandırma yeteneğini artırmak için CNN kullanılarak her aşamada özellik haritaları oluşturulup birden fazla özelliği içerebilen tek özellikte birleştirilerek çok düzeyli füzyon ağı (MFN) önerilmiştir. [13]'te, derin öğrenme kullanılarak çelik kusurlarının tespiti yapılmıştır. Çalışmada, derin sinir ağı tabanlı bir teşhis modeli ve makine öğrenimi tabanlı sınıflandırma modeli uygulanmıştır. [14]'te, kusur tespiti için önerilen CNN ile omurga mimarisi olarak önceden eğitilmiş SqueezeNet'i benimseyerek gerçek zamanlı bir tespit yöntemi önerilmiştir. [15]'te, çelik yüzey hatası tanıma için CNN'ye dayalı yarı denetimli bir yaklaşım önerilmiştir. Önerilen yöntemde, sınırlı bir etiketli veri seti ile %17,53 oranında iyileştirme elde edilmiştir. [16]'da, geliştirilmiş YOLOv4 algoritmasına dayalı bir çelik şerit yüzey hatası algılama yöntemi önerilmiştir. Önerilen algoritma kullanılan veri kümesi için ortalama kesinlik değerlerini %3,87 oranında iyileştirerek %85,41'e ulaşmıştır. [17]'de, çelik malzemelerin yüzeylerindeki kusurları tespit etmek için CNN tabanlı bir yöntem önerilmiştir. Çalışmada önerilen mimari, çelik kusurlarını sınıflandırmada yüzde 95,21 oranında doğruluk oranı elde etmiştir.

Literatürde kullanılan yöntemler iyi sonuçlar elde etse de çelik yüzeylerin sahip olduğu özellikler, kusurların tespiti için bazı zorluklar oluşturmaktadır. Bu zorluklardan biri çelik üzerinde meydana gelen kusurların bazıları geniş alanı kaplarken bazılarının oldukça küçük olmasıdır. Yüzey üzerindeki küçük kusurların tespit edilmesi genellikle zordur. Küçük kusurların bulunduğu veri kümelerinde daha doğru bir sınıflandırma yapabilmek için modelin tespit yeteneği artırılmalıdır. Kusurlu ve kusursuz çelik görüntülerindeki benzerlikler nedeniyle çelik yüzeylerdeki kusur tanıma görevi, ince taneli bir sınıflandırma görevi olarak düşünülebilir. Çift doğrusal CNN modelleri, ince taneli sınıflandırma problemini çözmek için önerilmiştir. Çift doğrusal CNN'de görüntülerin açıklamasını elde etmek için iki adet CNN tabanlı özellik çıkarıcı kullanılır. Özellik çıkarıcıların çıktılarının görüntünün her konumunda dış çarpım olarak çoğaltılır ve konumlar arası havuzlanır. Dış çıktılar ürünü parça-özellik etkileşimlerini arasındaki ikili korelasyonları yakalar. Böylece model iyi bir performans elde edebilir. Kusur tespiti için çift doğrusal CNN kullanan çalışmalar, yüksek doğruluk oranları elde etmiştir. [18]'de yüzey kusurlarının sınıflandırılmasını gerçekleştirmek için çift doğrusal modele dayanan bir yöntem önerilmiştir. D-VGG16 tarafından çift doğrusal modelden elde edilen özellikler softmax fonksiyonuna aktarılıp Sınıf Aktivasyon Haritalaması (Grad-CAM) kullanılarak kusurlu bölgenin lokalizasyonu gerçekleştirilmiştir. [19]'da, görüntü tabanlı erimiş havuz deliği (MPK) kusurlarının tanınması için dikkat tabanlı çift doğrusal özellik çıkarma mekanizması geliştirilmiştir. [20]'de, dökümlerde tahribatsız kusur tespiti için mekansal dikkat mekanizması ve çift doğrusal havuzlamayı birleştirerek yeni bir yöntem önerilmiştir.

Bu çalışmanın amacı, sınıfları arasında benzerlikler olan veri kümeleri için ince taneli görsel tanıma uygulamaktır. Çelik görüntüsü üzerinde sadece noktasal hataların bulunması sınıflandırma görevini zorlaştırmaktadır. Kullanılan çift doğrusal modeller görsel nesnelere tanırken belirli detaylara odaklanarak ayrıntıların özelliklerini çıkarmaktadır. Çalışmada, sınıflandırma görevleri için sıklıkla kullanılan ağlar kullanılmıştır. Kullanılan MobileNetv2 ve Resnet50 gibi ağlar kusurlu görüntülerin sınıflandırılması için oldukça iyidir. Ancak noktasal hatalar gibi küçük ayrıntıları sınıflandıramayabilir. Bu sorunun üstesinden gelebilmek için, seçilen CNN modelleri önce tek kullanılarak eğitilmiş ardından çift doğrusal model yapısı kullanılarak eğitilmiştir. Sonuçlar karşılaştırılarak yöntemin performansı değerlendirilmiştir.

2. Materyal ve Metod

Çalışmanın bu bölümünde, çelik yüzey görüntülerinden kusurları tespit etmek için çift doğrusal CNN tabanlı yöntemin aşamaları açıklanmıştır. Çift doğrusal CNN yapısında önceden eğitilmiş modeller kullanılmıştır. Buradaki amaç, eğitim maliyetlerini azaltmak ve sınıflandırma için uygun ağırlıkları seçmektir. Bu nedenle, eğitime ImageNet veri kümesi üzerinde eğitilmiş modeller ile başlanmıştır. Çift doğrusal CNN yapısında kullanılan modeller VGG16, Resnet50, Xception ve MobileNetv2'dir. Tüm adımları tamamladıktan sonra, çeliklerde kusur tespiti için en iyi performans gösteren modeli belirlemek için sonuçlar karşılaştırılmıştır. Çalışmada kullanılan veri kümesi, Dingming Yang ve arkadaşlarının [21], gerçek zamanlı X-ray görüntüleme sistemi ile topladığı çelik boru görüntülerinden oluşmaktadır. Oluşturulan veri kümesi 600 sağlam ve 550 kusurlu görüntüden oluşmaktadır. Önerilen yöntemin mimarisi, Şekil 1'de gösterilmektedir.

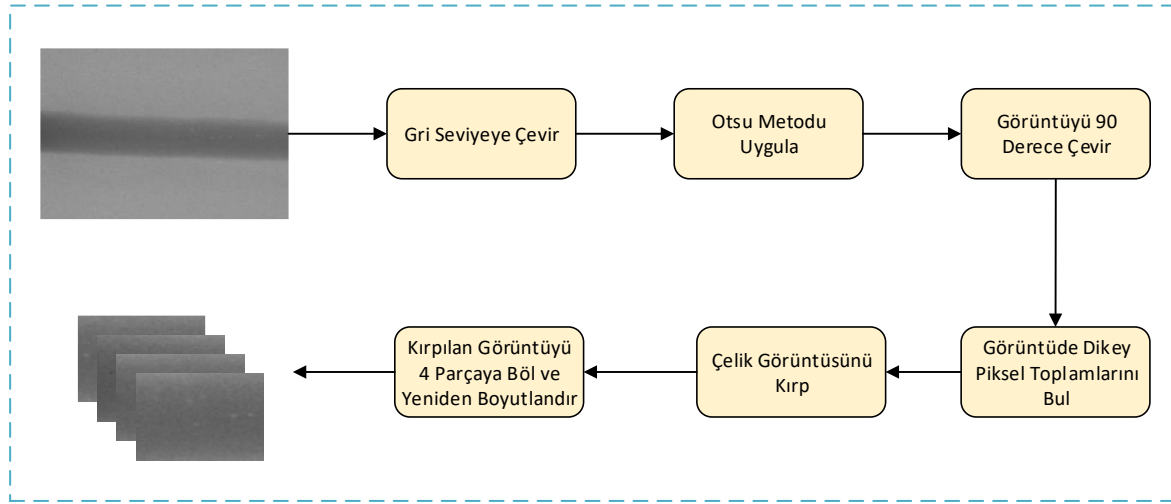


Şekil 1. Kusur tespiti için önerilen yöntem

2.1 Görüntü önileme

İlk aşamada elde edilen veri kümesindeki veri miktarı, eğitim süreci için yetersizdir. Orijinal görüntüden elde edilen çelik görüntüsünün tek parça halinde kullanılması eğitim kalitesini olumsuz yönde etkileyecektir. Bu nedenle, iyi bir eğitim sürecini gerçekleştirmek için veri kümesinde bulunan görüntülerden çelik görüntüsü kırılarak elde edilen kırılmış çelik görüntüsü 4 eşit parçaya bölünmüştür. Ardından, modelin girişine uygun olması için $224 \times 224 \times 3$ boyutlarında yeniden boyutlandırılmıştır. Böylece veri kümesindeki örnek sayısının fazla olması sağlanmıştır. Elde edilen veri kümesindeki görüntüler incelenerek sağlam ve kusurlu olmak üzere ayrılmıştır. Veri kümesinin oluşturulması için önerilen yöntem Şekil 2’de verilmiştir.

Alınan görüntü üzerinde çelik görüntüsünü kırabilmek için çeliğin sınırlarını belirlemek gerekmektedir. Bu nedenle giriş görüntüsüne eşikleme yapılmıştır. Görüntü eşikleme, görüntüyü siyah ve beyaz piksellerden oluşan ikili hale getirmek için kullanılır. Bu çalışmada, eşikleme işlemi için Otsu metodu kullanılmıştır [22].



Şekil 2. Veri kümesinin oluşturulması için önerilen yöntem

Giriş görüntüsü, 0 ile $L - 1$ gri seviye aralığında $I(x, y)$ olarak tanımlanırsa ve L , görüntüdeki farklı gri seviye sayısı kabul edilirse; i gri seviyeye sahip piksel sayısı n_i ve n , $M \times N$ boyutlu bir dizinin piksel sayısı olsun. Gri seviye i 'nin oluşma olasılığı Denklem 1'deki gibidir.

$$p_i = \frac{n_i}{n} \quad (1)$$

Giriş görüntüsü t eşığı ile iki sınıfa ayrılırsa, ilk sınıf $[0, t]$ seviyelerine sahip piksellerden ve diğer sınıf $[t+1, L-1]$ seviyelerine sahip piksellere sahip olur. $P_0(t)$ ve $P_1(t)$ kümülatif olasılıkları, aşağıdaki denklemlerde belirtildiği gibi hesaplanır.

$$P_0(t) = \sum_{i=0}^t p_i \quad (2)$$

$$P_1(t) = \sum_{i=t+1}^{L-1} p_i = 1 - P_0(t) \quad (3)$$

İki sınıf için ortalama seviyeleri Denklem 4 ve Denklem 5'teki gibi hesaplanır.

$$u_0(t) = \sum_{i=0}^t i * \frac{p_i}{P_0(t)} \quad (4)$$

$$u_1(t) = \sum_{i=t+1}^{L-1} i * \frac{p_i}{P_1(t)} \quad (5)$$


Belirlenen bir t eşiği için sınıflar arası varyans Denklem 6'daki gibi hesaplanır.

$$\delta_b(t) = P_0(t)(u_0(t))^2 + P_1(t)(u_1(t))^2 \quad (6)$$

Otsu yönteminde uygun eşik değeri Denklem 7'deki gibi bulunur.


$$T = \underset{1 < t < L}{argmax} \delta_b(t) \quad (7)$$

Şekil 3.a'da, orijinal çelik görüntüsü verilmiştir. Şekil 3.b'de Otsu yöntemi kullanılarak bir eşik oluşturulmuştur ve sonuç gösterilmiştir. Gri seviye görüntüde gri seviyesi eşikten daha düşük ise siyah ile daha büyük ise beyaz ile tanımlanmıştır.




Şekil 3. Otsu eşikleme sonucu a) Orijinal görüntü b) Otsu metodu uygulandıktan sonra oluşan görüntü

Görüntüdeki çelik sınırlarını belirlemek için Şekil 3.b'deki görüntü 90° döndürülüp elde edilen görüntünün histogramı elde edilmiştir. Elde edilen histogramdan, görüntünün X eksenindeki en yüksek yoğunluğa sahip pikseller pik noktası oluşturmaktadır. Şekil 4'te görüldüğü gibi, çeliğin olduğu pikseller histogramda pik noktası oluşturmıştır.




Şekil 4. Histogram çıktısı a) Giriş görüntüsü b) Beyaz piksellerin x eksenini boyunca oluşturduğu pik noktası

Şekil 5'te görüldüğü gibi orijinal görüntüden kırılarak elde edilen çelik görüntüsü, 224 × 224 × 3 boyutlarında biçimlendirilmiştir. Veri kümesi sağlam ve kusurlu olmak üzere iki etiketten oluşmaktadır. Şekil 6, iki sınıf için örnekleri içermektedir.



Şekil 5. Veri kümesi oluşturma a) Çelik sınırlarının belirlenmesi b) Çelik görüntüsünün orijinal görüntüden kırılması b) Kırılan görüntünün 4 eşit parçaya bölünmesi ve yeniden boyutlandırılması



Şekil 6. Veri Kümesinden bazı örnek görüntüler a) Sağlam b) Deforme

2.2. Çift doğrusal evrişimli sinir ağı (Bilinear CNN)

Çelik üzerindeki kusurlar küçük olduğundan bir çelik üzerindeki kusurların tespiti oldukça zordur. Bu nedenle VGG16, MobileNetv2 gibi modeller kusur tespiti için çok iyi performans gösterememektedir. Veri kümesindeki farklı sınıflar arasındaki görüntüler birbirine benzer ise veri kümesindeki sorunların ayırt edilmesi oldukça zordur [23]. Bu görevi çözebilmek için genellikle, giriş görüntülerinin oldukça yerleştirilmiş niteliklerinin tanınması gerekmektedir. Örneğin, çelik görüntüsü üzerinde bulunan bir lekeyi delik kusurundan ayırt etmek için görüntüdeki ince farklılıkların tanınması gerekir. Son yıllarda en fazla kullanılan ve en gelişmiş tekniklerden olan derin öğrenme modelleri bile bu görevde başarısız olmaktadır. Yapılan araştırmalarda farklı uygulamalar için birçok CNN tabanlı ince taneli sınıflandırma yaklaşımı önerilmiştir. Bu çalışmada bu sorunu çözmek için çift doğrusal evrişimli sinir ağı (Bilinear CNN) kullanılarak sınıflandırma yapılmıştır [24].

İnce taneli nesne tanıma, bilgisayarlı görmede zorlu bir görevdir. Diğer temel düzey görüntü sınıflandırması yapan algoritmalardan farklı olarak ince taneli nesne tanıma, görüntü olarak benzer olan ancak arada az fark bulunan görüntüleri tanımaya odaklanır.

[24]'e göre, ince taneli görüntü sınıflandırması için çift doğrusal model Denklem 8'deki gibi açıklanabilir.

$$M = F(f_A, f_B, P, C) \quad (8)$$

Denklemler 8’de M bilinear modeli, f_A ve f_B iki özellik çıkarıcıyı, P havuzlama fonksiyonunu ve C sınıflandırma fonksiyonunu temsil etmektedir. Özellik çıkarıcı Denklemler 9’daki gibi tanımlanır. Bu işlev, görüntüleri ve konumları karşılık gelen özelliklere eşlemektedir.

$$f : \mathcal{L} \times \mathcal{J} \rightarrow \mathbb{R}^{c \times D} \quad (9)$$

Denklemler 9’da \mathcal{J} görüntüleri teslim ederken \mathcal{L} konumları temsil etmektedir. \mathbb{R} bir boyutun özelliğidir \mathcal{L} genellikle konum ve ölçeği ifade eder. $\mathbb{R}^{c \times D}$ ise $c \times D$ boyutunda özelliklerdir. Çift doğrusal karakteristikler elde etmek için, f_A ve f_B ’nin çıktısı her konumda Denklemler 10’daki gibi birleştirilir. Çıktıları birleştirmek için her bir l konumundaki matris dış çarpımı kullanılır. l konumundaki f_A ve f_B ’nin bilinear özellik kombinasyonu bilinear olarak verilir. Denklemlerde verilen f_A ve f_B ’nin uyumlu olması için özellik boyutu c uyumlu olmalıdır.

$$(l, \mathcal{J}, f_A, f_B) = f_A(l, \mathcal{J})^T f_B(l, \mathcal{J}) \quad (10)$$

Görüntünün tüm konumlarındaki çift doğrusal özellikler P ile toplanır. Bu işlem, bir görüntü tanımlayıcısı elde etmek için gerçekleştirilir. Havuzlama, tüm konumların çift doğrusal özellikleri toplanarak gerçekleştirilir.

$$P(\mathcal{J}) = \sum l \in \mathcal{L}^{B(l, \mathcal{J}, f_A, f_B)} \quad (11)$$

f_A, f_B , ile elde edilen özellikler sırasıyla $C \times M$ ve $C \times N$ boyutlarındaysa $P(\mathcal{J})$ $M \times N$ boyutunda olur. $P(\mathcal{J})$ ’nin $MN \times 1$ boyutuna yeniden biçimlendirilmesiyle elde edilen çift doğrusal vektör, bir sınıflandırma fonksiyonu C ile kullanılabilen genel amaçlı bir görüntü tanımlayıcıdır.

2.3 Kullanılan önceden eğitilmiş CNN modelleri

2.3.1 MobileNetv2

Çalışmada kullanılan sınıflandırıcılardan biri MobileNetv2’dir. MobileNet’in geliştirilmiş versiyonu olan MobileNetv2’de doğruluk önemli ölçüde artırılmıştır [25]. MobileNetv2’nin seçilme nedeni yüksek doğruluk elde edebilirken düşük çıkarım süresine sahip olabilmesidir. Bu özelliği sayesinde sahada üretim hattında gerçek zamanlı uygulamalarda kullanılabilme potansiyeli vardır. MobileNetv2 ağ mimarisi, 19 orijinal temel bloktan oluşur. Bu blokları, ortalama bir havuzlama katmanına sahip 1×1 evrişim katmanı takip eder. Son katman bir sınıflandırma katmanıdır.

2.3.2 ResNet50

ResNet50, He Kaiming ve arkadaşları tarafından 2015 yılında yayınlanan "Deep Residual Learning for Image Recognition" makalesinde tanıtılmıştır [26]. ResNet50, 1 maksimum havuzlama ve 1 ortalama havuz katmanı ile birlikte 48 evrişim katmanına sahip ResNet modelinin bir çeşididir. ResNet50, ResNet34’ün geliştirilmiş bir versiyonudur. ResNet34’teki 2 katmanlı blokların her biri, 3 katmanlı darboğaz bloğu ile değiştirilerek ResNet50 mimarisini oluşturmaktadır. Oluşturulan bu yapı, 34 katmanlı ResNet modelinden çok daha yüksek doğruluk oranına sahiptir.

2.3.3 VGG-16

Bu mimari, 16 katmandan oluşan düzgün bir mimariye sahiptir [27]. Evrişimli katmanlar 3×3 kıvrımlara ve çok sayıda filtreye sahiptir. Son yıllarda, sınıflandırma görevleri için oldukça popüler olmuştur. VGG-16, 138 milyon parametreden oluşur ve transfer öğrenme yöntemiyle elde edilir.

2.3.4 Xception

Xception, François Chollet tarafından tanıtılan Derinlemesine Ayrılabilir Evrişimleri içeren derin bir evrişimli sinir ağı mimarisidir [28]. Xception mimarisi, çoğu klasik sınıflandırma mücadelesinde VGG-16 ve ResNet gibi popüler ağlardan iyi performans göstermiştir.

2.4 Modeller için hiperparametreler

Tablo 1’de, modellerin eğitiminde kullanılan hiperparametreler verilmiştir. Giriş görüntüleri 224×224 olarak belirlenip parti boyutu 4 olarak ayarlanmıştır. Modellerde öğrenme sürecini geliştirmek için Adam optimizyer kullanılmıştır. Döngü sayısı 50 olarak belirlenmiştir. Öğrenme oranı 0.001 olarak belirlenmiştir. Ayrıca, kayıp işlevi olarak Kategorik Çapraz Entropi (Categorical Cross Entropy) ve aktivasyon fonksiyonu olarak Softmax kullanılmıştır.

Tablo 1. Modellerde kullanılan hiperparametreler

Parametre	Değer
Görüntü Boyutu	224×224
Parti Boyutu	4
Optimizyer	Adam
Döngü	50
Öğrenme Oranı	0.001

2.5. Performans ölçüm metrikleri

Sınıflandırma işlemi, eğitim, doğrulama ve test aşamalarından oluşur. Eğitim aşamasında modelin parametreleri ayarlanarak model eğitilir. Eğitim hatası ile modelin eğitim verilerine uyumu kontrol edilir. Eğitilen model genellikle eğitim verilerine uyacağı için eğitim hatası test hatasından daha küçüktür. Sınıflandırma algoritmalarının amacı eğitim verilerini kullanarak daha önce görmediği verilerin sınıfını tahmin etmeyi öğrenmektir. Doğrulama aşamasında modelin performansı değerlendirilir.

Sınıflandırma problemleri sınıf sayısına göre değişmektedir. Bu çalışmada, iki sınıflı sınıflandırma yapılmıştır. İki sınıftan pozitif sınıf için P ve negatif sınıf için N olarak belirlenmiştir. Şekil 7’de dört olası çıktıyı içeren karmaşıklık matrisi verilmiştir.

		Doğru sınıf	
		Pozitif	Negatif
Tahmin edilen sınıf	Pozitif	DP	YP
	Negatif	YN	DN

Şekil 7. Karmaşıklık Matrisi

Karmaşıklık matrisinde girdi görüntüsü gerçekte pozitifse ve pozitif olarak sınıflandırıldıysa, yani doğru sınıflandırılmış bir pozitif ise, doğru pozitif (DP) olarak değerlendirilir. Girdi görüntüsü gerçekte pozitifse ve negatif olarak sınıflandırılırsa, yanlış negatif (YN) olarak değerlendirilir. Girdi görüntüsü negatifse ve değerlendirme sonucu negatif ise doğru negatif (DN) olarak değerlendirilir. Son olarak girdi görüntüsü negatif iken sınıflandırma sonucu pozitif ise, yanlış pozitif (YP) olarak değerlendirilir. Karmaşıklık matrisi birçok ölçüm metriğini hesaplamak için kullanılır. Ölçüm metrikleri, sınıflandırma sonuçlarını değerlendirme önemli bir faktördür. Çalışmada kullanılan ölçüm metrikleri ve kullanılan denklemler aşağıda verilmiştir.

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (12)$$

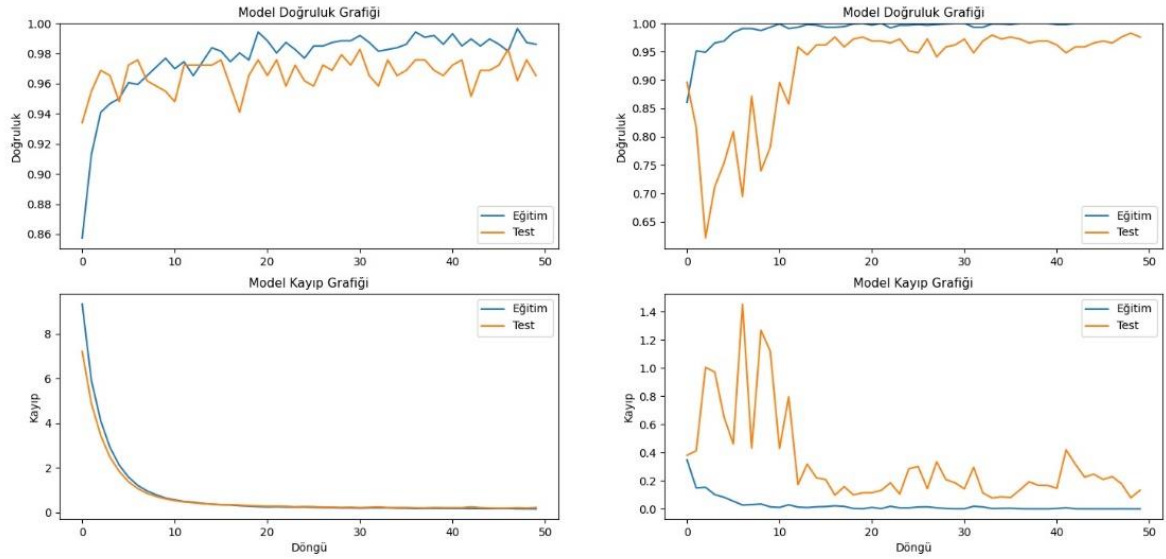
$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (13)$$

$$\text{Geri Çağırma} = \frac{DP}{DP + YN} \quad (14)$$

$$F1 = \frac{2 * \text{Geri Çağırma} * \text{Kesinlik}}{\text{Geri Çağırma} + \text{Kesinlik}} \quad (15)$$

3. Bulgular

Bu bölümde önerilen çift doğrusal CNN tabanlı yöntemin çelik yüzey kusurlarını sınıflandırma sonuçları değerlendirilmiştir. Çalışmada, çift doğrusal modeller oluşturulan veri kümesindeki görüntülerin kusurlu ve sağlam olmak üzere sınıflandırılması için kullanılmıştır. Elde edilen sonuçlar çift doğrusal olmayan modeller ile karşılaştırılmıştır. 600 sağlam ve 550 kusurlu görüntüden oluşan veri kümesinin %75'i eğitim için ve %25'i test için ayrılmıştır. Çift doğrusal yapının kusur tespiti üzerindeki etkinliğini kanıtlamak için dört farklı ağ yapısı kullanılarak karşılaştırma yapılmıştır. Elde edilen sonuçlar karşılaştırıldığında çift doğrusal CNN yapısının performans ölçüm metriklerinde üstün olduğu ve doğruluk sonuçlarını geliştirdiği gösterilmiştir. Çift doğrusal CNN tabanlı modellerde, kusur tespitinin çift doğrusal olmayan modellere göre daha iyi olduğu görülmüştür. Bunun nedeni, çift doğrusal CNN ağlarının görüntü üzerindeki detayları daha iyi öğrenebilmesidir. Her bir model için elde edilen model doğruluk grafiği ve model kayıp grafiği Şekil 8-Şekil 11'de gösterilmiştir. Ayrıca, her bir modelin karmaşıklık matrisi Şekil 12-Şekil 15'te gösterilmiştir.

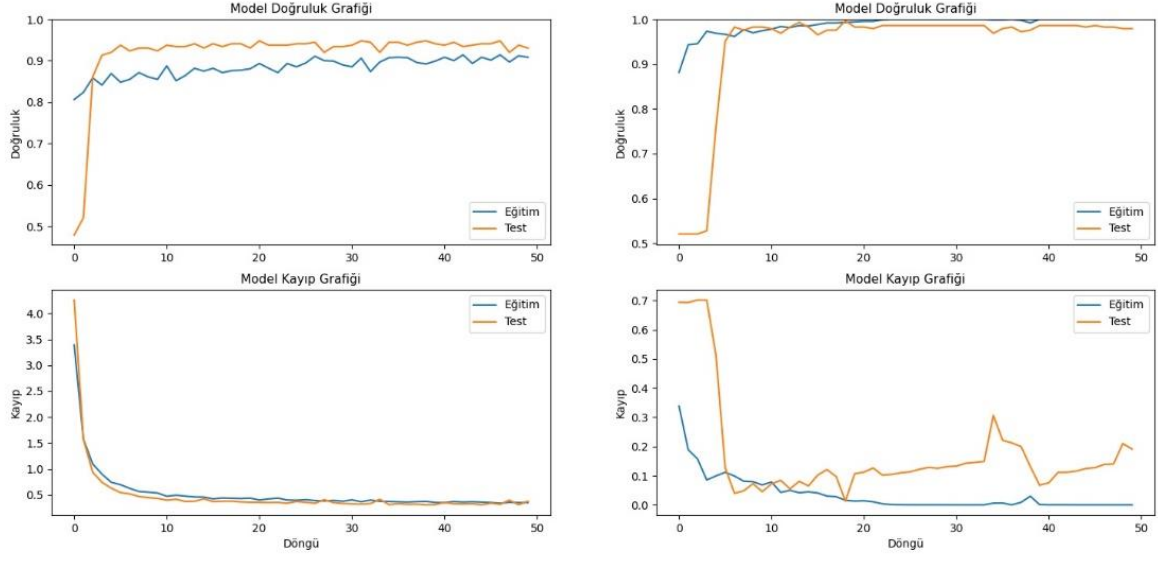


a) MobileNETv2

b) Çift Doğrusal MobileNETv2

Şekil 8. MobileNETv2 ve çift doğrusal MobileNETv2 grafik karşılaştırması


Çift Doğrusal CNN Kullanarak Çelik YüzeY Kusurlarının Sınıflandırılması



a) ResNet50

b) Çift Doğrusal ResNet50

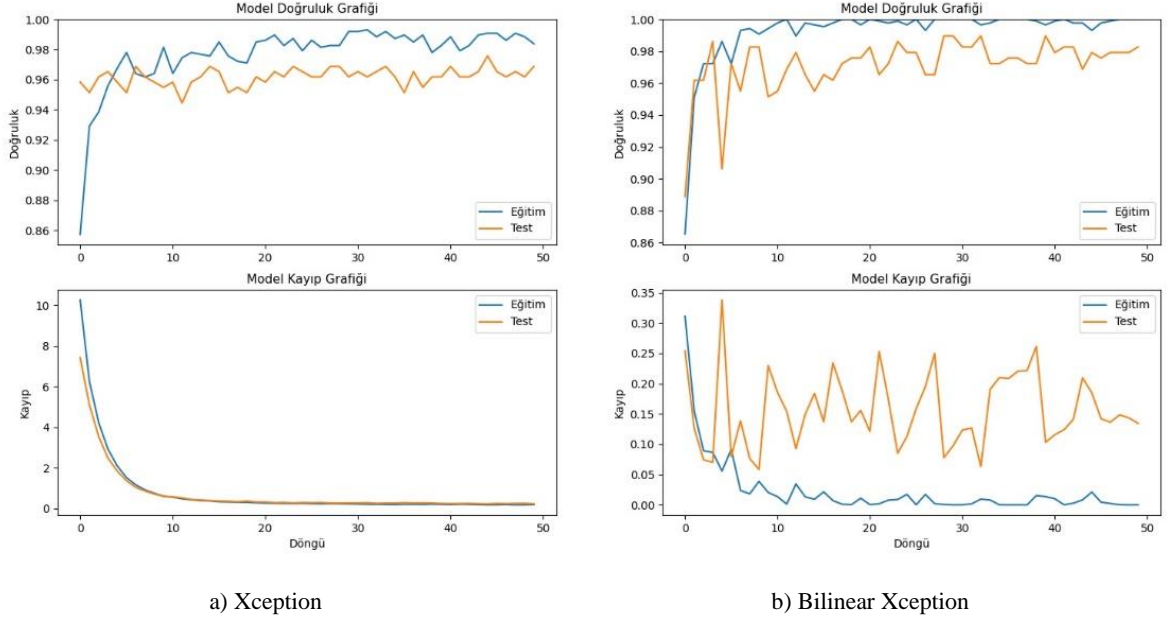
Şekil 9. ResNet50 ve Çift Doğrusal ResNet50 grafik karşılaştırması



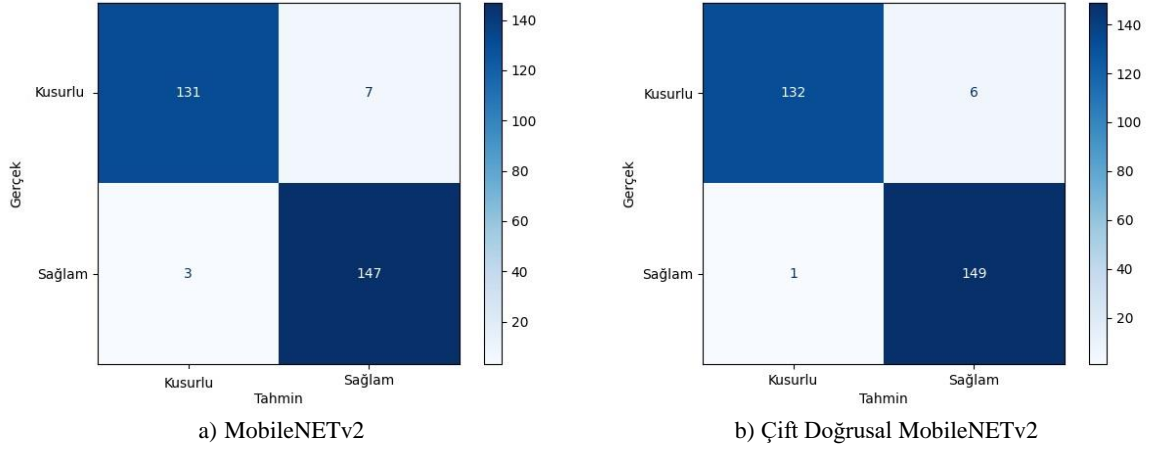
a) VGG16

b) Çift Doğrusal VGG16

Şekil 10. VGG16 ve Çift Doğrusal VGG16 grafik karşılaştırması

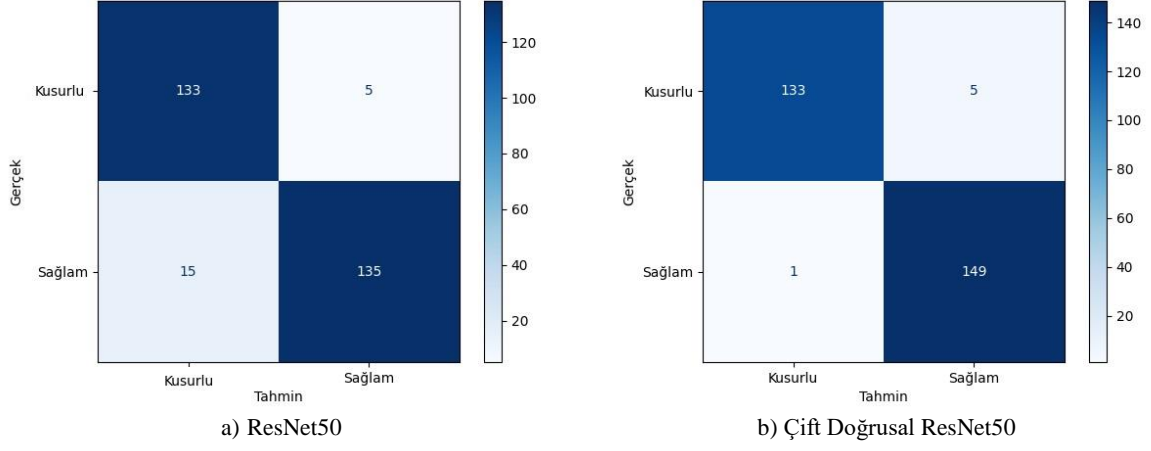


Şekil 11. Xception ve Çift Doğrusal Xception grafik karşılaştırması

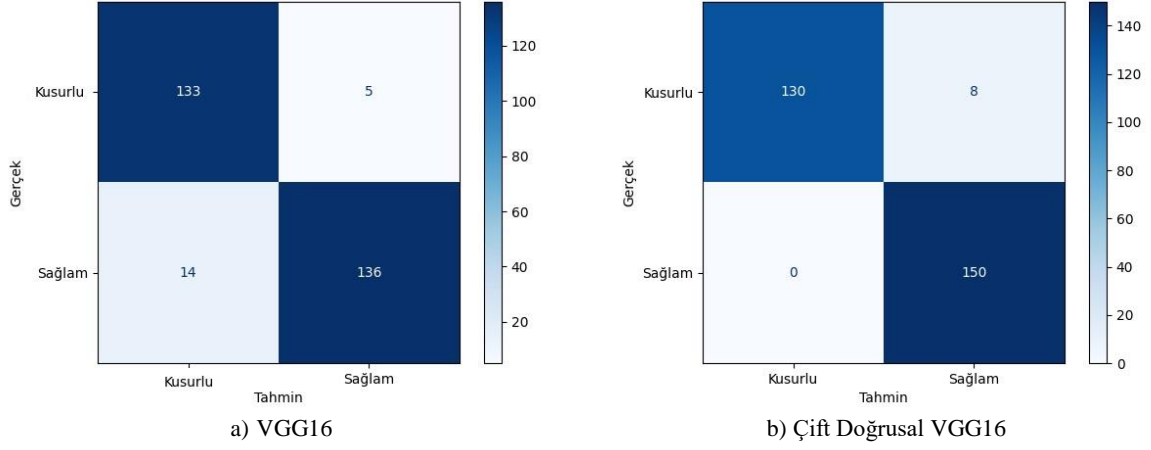


Şekil 12. MobileNETv2 ve Çift Doğrusal MobileNETv2 karmaşıklık matrisi karşılaştırması

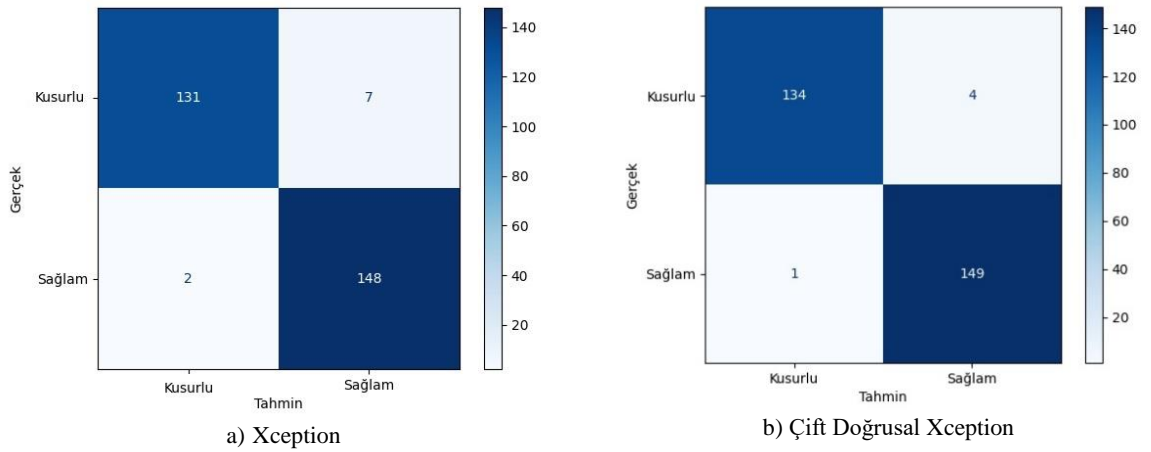
Çift Doğrusal CNN Kullanarak Çelik Yüzey Kusurlarının Sınıflandırılması



Şekil 13. ResNet50 ve Çift Doğrusal ResNet50 karmaşıklık matrisi karşılaştırması



Şekil 14. VGG16 ve Çift Doğrusal VGG16 karmaşıklık matrisi karşılaştırması



Şekil 15. Xception ve Çift Doğrusal Xception karmaşıklık matrisi karşılaştırması

Tablo 2’de, elde edilen tüm performans metrikleri karşılaştırılmıştır. Sonuçlar incelendiğinde çift doğrusal mimari kullanılarak oluşturulan modellerin daha yüksek doğruluk oranı elde ettiği görülmüştür. Çift Doğrusal Xception modeli %98.26 doğruluk oranıyla en yüksek performansı elde ederken ResNet50 modeli %93.05 doğruluk oranı ile en düşük doğruluk oranını elde etmiştir.

Tablo 2. Elde edilen doğruluk sonuçları

Ağ Yapısı	Doğruluk (%)	Geri çağırma (%)	Kesinlik (%)	F1 (%)
MobileNetv2	96.52	98.0	95.45	96.71
Bilinear MobileNetv2	97.57	99.33	96.12	97.70
ResNet50	93.05	90.0	96.43	93.10
Bilinear ResNet50	97.91	99.33	96.75	98.02
VGG16	93.40	90.66	96.45	93.47
Bilinear VGG16	97.22	100	94.93	97.40
Xception	96.87	98.66	95.48	97.04
Bilinear Xception	98.26	99.33	97.38	98.34

4. Sonuçlar

Çalışmanın başında da belirtildiği gibi çelik yüzey kusurlarının tespitinde yapay zekâ kullanımı oldukça uygundur, çünkü insan denetçiler ile karşılaştırınca yapay zekâ kullanılarak oluşturulan otomatik sistemlerin, maliyetleri düşürme potansiyelleri oldukça fazladır. Literatürden örnekler de incelendiğinde evrişimli sinir ağlarının bu görev için oldukça uygun bir yapı olduğu görülmektedir. Yüksek doğruluk oranı elde edebilen bir CNN modelinin endüstride kullanılma potansiyeli yüksektir. Bu nedenle bu çalışmada çelik yüzey görüntülerinin sınıflandırma doğruluğunu artırmak için çift doğrusal CNN yapısı kullanılmıştır.

Genel olarak, bu çalışmada kullanılan yöntem çelik yüzey görüntülerinin sınıflandırılmasında yüksek doğruluk oranı elde etmiştir. Sonuçlar incelendiğinde sınıflandırma işlemi için çift doğrusal CNN kullanımının doğruluk oranlarını geliştirdiğini göstermektedir. Bu nedenle, çift doğrusal CNN kullanımının özellikle küçük kusur çeşitleri üzerinde etkili olduğundan çelik yüzey görüntülerinin analizinde ve sınıflandırılmasında kullanılabilir uygun bir teknik olduğu görülmüştür. Elde edilen sonuçlar karşılaştırılınca, çift doğrusal modellerin performansı ile diğer modellerin performansları arasında fark olduğu kanıtlanmıştır.

Teşekkür

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 5210082 numaralı proje ile desteklenmiştir.

Kaynaklar

- [1] Agarwal, K., Shivpuri, R., Zhu, Y., Chang, T. S., & Huang, H. (2011). Process knowledge based multi-class support vector classification (PK-MSVM) approach for surface defects in hot rolling. *Expert Systems with Applications*, 38(6), 7251-7262.
- [2] Choi, W., Huh, H., Tama, B. A., Park, G., & Lee, S. (2019). A neural network model for material degradation detection and diagnosis using microscopic images. *IEEE Access*, 7, 92151-92160.
- [3] Zhou, Q., Chen, R., Huang, B., Liu, C., Yu, J., & Yu, X. (2019). An automatic surface defect inspection system for automobiles using machine vision methods. *Sensors*, 19(3), 644.
- [4] Zheng, X., Zheng, S., Kong, Y., & Chen, J. (2021). Recent advances in surface defect inspection of industrial products using deep learning techniques. *The International Journal of Advanced Manufacturing Technology*, 113, 35-58.
- [5] Jiahui, C. O. N. G., Yunhui, Y. A. N., & Dong, D. (2010). Application of Gabor filter in strip surface defect detection. *Journal of Northeast University (Natural Science Edition)*, 31(2), 257-260.
- [6] Ryu, S. G., Koo, G., & Kim, S. W. (2020). An adaptive selection of filter parameters: defect detection in steel image using wavelet reconstruction method. *ISIJ International*, 60(8), 1703-1713.

- [7] Mao, T., Ren, L., Yuan, F., Li, C., Zhang, L., Zhang, M., & Chen, Y. (2019, May). Defect recognition method based on HOG and SVM for drone inspection images of power transmission line. In 2019 international conference on high performance big data and intelligent systems (HPBD&IS) (pp. 254-257). IEEE.
- [8] Boudiaf, A., Benlahmidi, S., Harrar, K., & Zaghoudi, R. (2022). Classification of surface defects on steel strip images using convolution neural network and support vector machine. *Journal of Failure Analysis and Prevention*, 22(2), 531-541.
- [9] GÜÇLÜ, E., AYDIN, İ., ŞENER, T. K., & Erhan, A. K. I. N. Çelik Yüzeylerdeki Kusurların Tespiti için Derin Öğrenme Tabanlı Gömülü Sistem Tasarımı. *EMO Bilimsel Dergi*, 12(2), 27-33.
- [10] Konovalenko, I., Maruschak, P., Brezinová, J., Viňáš, J., & Brezina, J. (2020). Steel surface defect classification using deep residual neural network. *Metals*, 10(6), 846.
- [11] Gao, Y., Gao, L., Li, X., & Yan, X. (2020). A semi-supervised convolutional neural network-based method for steel surface defect recognition. *Robotics and Computer-Integrated Manufacturing*, 61, 101825.
- [12] He, Y., Song, K., Meng, Q., & Yan, Y. (2019). An end-to-end steel surface defect detection approach via fusing multiple hierarchical features. *IEEE Transactions on Instrumentation and Measurement*, 69(4), 1493-1504.
- [13] Lee, S. Y., Tama, B. A., Moon, S. J., & Lee, S. (2019). Steel surface defect diagnostics using deep convolutional neural network and class activation map. *Applied Sciences*, 9(24), 5449.
- [14] Fu, G., Sun, P., Zhu, W., Yang, J., Cao, Y., Yang, M. Y., & Cao, Y. (2019). A deep-learning-based approach for fast and robust steel surface defects classification. *Optics and Lasers in Engineering*, 121, 397-405.
- [15] Gao, Y., Gao, L., Li, X., & Yan, X. (2020). A semi-supervised convolutional neural network-based method for steel surface defect recognition. *Robotics and Computer-Integrated Manufacturing*, 61, 101825.
- [16] Li, M., Wang, H., & Wan, Z. (2022). Surface defect detection of steel strips based on improved YOLOv4. *Computers and Electrical Engineering*, 102, 108208.
- [17] Karaduman, G., Aydin, I., Akin, E., & Özdemir, S. (2022, August). Detection of the Steel Faults Based on Deep Learning. In 2022 International Conference on INnovations in Intelligent SysTems and Applications (INISTA) (pp. 1-2). IEEE.
- [18] Zhou, F., Liu, G., Xu, F., & Deng, H. (2019). A generic automated surface defect detection based on a bilinear model. *Applied Sciences*, 9(15), 3159.
- [19] Liu, T., Zheng, P., Chen, H., & Zhang, L. (2023). An attention-based bilinear feature extraction mechanism for fine-grained laser welding molten pool/keyhole defect recognition. *Journal of Manufacturing Processes*, 87, 150-159.
- [20] Tang, Z., Tian, E., Wang, Y., Wang, L., & Yang, T. (2020). Nondestructive defect detection in castings by using spatial attention bilinear convolutional neural network. *IEEE Transactions on Industrial Informatics*, 17(1), 82-89.
- [21] Yang, D., Cui, Y., Yu, Z., & Yuan, H. (2021). Deep learning based steel pipe weld defect detection. *Applied Artificial Intelligence*, 35(15), 1237-1249.
- [22] Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1), 62-66.
- [23] Luo, J. H., & Wu, J. X. (2017). A survey on fine-grained image categorization using deep convolutional features. *Acta Autom. Sin.*, 43(8), 1306-1318.
- [24] Lin, T. Y., RoyChowdhury, A., & Maji, S. (2015). Bilinear CNN models for fine-grained visual recognition. In *Proceedings of the IEEE international conference on computer vision* (pp. 1449-1457).
- [25] Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4510-4520).
- [26] 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).
- [27] Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- [28] Chollet, F. (2016). Xception: deep learning with depthwise separable convolutions (2016). *arXiv preprint arXiv:1610.02357*.