

ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BASKILI DEVRE KARTLARI ÜZERİNDEKİ LEHİM HATALARININ DERİN
ÖĞRENME TABANLI SINIFLANDIRILMASI

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

ALİ SEZER

HAZİRAN 2021

ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BASKILI DEVRE KARTLARI ÜZERİNDEKİ LEHİM HATALARININ DERİN
ÖĞRENME TABANLI SINIFLANDIRILMASI

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

ALİ SEZER

DANIŞMAN: Dr. Öğr. Üyesi Aytaç ALTAN

ZONGULDAK

Haziran 2021

KABUL:

Ali SEZER tarafından hazırlanan “Baskılı Devre Kartları Üzerindeki Lehim Hatalarının Derin Öğrenme Tabanlı Sınıflandırılması” başlıklı bu çalışma jürimiz tarafından değerlendirilerek Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalında Yüksek Lisans Tezi olarak oybirliğiyle kabul edilmiştir.
17/06/2021

Danışman: Dr. Öğr. Üyesi Aytaç ALTAN

Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü

Üye: Dr. Öğr. Üyesi Rukiye UZUN ARSLAN

Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü

Üye: Dr. Öğr. Üyesi Batıkan Erdem DEMİR

Karabük Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği Bölümü

ONAY:

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım.

..../..../2021

Prof. Dr. Ahmet ÖZARSLAN
Fen Bilimleri Enstitüsü Müdürü



“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Ali SEZER

ÖZET

Yüksek Lisans Tezi

BASKILI DEVRE KARTLARI ÜZERİNDEKİ LEHİM HATALARININ DERİN ÖĞRENME TABANLI SINIFLANDIRILMASI

Ali SEZER

Zonguldak Bülent Ecevit Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Aytaç ALTAN

Haziran 2021, 53 sayfa

Elektronik cihazların üretim süreçlerinde, yüzeye monte edilen elemanların baskılı devre kartlarına (BDK) montajı sürecinde oluşan lehim hatalarından kaynaklanan sorunlar nedeniyle üretim faaliyetleri aksamakta ve bu da üretim maliyetlerinde artışa neden olmaktadır. Krem lehim uygulamalarında elektronik kartlarda oluşabilecek kusurlar genellikle üretim sürecinin son aşamasında fark edilmektedir. Bu durum üretim verimliliğini düşürmekte ve kritik sistemlerin teslimat programında gecikmelere neden olmaktadır.

Bu çalışmada baskılı devre kartları (BDK) üzerindeki krem lehim kusurlarını erken aşamada tespit etmek için görüntü işleme teknikleri kullanılarak optimizasyona dayalı bir derin öğrenme modeli önerilmiştir. Derin öğrenme yöntemlerinden biri olan evrişimli sinir ağı (ESA), bu çalışmaya özel hazırlanmış veri seti kullanılarak eğitilmiştir ve baskılı devre kartları (BDK) üzerindeki krem lehim uygulanmış ped bölgeleri, krem lehim hataları belirtilerek sınıflandırılmıştır. Çalışmada kullanılan toplam altı krem lehim sınıf türü, literatürde sıklıkla karşılaşılan doğru lehimleme, düzeltilemez lehimlem, eksik lehim, fazla lehim, kısa devre ve yabancı nesne örneklerinden oluşturulmuştur.

ÖZET (devam ediyor)

Modelin geçerliliği 648 test verisinden oluşan veri seti üzerinden test edilmiştir. Ayrıca çalışmada, görüntü işleme ve optimizasyon yöntemlerinin model performansına etkisi incelenerek %96.40 başarımlı oranı elde edilmiştir. Önerilen model yardımı ile baskılı devre kartları (BDK) üzerindeki kusurlu krem lehim alanları tespit edilmiş ve bu bölgeler çerçeve içerisine alınarak görselleştirilmiştir.

Anahtar Kelimeler: Evrimsel sinir ağı (ESA), derin öğrenme, optimizasyon, baskılı devre kartı (BDK), sinyal işleme, lehim hataları.

Bilim Kodu: 608.05.00, 608.05.02

ABSTRACT

M. Sc. Thesis

DEEP LEARNING BASED CLASSIFICATION OF SOLDER DEFECTS ON PRINTED CIRCUIT BOARDS

Ali SEZER

**Zonguldak Bülent Ecevit University
Graduate School of Natural and Applied Sciences
Department of Electrical and Electronics Engineering**

Thesis Advisor: Assist. Prof. Dr. Aytaç ALTAN

June 2021, 53 pages

In the production processes of electronic devices, production activities are interrupted due to the problems caused by soldering defects during the assembly of surface-mounted elements on printed circuit boards (PCBs) and this leads to an increase in production costs. In cream solder applications, defects that may occur in electronic cards are usually noticed at the last stage of the production process. This situation reduces the efficiency of production and causes delays in the delivery schedule of critical systems.

In this study, an optimization-based deep learning model is proposed by using image-processing techniques in order to detect cream solder defects on PCBs with high performance at an early stage. Convolutional neural network (CNN), one of the deep learning methods, is trained using the data set obtained for this study and ped regions on PCB are classified. A total of six types of classes used in the study consist of uncorrectable soldering, missing soldering, excess soldering, short circuit, undefined object and correct soldering, which are frequently used in the literature.

ABSTRACT (continued)

The validity of the model has been tested on the data set consisting of 648 test data. Also, in the study, the effect of image processing and optimization methods on model performance is examined and 96.40% success rate was achieved. With the help of the proposed model, defective cream solder areas on PCBs are detected and these regions are visualized by taking them into a frame.

Keywords: Convolutional neural network (CNN), deep learning, optimization, printed circuit board (PCB), signal processing, soldering errors.

Science Code: 608.05.00, 608.05.02

TEŞEKKÜR

Çalışmalarım boyunca değerli yardım ve katkılarıyla beni yönlendiren saygıdeğer hocam Dr. Öğr. Üyesi Aytaç ALTAN'a teşekkürlerimi sunarım.

Araştırma çalışma imkânlarından faydalandığım TÜBİTAK SAGE'ye teşekkürlerimi sunarım.

Yüksek lisans tez çalışmamı 2020-75737790-04 numaralı proje kapsamında destekleyen Zonguldak Bülent Ecevit Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü'ne teşekkürlerimi sunarım.

Bu çalışmanın gelişmesinde değerli bilgilerini, yorumlarını ve yardımlarını esirgemeyen Sn. Ali PELGUR, Muhammed Kemal ÖZCAN, Ayça KAYALARLI, Tolga DİNSEVER ve çalışma arkadaşlarıma çok teşekkür ederim. Ayrıca çalışmalarım kapsamında bana her zaman yardımcı olan kıymetli arkadaşlarım Yasin ERGEN ve Kerem Can KATIRCI'ya teşekkürlerimi sunarım.

Her zaman ve tüm çalışmalarım boyunca emek ve destekleriyle yanımda olan çok değerli aileme en içten teşekkürlerimi sunarım.



İÇİNDEKİLER

	<u>Sayfa</u>
KABUL	ii
ÖZET	iii
ABSTRACT	v
TEŞEKKÜR	vii
İÇİNDEKİLER.....	ix
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ	xv
SİMGELER VE KISALTMALAR DİZİNİ.....	xvii
 BÖLÜM 1 GİRİŞ	 1
 BÖLÜM 2 VERİLERİN TOPLANMASI VE İŞLENMESİ	 9
2.1 VERİLERİN TOPLANMASI	9
2.2 VERİLERİN SİNİR AĞI MODELİ İÇİN HAZIRLANMASI	13
2.2.1 Çevirme.....	14
2.2.2 Döndürme	15
2.2.3 Kaydırma.....	15
2.2.4 Gürültü Ekleme	16
2.2.5 Bulanıklaştırma	17
 BÖLÜM 3 LEHİM HATALARININ TESPİTİNDE DERİN ÖĞRENME YÖNTEMİ	 21
3.1 EVRİŞİMLİ SİNİR AĞI (ESA) GENEL MODELİ.....	21
3.2 EVRİŞİM KATMANI.....	24
3.3 AKTİVASYON KATMANI	25
3.4 HAVUZ KATMANI	26
3.5 DÜZLEŞTİRME KATMANI.....	26

İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
3.6 TAM BAĞLANTI KATMANI	27
3.7 SINIFLANDIRMA KATMANI.....	27
3.8 OPTİMİZASYON	27
3.9 EVRİŞİMLİ SINIR AĞI (ESA) MİMARİLERİ	29
3.9.1 LeNet-5 Mimarisi.....	30
3.9.2 AlexNet Mimarisi	30
3.9.3 VGG-16 Mimarisi	30
3.9.4 ResNet Mimarisi	30
3.10 GÖRÜNTÜ İŞLEME	31
 BÖLÜM 4 DENEYSEL SONUÇLAR VE TARTIŞMA	 35
4.1 KREM LEHİM VERİ SETİ	35
4.2 PERFORMANS ÖLÇÜMLERİ	37
4.3 DENEYSEL SONUÇLAR.....	39
 BÖLÜM 5 SONUÇLAR VE ÖNERİLER.....	 49
 KAYNAKLAR.....	 51
ÖZGEÇMİŞ	53

ŞEKİLLER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Şekil 1.1 a) Lehim köprüsü hatası, b) Lehim köprüsü hatası.....	3
Şekil 1.2 a) Delikli lehimleme yapılan bileşenlerde karşılaşılan kalkık malzeme hatası örneği, b) Yüzey montajlı bileşenlerde görülen kalkık malzeme hatası örneği	3
Şekil 1.3 a) Aşırı lehim hatası, b) Aşırı lehim hatası.	4
Şekil 1.4 a) BDK yüzeyine lehim topçuğunun sıçraması, b) Lehim topçuğunun BDK yüzeyindeki ped bölgeleri arasına sıçraması.....	4
Şekil 1.5 a) Islanmama durumu bakır yüzey açıkta kalmış, b) Islanmış lehimin geri çekilmesi sonucu kalıntı oluşması, c) ıslanma ve ıslanmama görselleri, d) ıslanma ve ıslanmama yapısal gösterim	5
Şekil 1.6 a) İnce bakır plakası hatası, b) Zedelenmiş ped eklem hatası	6
Şekil 1.7 a) Pin deliği, b) Pin deliği ve üfleme deliği örnekleri	6
Şekil 1.8 a) Lehim atlama, b) Bölgesel ped bölgelerinin atlanması.....	7
Şekil 1.9 a) Lehim bayrağı (Sünme-Bıyık) oluşumu, b) Lehim bayrağı sebebiyle kısa devre oluşumu.....	7
Şekil 1.10 a) Baskılı devre kartı (BDK) yüzeyinde lehim renk değişikliği, b) Ped bölgesinde lehim renk değişikliği.....	8
Şekil 2.1 Krem lehim sürme makinası elek destekleme aparatı yerleşimi	10
Şekil 2.2 Krem lehim sürme makinası elek yerleşimi	10
Şekil 2.3 Krem lehim sürme makinası lehimin kızaklar yardımı ile lek üzerinden sürülerek baskılı devre kartı yüzeyine yerleştirilmesi.....	11
Şekil 2.4 a) Baskılı devre kartı dizgi makinası, b) Dizgi makinası komponent yerleşim bölmeleri	11
Şekil 2.5 Dizgi makinası komponent taşıma kolunun çalışması	12
Şekil 2.6 a) Krem lehim eritilmesi için gerekli olan fırın, b) fırın iç kısmı ve kart taşıma ray sistemi	12
Şekil 2.7 Veri toplama ve veri hazırlama için kullanılan kamera (a) kamera kurulumu (b) kamera (c) BDK görüntüsü (d) çıkarılmış ped bölgesi	13
Şekil 2.8 Veri kümesi büyütme için çevirme tekniği (a) orijinal görüntü (b) yatay olarak çevrilmiş görüntü (c) dikey olarak çevrilmiş görüntü.....	14
Şekil 2.9 Veri kümesi büyütme için döndürme tekniği (a) orijinal görüntü (b) 45 ° döndürülmüş görüntü (c) -45 ° döndürülmüş görüntü	15
Şekil 2.10 Veri kümesi büyütme için kaydırma tekniği (a) orijinal görüntü (b) kaydırılmış görüntü	16
Şekil 2.11 Veri kümesi büyütme için gürültü eklenme tekniği (a) orijinal görüntü (b) gürültü ekledikten sonra elde edilen görüntü.....	16

ŞEKİLLER DİZİNİ (devam ediyor)

No	Sayfa
Şekil 2.12 Veri kümesi büyütme için bulanıklaştırılmış görüntü elde etme (a) orijinal görüntü (b) bulanık görüntü.....	17
Şekil 2.13 a) Çevrilmiş görüntü örneği, b)kaydırılmış görüntü örneği, c) gürültü eklenmiş görüntü örneği, d) döndürülmüş görüntü örneği	18
Şekil 2.14 Görüntü eşleştirme için önerilen yöntemin akış diyagramı.	19
Şekil 3.1 Evrişimli sinir ağı yapısı	21
Şekil 3.2 Evrişimli sinir ağına ait temel bileşenler.....	22
Şekil 3.3 Lehim kusurlarını tespit etmek için önerilen modelin akış diyagramı.....	23
Şekil 3.4 Evrişim katmanı çalışma prensibi	24
Şekil 3.5 ReLu formülü ve grafiği	25
Şekil 3.6 Maksimum havuzlama katmanı prensibi	26
Şekil 3.7 Maksimum havuzlama katmanı prensibi	27
Şekil 3.8 Şablon örnekleri (a) doğru şablon örneği 1 (b) doğru şablon örneği 2	31
Şekil 3.9 Lehim hatalarını tespit etmek için görüntü eşleştirme örnekleri (a) orijinal görüntü (b) eşleşen görüntü	31
Şekil 3.10 Şablon örnekleri (a) eksik lehim şablon örneği (b) fazla lehim şablon örneği.	32
Şekil 3.11 a) Lehim hatalarını tespit etmek için görüntü eşleştirme örnekleri (a) orijinal görüntü (b) eşleşen görüntü.....	32
Şekil 3.12 Görüntü eşleştirme için önerilen yöntemin akış diyagramı.	33
Şekil 4.1 Veri seti örnekleri (a) doğru uygulama 1 (b) doğru uygulama 2 (c) yanlış uygulama 1 (d) yanlış uygulama 2	35
Şekil 4.2 Veri seti örnekleri (a) fazla lehim hatası 1 (b) fazla lehim hatası 2 (c) eksik lehim hatası 1 (d) eksik lehim hatası 2	36
Şekil 4.3 Veri seti örnekleri (a) kısa devre hatası 1(b) kısa devre hatası 2 (c) yabancı malzeme hatası 1 (d) yabancı malzeme hatası 2.	36
Şekil 4.4 AdaMax optimizasyonunun doğruluğu ve doğrulama doğruluğu karşılaştırması. ...	39
Şekil 4.5 AdaMax optimizasyonunun kayıp ve doğrulama kaybı karşılaştırması.	40
Şekil 4.6 RMSprop optimizasyonunun doğruluğu ve doğrulama doğruluğu karşılaştırması ..	40
Şekil 4.7 RMSprop optimizasyonunun kayıp ve doğrulama kaybı karşılaştırması.	41
Şekil 4.8 Adam optimizasyonunun doğruluğu ve doğrulama doğruluğu karşılaştırması.	41
Şekil 4.9 Adam optimizasyonunun kayıp ve doğrulama kaybı karşılaştırması	42
Şekil 4.10 AdaMax, RMSprop ve Adam optimizasyonlarının performans karşılaştırması.....	42
Şekil 4.11 AdaMax, RMSprop ve Adam optimizasyonlarının kayıp karşılaştırması	43
Şekil 4.12 (a) Orijinal görüntü (b) AdaMax optimizasyonu sonucu tespit edilen hatalar ve renksel ifadeleri, kusur kategorilerine göre sınıflandırılan lehim pedi konumları, sırasıyla doğru için mavi, yanlış için kırmızı, eksik lehim için camgöbeği, fazla lehim için yeşil, kısa devre için sarı ve tanımlanmamış nesne için mor	44

ŞEKİLLER DİZİNİ (devam ediyor)

No

Sayfa

- Şekil 4.13 (a) Orijinal görüntü (b) RMSprop optimizasyonu sonucu tespit edilen hatalar ve renksel ifadeleri, kusur kategorilerine göre sınıflandırılan lehim pedi konumları, sırasıyla doğru için mavi, yanlış için kırmızı, eksik lehim için camgöbeği, fazla lehim için yeşil, kısa devre için sarı ve tanımlanmamış nesne için mor 44
- Şekil 4.14 (a) Orijinal görüntü (b) AdaMax optimizasyonu sonucu tespit edilen hatalar ve renksel ifadeleri, kusur kategorilerine göre sınıflandırılan lehim pedi konumları, sırasıyla doğru için mavi, yanlış için kırmızı, eksik lehim için camgöbeği, fazla lehim için yeşil, kısa devre için sarı ve tanımlanmamış nesne için mor 45
- Şekil 4.15 (a) Orijinal görüntü (b) RMSprop optimizasyonu sonucu tespit edilen hatalar ve renksel ifadeleri, kusur kategorilerine göre sınıflandırılan lehim pedi konumları, sırasıyla doğru için mavi, yanlış için kırmızı, eksik lehim için camgöbeği, fazla lehim için yeşil, kısa devre için sarı ve tanımlanmamış nesne için mor 45
- Şekil 4.16 (a) Orijinal görüntü (b) AdaMax optimizasyonu sonucu tespit edilen hatalar ve renksel ifadeleri, kusur kategorilerine göre sınıflandırılan lehim pedi konumları, sırasıyla doğru için mavi, yanlış için kırmızı, eksik lehim için camgöbeği, fazla lehim için yeşil, kısa devre için sarı ve tanımlanmamış nesne için mor 46
- Şekil 4.17 (a) Orijinal görüntü (b) RMSprop optimizasyonu sonucu tespit edilen hatalar ve renksel ifadeleri, kusur kategorilerine göre sınıflandırılan lehim pedi konumları, sırasıyla doğru için mavi, yanlış için kırmızı, eksik lehim için camgöbeği, fazla lehim için yeşil, kısa devre için sarı ve tanımlanmamış nesne için mor 46
- Şekil 4.18 (a) Orijinal görüntü (b) AdaMax optimizasyonu sonucu tespit edilen hatalar ve renksel ifadeleri, kusur kategorilerine göre sınıflandırılan lehim pedi konumları, sırasıyla doğru için mavi, yanlış için kırmızı, eksik lehim için camgöbeği, fazla lehim için yeşil, kısa devre için sarı ve tanımlanmamış nesne için mor 47
- Şekil 4.19 (a) Orijinal görüntü (b) RMSprop optimizasyonu sonucu tespit edilen hatalar ve renksel ifadeleri, kusur kategorilerine göre sınıflandırılan lehim pedi konumları, sırasıyla doğru için mavi, yanlış için kırmızı, eksik lehim için camgöbeği, fazla lehim için yeşil, kısa devre için sarı ve tanımlanmamış nesne için mor 47



ÇİZELGELER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Çizelge 4.1 Krem lehim veri seti havuzu.	36
Çizelge 4.2 Krem lehim hata türleri ve elde edilen veri seti içerisindeki örnek sayıları.....	37
Çizelge 4.3 Karşıtlık matrisi ve hesaplanan parametreleri.	37
Çizelge 4.4 Performans ölçütleri ve elde edilen değerleri.	37
Çizelge 4.5 Optimizasyon türlerine ait verim ve kayıp çizelgesi.	39





SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

A	: Yatay eksen de yeni piksel konumu
a	: Yatay eksen piksel konumu
da	: Yatay eksen de pikseller arası yerdeğıştirme
B	: Yeni piksel konumu
b	: Dikey eksen de yeni piksel konumu
db	: Dikey eksen piksel konumu
X	: YSA giriş vektörü
Y	: YSA çıkış vektörü
W	: Nöronlar arası ağırlık vektörü
vt	: Geçmiş eğimlerin karelerinin üssel ağırlık ortalamalar
mt	: Momentum değışikliklerinin ön belleğe alınması
η	: Adım boyu
β_1, β_2	: Moment tahminleri için üstel azalma oranları
θ_t	: İlk parametre vektörü
g_t	: t zaman aşımındaki stokastik hedef
u_t	: Üstel ağırlıklı sonsuzluk normu

KISALTMALAR

Adam	: Adaptive Moment Estimation
BDK	: Baskılı Devre Kartı
ESA	: Evrişimli Sinir Ağı
FN	: Yanlış Negatif (False Negative – FN)
FP	: Yanlış Pozitif (False Positive – FP)
ReLU	: Rectified Linear Unit
RGB	: Red Green Blue

SİMGELER VE KISALTMALAR DİZİNİ (devam ediyor)

RMSprop	: Root Mean Square Prop
SPI	: Solder Paste Inspection
TN	: Doğru Negatif (True Negative – TN)
TP	: Doğru Pozitif (True Positive – TP)
YSA	: Yapay Sinir Ağı



BÖLÜM 1

GİRİŞ

Her elektronik cihazda kullanılan baskılı devre kartlar (BDK) üzerinde yer alan elemanlara bağlı olarak yüzey montajlı olarak üretilmektedir. Kartlar üzerinde bulunan bakır ped yüzeylere elektronik bileşenlerin tutturulabilmesi amacı ile krem lehim uygulaması, bu amaca yönelik cihazlar aracılığı ile seri üretime uygun bir şekilde gerçekleştirilmektedir. Bu süreçte krem lehim ve ped yüzeylerinden kaynaklı hatalar nedeniyle üretim süreçleri aksayabilmekte veya kartın başarılı bir şekilde devre elemanı montajının yapılamamasından karta uygulanan testlerde hatalar karşımıza çıkmaktadır (Wu, Zhang, Kuang, Ouyang and Xie 2013, Kasturkar and Lokhande 2016). Bu problemin üstesinden gelebilmek için bu çalışmada BDKlar üzerindeki krem lehim hataları tespitinde 2D sinyal işleme yöntemleri kullanılarak optimizasyon tabanlı hibrid bir evrişimli sinir ağı (ESA) modeli geliştirilmiştir.

BDKlar üzerinde bulunan bakır ped yüzeylere bileşenlerin tutturulabilmesi her bir BDK türüne özel üretilmiş elek yardımı ile homojen olarak sürülen krem lehim sayesinde gerçekleştirilir. Uygulanan krem lehim akışkan formda birbiri üzerinde duran lehim toparlarından oluşmaktadır ve her zaman istenilen formda lehim uygulaması elde edilemez. Dolayısı ile bileşenlerin kart yüzeyine sabitlenmesi sürecinde telafisi zor olan lehimleme hataları oluşmaktadır.


BDKlar üzerindeki lehimleme hatalarının tespit edilmesine yönelik olarak bazı çalışmalar literatürde yer almaktadır. Wo ve arkadaşları (Wu, Zhang, Kuang, Ouyang, and Xie 2013) tarafından yapılan çalışmada, genetik algoritma ve bir sinir ağı birleştirilerek, BDK üzerinde yüzey montaj bileşenlerinde görülen lehim bağlantı hatalarını gözlemeyi ve otomatik optik inceleme performansını arttırmayı amaçlamışlardır. Yaptıkları çalışmada hatalara ait 6 tip sınıf kullanılmış olup, geri yayılım sinir ağı ile genetik algoritma birleştirilerek %98.46'lık bir başarımla elde edilmiştir. Mohanty ve arkadaşları (Mohanty, Shah, Haugen and Holte 2008) tarafından gerçekleştirilen çalışmada, küçük boyutlu bileşenlerin 2 boyutlu ve 3 boyutlu alan hacim bağlantısı çalışılmış ve BDK krem lehim incelemesi üzerinde yatırım getirisi sağlanması

hedeflenmiştir. Küçük boyutlu bileşenlerin BDKlar üzerinde kullanımının yaygınlaşması ve bunların lehimlenmesi için kurşunsuz lehim kullanımının daha verimli olması amaçlanan çalışmada farklı boyutlarda bileşenlerin 2 boyutlu alan ölçümleri ile lehim pastası incelemesi (Solder Paste Inspection-SPI) sonucu oluşturulan alan üzerinden türetilen yükseklik haritasının birbirleri ile bağlantısı incelenmiştir. Sonuçta 2 boyutlu yöntemin 3 boyutlu yöntemden daha yüksek alan verileri sunduğu görülmüş ve her ikisi arasındaki tahminin ve bağlantı tahmininin sınırlarını anlayabilmek için doğrusal regresyon kullanılmıştır. Kasturkar ve Lokhande (Kasturkar and Lokhande 2016) çalışmalarında, BDKlar üzerinde su yolları da dahil olmak üzere tüm hataları inceleyerek görüntü işleme teknikleri ile sınıflandırmışlardır. Toplam 14 sınıfı 5 kategoride toplayarak oluşturdukları çalışmada hatalar, görsel verilerde bulunan farklılıkların ilk olarak BDKların resimlerinin 4 bölgeye ayrılması ile işlenmiş ve yeni resimler elde edilmiştir. Elde edilen her bir yeni resim görüntü işleme ile sınıflandırılmıştır. BDKlar üzerinde bulunan hataların bölgeleri belirtilmiştir. Huang ve Wei (Huang and Wei 2019) yayınladıkları çalışmalarında, 1386 BDK resmi ile beslenen evrişimli sinir ağını kullanarak kartlar üzerindeki hataları tespit edilmeye çalışmıştır. Sinir ağları ile gerçekleştirilen çalışmalarda yaşanan veri seti sorununa dikkat çekmiş ve kendi veri setlerini yayınlamışlardır. Veri setlerinde 6 temel lehim hatası bulunmaktadır. Kullandıkları derin öğrenme yöntemi ile önceki çalışmalarda karşılaşılan verim sorunları giderilmeye çalışmış ve ortalamada %99'luk bir başarımla elde etmişlerdir. Çalışmada her bir hataya ait bağlantı kutucukları kullanılarak hatalar tespit edilmiş ve sınıflandırılmıştır. Chauhan ve Bhardwaj (Chauhan and Bhardwaj 2011) oluşturdukları çalışmada BDK üretim, bileşen kontrolü ve lehimle aşamalarını incelemiş ve bu aşamalara ait hataları makine görmesini kullanarak orjinal resimden lojik operasyonlar yardımı ile görsel fark olarak elde etmişlerdir. Kartların her üç aşamada kontrol edilmesi BDK üretim, bileşen ve lehimleme aşamalarının her biri için hataların ayrı ayrı belirlenmesine olanak sağlamış ve bulunan hataların renkli olarak gösterilmesi ile kullanıcı bilgilendirilmiştir.

Literatürde de bahsedildiği gibi kartlarda ortaya çıkan ve lehimleme sürecinin sonunda karşılaşılan temel lehimleme hataları lehim köprüsü, kalkık malzeme, aşırı lehim, lehim topçukları, lehim ıslatma-ıslatmama, kalkmış pedler, pin delikleri ve üfleme delikleri, lehim atlama, lehim bayrağı ve lehim renk değişikliği olarak sıralanabilmektedir (Huang and Wei 2019, Wu, Zhang, Kuang, Ouyang and Xie 2013). Krem lehim yanlış uygulanması sonucu karşılaşılan uygulama hataları sık görülen ve seyrek karşılaşılan hatalar olarak ayrıştırılabilmektedir. Sık görülen hatalar; lehim köprüsü, kalkık malzeme, aşırı lehim ve lehim topçukları olarak sıralanabilir. Sık görülen hatalara nazaran seyrek karşılaşılan lehim uygulama

hataları; lehim ıslatma-ıslatmama, kalkmış pedler, pin delikleri ve üfleme delikleri, lehim atlama, lehim bayrağı ve lehim renk değişikliğidir.

Lehim köprüsü, kısa devre olarak da adlandırılan lehim hatasıdır. Bağımsız iki ped bölgesinin birbirine temas etmesi ile oluşmaktadır. Bu sorunun en büyük sebepleri kartın lehimlenmesi için gerekli olan doğru ısıl profilin kullanılmasına rağmen, pedler ve lehim maskesi katmanı arasında yeterli boşluk bırakılmamış olması, aynı tip malzemelerin aynı yönde yönlendirilmemiş olması veya büyük bileşenler ile düşük ağırlık dağılımlı BDK tasarımı olarak tanımlanmaktadır. Oluşabilecek olası lehim köprüsü örnekleri Şekil 1.1’de gösterilmektedir.




Şekil 1.1 a) Lehim köprüsü hatası, b) Lehim köprüsü hatası.

Kalkık malzeme, kart üzerinde tabandan kalkık bir malzeme görüldüğünde anlaşılır. Bu hata mezar taşı olarak da isimlendirilir. Fazla lehim uygulanması, BDK esnemesi ve uzun malzeme bacaklarının malzemeyi yukarı kaldırması hatanın oluşması için uygun zemini hazırlamaktadır. Yüzey montajı ve delikli yapıdaki lehimlemelere özgü hata görselleri Şekil 1.2’de gösterilmektedir.



Şekil 1.2 a) Delikli lehimleme yapılan bileşenlerde karşılaşılan kalkık malzeme hatası örneği, b) Yüzey montajlı bileşenlerde görülen kalkık malzeme hatası örneği.

Aşırı lehim, kartlara çok fazla lehim uygulandığı durumlarda, bileşenlerin bacaklarında lehim birikmesi ile oluşmaktadır. Bu hatada lehim hala işlevini gerçekleştirse de ileride büyük sorunlara yol açabileceğinden istenmeyen bir durumdur. Bu sorunun en temel nedenleri, elek delikleri ve kart ped bölgelerinin oranlarının yanlış olması, aşırı hızlı lehim sürülmesi, aynı tip malzemelerin aynı yönde kullanılmamış olması ve tasarım sürecinde yanlış oranda uzunluk/ped kullanılmış olmasıdır. Şekil 1.3’de hataya ait görseller sunulmaktadır.



(a)




(b)

Şekil 1.3 a) Lehim topu oluşumu sonucu aşırı lehim hatası, b) Lehimin bacağa tırmanması ile oluşan aşırı lehim hatası.

Lehim topçukları, küçük lehim parçalarının lehim eritme işlemi sırasında BDK yüzeyine yapışması ile oluşur. Bu hata kartın her hangi bir yerinde oluşabilir ve gözle tespiti mikrometre seviyelerinde oluşan hatalarda oldukça zordur. İki bacak arasında oluşan bir lehim topçuğunun fark edilememesi iki ped arası güvenli boşluk aralığının mesafesini azaltacağı için sistemin çalışması esnasında akım atlamalarına sebebiyet verebilmektedir. Bu hatanın oluşmasının en temel nedenleri; lehimleme sıcaklığının çok yüksek olması, uygulanan lehimin pedlere tam yapışmaması, kullanılan reçinenin ısıtılması sonucu oluşan gazların lehim BDK yüzeyine sıçratması olarak sıralanabilmektedir. Hataya ait görseller Şekil 1.4’de sunulmaktadır.




(a)



(b)


Şekil 1.4 a) BDK yüzeyine lehim topçuğunun sıçraması, b) Lehim topçuğunun BDK yüzeyindeki ped bölgeleri arasına sıçraması.

Lehim ıslatma ve ıslatmama, BDK üzerindeki eklem noktalarının ergimiş lehim yayılmasıyla ıslak hale gelmesi iyi bir şeydir. Bu süreçte iki sorun ile karşılaşılabilir. Birincisi, erimiş lehimin bir bacağı ya da pedi kaplayıp daha sonra, garip bir şekilde şekillendirilmiş bir lehim kalıntısı bırakarak geri çekilmesidir. Ayrıca, lehimin sadece bir yüzeye kısmen bağlı kaldığı ve açığa çıkmış bakır geride bıraktığı ıslanmayan durumlar oluşabilir. Bu sorunun en temel nedenleri; malzemenin rafda, lehimlenebilirlik raf ömründen fazla bekletilmiş olması, uygulanan reçinenin zamanı geçmiş olması ve pirinç parça pimlerinde kullanılan kaplama düzgün bir şekilde bakır ile kaplanmamış olması gibidir. Şekil 1.5’de hataya ait görseller ve donmuş lehimin yapısı gösterilmektedir.



Şekil 1.5 a) Islanmama durumu bakır yüzey açıkta kalmış, b) Islanmış lehimin geri çekilmesi sonucu kalıntı oluşması, c) ıslanma ve ıslanmama görselleri, d) ıslanma ve ıslanmama yapısal gösterim.

Kalkmış pedler bir bileşen yanlışlıkla lehimlenmişse ve sökülmesi gerekiyorsa, bu işlem BDK üzerindeki bahsedilen bileşenin ped'inin kalkmasına yol açabilir. Bu sorunun en temel nedenleri; ince bakır katmanı ile tasarlanan BDK kullanımı, kartın, delik boyunca düzgün bir bakır kaplama tabakası almamış olması ve bakır ile BDK plakası arasındaki katmanın zedelenen bölgeye aşırı yüklenmiş ped eklemi olması gibidir. Şekil 1.6’da görsel olarak hata belirtilmektedir.




(a)




(b)

Şekil 1.6 a) İnce bakır plakası hatası, b) Zedelenmiş ped eklem hatası.

Pin delikleri ve üfleme deliklerinin tespiti kolaydır sadece bağlantı noktasında bir delik aranmalıdır. Bir delik gözlenmiş ise bu sadece yüzeyde değil iç kısımlara kadar hatta BDK yüzeyine kadar uzanabilir. Bu sorunun en temel nedenleri; bakır plakanın altında bulunan malzemenin nemli olması, benzer tipteki bileşenlerin yanı yönde yönlendirilmemiş olması ve tasarımda çok küçük veya çok büyük delik-delik oranlarının seçilmiş olması gibidir. Şekil 1.7’de delik ve üfleme delikleri örnekleri verilmektedir.




(a)




(b)

Şekil 1.7 a) Pin deliği, b) Pin deliği ve üfleme deliği örnekleri.

Lehim atlama lehimleme sürecinde BDK üzerinde lehim sürülmemiş ped bırakmasıdır. Bu sorunun en temel nedenleri; BDK lehimleme yükseklik değerinin yanlış olması, tasarım sürecinde ped için uygun pabuç seçimi ve BDKdaki reçinenin lehimin pede tam tutunmasını engellemiş olması olarak sıralanabilir. Şekil 1.8’de gözlemlenene lehim atlama sorunlarına ait görseller paylaşılmaktadır.




(a)




(b)

Şekil 1.8 a) Lehim atlama, b) Bölgesel ped bölgelerinin atlanması.

Lehim bayrağı (Sünme, Bıyık) hatası zayıf reçine uygulaması ve lehim drenaj sorunlarının bir göstergesidir ve kartta başka lehimleme hatalarına yol açabilir. Bu sorunun en temel nedenleri; kullanılan lehimin yeterince akışkan olmaması, düzgün yapılmayan reçine uygulamaları sonucu oluşan lehimde sünme, lehim yapılacak bölgenin zamanla oksidasyona uğramış olması olarak gösterilmektedir. Şekil 1.9’da hatanın görseli ve bu hata sebebiyle oluşabilecek kısa devrelere ait örnekler paylaşılmaktadır.



(a)




(b)

Şekil 1.9 a) Lehim bayrağı (Sünme-Bıyık) oluşumu, b) Lehim bayrağı sebebiyle kısa devre oluşumu.

Lehim renk değişikliği BDK üzerinde lehim direnci ve lehimleme makinalarının taşıyıcı bantlarına bağlı olarak oluşabilir. Bu sorunun en temel nedenleri, doğru reçine kullanılmaması veya yanlış sıcaklık değeri seçimi, lehimleme işlemi esnasında kullanılan kalınlık ve sıcaklık gibi özniteliklerin değiştirilmesi ve ürünün tasarımında belirtilen değerlerden farklı değerler ile üretilmeye çalışılması gibidir. Şekil 1.10’da çoğunlukla karşılaşılan lehim renk değişikliği görselleri verilmektedir.



(a)



(b)

Şekil 1.10 a) Baskılı devre kartı (BDK) yüzeyinde lehim renk değişikliği, b) Ped bölgesinde lehim renk değişikliği

Sıralanan lehim hataları, üretim sonunda karşılaşılan ve çoğunlukla yanlış krem lehim uygulamasının fark edilememesi sonucu gözlenen üstesinden gelinmesi uzun zaman alan hatalardır. Bu hatalar kartların düzeltmeye rağmen kusurlu olarak değerlendirilmesine neden olmaktadır (Öztürk ve Akdemir 2017). BDKlarda bu hataların düzeltilmesi çoğu zaman mümkün olmamaktadır. Düzeltelen BDKlarda ise daha sonradan çeşitli sorunlar ortaya çıkabilmekte ve kartların işleme tabi tutulmuş hatalı kart olarak değerlendirilmesine sebep olmaktadır. Bu durum zaman ve kaynakların ekonomik kullanılamamasına neden olmakta ve üretim sürecini aksatmaktadır. Her üretim öncesi, kayıpları engellemek için belirlenen adette kart bu sürece tabi tutularak önlem alınmaya çalışılsa bile bazı özel durumlarda tek bir kart bile ciddi zaman ve kaynak kayıplarına yol açabilmektedir (Chauhan and Bhardwaj 2011).

Bu çalışmada literatürdeki çalışmalardan farklı olarak BDK üzerindeki lehim hatalarının tespiti için 2D sinyal işleme yöntemleri kullanılarak optimizasyon temelli evrişimli sinir ağı modeli önerilmektedir. Önerilen modelin başarımı literatürde yer alan modellere kıyasla oldukça dayanıklı ve yüksektir. Geliştirilen modelde sınıflandırıcı için hazırlanmış veri seti, belirlenen lehimleme hataları ve doğru uygulama olmak üzere 6 çeşit sınıfa ayrılmakta ve görselleştirilerek kullanıcıya sunulmaktadır.


Çalışmanın geri kalan kısmı aşağıdaki şekilde organize edilmiştir. Çalışmanın ikinci bölümünde verilerin toplanması ve veri ön işleme süreci sunulmaktadır. Üçüncü bölümde 2D sinyal işleme algoritmaları ve optimizasyon teknikleri ile evrişimli sinir ağının çalışmaya uygulanması anlatılmaktadır. Dördüncü bölümde önerilen yöntem ile elde edilen sonuçlar sunulmakta ve bu sonuçlar literatürde yer alan diğer yöntemler ile karşılaştırılarak tartışılmaktadır. Son olarak çalışmanın sonuçları beşinci bölümde vurgulanmaktadır.

BÖLÜM 2

VERİLERİN TOPLANMASI VE İŞLENMESİ


2.1 VERİLERİN TOPLANMASI

BDK üzerindeki krem lehim hatalarının tespit edilebilmesi ve bu hatalardan kaçınabilmek için çalışmanın başlangıcında kartlar üzerine uygulanan krem lehim hataları gözlenmiş olup sık görülen hatalar belirlenmiştir. Ancak, bu alanda hazır veri seti bulunamadığından çalışmaya özgü veri seti oluşturulmuştur. Veri seti, kartlar üzerine uygulanan krem lehim uygulamalarında karşılaşılan hatalar yani düzeltilemez uygulama, doğru uygulama, fazla lehim, eksik lehim, kısa devre, yabancı malzeme olarak 6 temel gruba ait görseller elde edilerek oluşturulmuştur. Her bir guruba ait örneklerin bulunduğu deneme kartları hazırlanmıştır. Deneme kartı olarak daha önceden tasarlanmış ve örnekleri aktif olarak hali hazırda kullanılmakta olan kartlar seçilmiştir. Kartların temininin ardından kartlara krem lehim sürebilmek için kartların eleklerinin üretimi yapılmıştır. Elekler micromete kalınlıklarında ince plakalardan oluşmaktadır. Plakalar üzerinde ped bölgelerinin belirlenmesi ve ardından bu bölgelerin eritilerek veya lazer kesimle açılması ile kartların elekleri üretilmiş olur. Eleklerin elde edilmesinin ardından krem lehimin düzgün sürebilmesi, kartlar ve elekler için krem lehim sürme makinasının çalışma mantığına benzer kartın ve eleğin doğru konumlarda sabitlenmesini sağlayan kart havuzları oluşturulmuştur. Kartın ve eleğin uygun konumda hizalanmasının ardından krem lehim el yordamı ile elek üzerinden karta sürülmüştür. Kartların profesyonel olarak lehimlenmesi için lehim sürme makinası, dizgi makinası ve ısıl profil oluşturulabilen dizgi fırını kullanılmaktadır. Kartların krem lehimleme ve dizgi süreci, krem lehim makinası ile krem lehimin sürülmesi ile başlar. Lehim sürebilmek için ilk olarak kart sabitleyicilerinin makinaya doğru bir şekilde yerleştirilmeleri gerekmektedir. Şekil 2.1’de kart sabitleyicilerinin genel olarak konumlandırılabilceği bölge ve sabitleme aparatı gösterilmektedir.




Şekil 2.1 Krem lehim sürme makinası elek destekleme aparatı yerleşimi.

Krem lehim sürülecek kartın eleği makinaya takılır ve elek üzerine krem lehim dökülür. Ardından kart eleğin alt kısmına hizalanır. Eleğin makinaya yüklenmesi ve elek ile kartların hizalanmasına ait görsel Şekil 2.2’de gösterilmektedir.



Şekil 2.2 Krem lehim sürme makinası elek yerleşmi.

Elek üzerine sürülen lehim makinasının kızakları yardımı ile ileri ve geri sürerek kartın ped bölgelerinin lehim alması sağlanır. Lehimin elek üzerine sürülmesi Şekil 2.3'te gösterilmektedir.




Şekil 2.3 Krem lehim sürme makinası lehimin kızaklar yardımı ile lek üzerinden sürülerek baskılı devre kartı yüzeyine yerleştirilmesi.

Kart dizgisi, dizgi makinasına kartın üzerinde bulunan bileşenlerin konumlarının tanımlanması ve tanımlanan her bir bileşen için makinarya bir atama gerçekleştirilir. Makinarya ait bileşen bölmeleri Şekil 2.4'de verilmektedir.




(a)



(b)

Şekil 2.4 a) Baskılı devre kartı dizgi makinası, b) Dizgi makinası komponent yerleşim bölmeleri.

Dizgi makinası BDK üzerine bileşenleri hareketli bir kol yardımı ile taşır ve yerleştirir. Hareketli kol daha önceden konumları makinaya programlanan bileşenleri yüksekliklerine dikkat ederek yerleştirir. İlk olarak yükseklik değeri en düşük olan bileşenler BDK üzerine yerleştirilir ve ardından diğer bileşenlerin dizgisi hareketli kol yardımı ile gerçekleştirilir. Dizgi sürecinde hareketli kolun çalışması Şekil 2.5'te gösterilmektedir.



Şekil 2.5 Dizgi makinası komponent taşıma kolunun çalışması.

Dizgi işlemi tamamlanan kartlar fırınlanır. Fırınlama işlemi üç aşamada gerçekleşir. İlk olarak kart ısınma sürecine alınır. İkinci aşamada sıcaklık lehimin eriyeceği değere kadar yükseltilir. Üçüncü kısımda ise soğutma işlemi yapılır ve kart oda sıcaklığına kadar soğutulur. Fırına ait görseller Şekil 2.6'da gösterilmektedir.




(a)



(b)

Şekil 2.6 a) Krem lehim eritilmesi için gerekli olan fırın, b) fırın iç kısmı ve kart taşıma ray sistemi.

Yukarıda bahsedilen veri setinin hazırlanabilmesi için gerekli olan kart hazırlıkları dört kart için sırası ile tekrarlanmıştır. Deneme kartlarının hazırlanması ile kartların 3840 (H) x 2160 (V) çözünürlüklü bir kamere ile doğru uygulama görüntüleri elde edilmiştir. Veri setinin oluşturulabilmesi için yukarıda saydığımız her bir hatanın üzerinde bulunduğu kart görüntülerini elde etmek amacı ile hatalar her biri kartlar üzerinde oluşturulmuştur ve resimleri yüksek çözünürlü kamera yardımı ile çekilmiştir. Elde edilen veri seti içerisindeki her bir görüntünün çözünürlüğünün yüksek olması sınıflandırma işleminin çalışma süresini oldukça uzatmaktadır. Bu sorunun üstesinden gelebilmek için, çözünürlüğü düşürmek ve işlem süresini azaltabilmek, resimlerde hataların bulunduğu bölgelerin şablonlarının elde edilmesi ve yeni bir veri seti oluşturulması ile aşılmıştır (Pramerdorfer and Kampel 2015, Hossin and Sulaiman 2015). Ayrıca; çalışmada lehim hatalarına odaklanıldığı için elde edilen şablonlar sayesinde kart yüzeyinde kaplama altında belirgin olarak görülebilen suyolları ayrıştırılmıştır. Böylece eğitim için kullanılabilecek bir veri seti elde edilmiştir. Görsel verilerin elde edilmesine kullanılan kamera düzeneği ve veri setinin oluşturulmasını sağlayan görseller Şekil 2.7’de gösterilmiştir.



Şekil 2.7 Veri toplama ve veri hazırlama için kullanılan kamera (a) kamera kurulumu (b) kamera (c) BDK görüntüsü (d) çıkarılmış ped bölgesi.

2.2 VERİLERİN SİNİR AĞI MODELİ İÇİN HAZIRLANMASI


Derin öğrenme modellerinde sistem performansı ve kararlılığı için büyük veri kümeleri çok önemlidir. Modelin performansı, veri setinin boyutu ve çeşitliliği ile önemli ölçüde artmaktadır (Yoo, Kim and Kim 2020). Bu nedenle bu çalışma için hazırlanan veri seti genişletilmiştir.

Görüntüler piksellerden oluşmaktadır. Her görüntünün yükseklik ve genişlik pikselleri vardır ve her piksel, ilgili alanın sayısal değerini içeren bir hücredir. Bu açıdan bakıldığında, her

görüntü aslında bir piksel matrisidir. Bu bilgiler ışığında, genişletme işlemi sinyal işleme teknikleri kullanılarak gerçekleştirilmiştir (Ye 2019, Park, Hwang, Lee and Kim 2020). Görüntüyü çevirme, döndürme, kaydırma, gürültü ekleme ve bulanıklaştırma teknikleri bu çalışmada kullanılan tekniklerdir (Mikołajczyk and Grochowski 2018, Perez and Wang 2017).

2.2.1 Çevirme


Görüntülerin, yani görsel işaretlerin matrislerden oluştuğunu yukarıda belirtilmişti. Bu doğrultuda görüntüleri yatay ve dikey olarak işlemek için matris işlemleri kullanılır. Bir görüntünün yatay ve dikey ekseninde döndürülmesi, veri türetme tekniklerinde sıklıkla kullanılan yöntemlerden biridir. Yatay veya dikey eksen çevirme yeteneği, görüntünün matrisindeki her bir sütun veya satırın değerlerini ters çevirerek gerçekleştirilebilmektedir (Gómez-Ríos, Tabik, Luengo, Shihavuddin, Krawczyk and Herrera 2020). Bu sayede, x veya y eksenleri etrafında döndürülen orijinal görüntünün bir kopyası elde edilir. Sütun değerlerinin sırasını tersine çevirmek için Python dilinde "fliplr ()" komutu kullanılır ve bu sayede yatay eksen boyunca sol ve sağ taraflarda bulunan piksel değerlerinin yer değiştirmesi sayesinde çevirme gerçekleştirilir. Aynı şekilde, satır değerlerinin sırasının tersine çevrilmesi de "flipud ()" komutu ile yapılmaktadır ve görüntünün dikey eksen boyunca üst ve alt piksel değerlerinin yer değiştirmesi sonucu görsel verinin çevrilmesini sağlar. Bu iki komut, Python dilinin dizi işlemlerini gerçekleştirmek için kullanılan NumPy kitaplığının içeriğidir. Bu çevirme işlemi Şekil 2.8'de hem yatay hem de dikey eksen çevirme örnekleri ile gösterilmektedir.



Şekil 2.8 Veri kümesi büyütme için çevirme tekniği (a) orijinal görüntü (b) yatay olarak çevrilmiş görüntü (c) dikey olarak çevrilmiş görüntü.

2.2.2 Döndürme

Döndürme işlemi, "rotate ()" komutu ile gerçekleştirilir. Komutun çalışması için bir görüntünün ve açı değerinin girilmesi gerekir. Açı pozitif seçilirse, görüntü saat yönünün tersine döndürülür, açı negative ise görüntü saat yönünde döndürülür. Çalışmada kullanılan veriler üzerinde döndürme işlemi döndürme açısının rastgele seçilmesi sağlanılarak elde edilmiştir. Şekil 2.9'da -45 ve +45 derece döndürülerek elde edilen görüntü verileri gösterilmektedir.



Şekil 2.9 Veri kümesi büyütme için döndürme tekniği (a) orijinal görüntü (b) 45 ° döndürülmüş görüntü (c) -45 ° döndürülmüş görüntü.


2.2.3 Kaydırma

Görüntüler istenilen yönde belirtilen değer doğrultusunda kaydırılabilir. Kaydırma işlemini gerçekleştirebilmek için yatay ve dikey ekseninde yer değiştirme değerlerinin belirlenmesi gereklidir. Bu değerler ile birlikte başlangıç konumu yeni bir noktaya kaydırılır. Matematiksel olarak,

$$A = a + da \quad (2.1)$$

$$B = b + db \quad (2.2)$$


formülleri ile ifade edilir (Gedraite and Hadad 2011). Burada a ve b başlangıç konum değerlerini ve da ve db yer değiştirmeleri ifade etmektedir. A ve B kaydırma işlemi sonucu elde edilen yeni konum değerlerini göstermektedir. Kaydırma işlemi örnek görseli şekil 2.10'da gösterilmektedir.



Şekil 2.10 Veri kümesi büyütme için kaydırma tekniği (a) orijinal görüntü (b) kaydırılmış görüntü.

2.2.4 Gürültü Ekleme

Bu teknik, görüntüye rastgele gürültü ekler ve genellikle görüntüyü düzenlemek için kullanılır. Modelin derin öğrenme uygulamalarında aşırı uyum göstermesini engeller (Hussain, Gimenez, Yi and Rubin 2017). Gürültü eklemek için "random_noise ()" komutu görüntü verisi üzerinde kullanılmaktadır. Çalışmada kullanılan veri seti için bu teknik rastgele görseller üzerinde rastgele gürültü ekleme ile gerçekleştirilmiştir. Görüntülere gürültü eklenmesi örneği Şekil 2.11'de gösterilmektedir.




Şekil 2.11 Veri kümesi büyütme için gürültü eklenme tekniği (a) orijinal görüntü (b) gürültü ekledikten sonra elde edilen görüntü.

2.2.5 Bulanıklaştırma

Görüntüleri bulanıklaştırmak için "gaussian_blur ()" komutu kullanılır. Bu yöntem, görüntüleri işlemek için çekirdek boyutunu kullanır. Bulanıklık oranı, çekirdeğin boyutuyla doğru orantılı olarak artar (Hussain, Gimenez, Yi and Rubin 2017).

Görüntü işlemede Gauss bulanıklığı, bir görüntünün Gauss işleviyle bulanıklaştırılmasının sonucudur. Ayrıntıları azaltmak ve görüntüdeki istenmeyen gürültüyü gidermek için çoğunlukla grafik yazılımında kullanılır. Gauss düzeltmesi, farklı ölçeklerde görüntü yapıları geliştirmek için bilgisayarla görme algoritmalarında bir ön işleme adımı olarak da kullanılır. Bu bulanıklaştırma tekniğinin görsel efekti, görüntüyü yarı saydam bir ekranda görüntülemeye benzer, odak dışı bir lens tarafından üretilen bokeh efektinden veya normal aydınlatma altındaki bir nesnenin gölgesinden belirgin bir şekilde farklı olan yumuşak bir bulanıklıktır (Gedraite and Hadad 2011).


Elde edilen veri seti, eğitim veri setinden yeni görüntüler türetilerek eğitim sürecinde aşırı beslenme gibi sorunların önüne geçmek için orantılı bir şekilde düzenlenmiştir. Kullanılan veri集中的 bulanıklık Şekil 2.12'de gösterilmektedir.



Şekil 2.12 Veri kümesi büyütme için bulanıklaştırılmış görüntü elde etme (a) orijinal görüntü (b) bulanık görüntü.

Yukarıda verilen sinyal işleme tekniklerini veri setini genişletmek amacı ile bir görsele sırası ile uygulamak yerine rastgele bir görüntü için rastgele bir teknik seçilerek gerçekleştirilmiştir. İlk olarak veri setinden seçilen rastgele bir görsel için rastgele bir teknik elde edilmeye çalışılmıştır. Sinyal işleme tekniklerinin bir diziye atanması sayesinde rastgele bir teknik


seçilmesi gerçekleştirilebilmiştir. Her bir görsel veri için süreç tekrar çalıştırılarak sistemin yeni resimler üretmesi sağlanmıştır. Bu sayede birbirinden tamamen farklı istenilen adette veri seti çoğaltılabilmektedir. Üretilmiş resimlerden bazıları Şekil 2.13'te gösterilmektedir.



Şekil 2.13 a) Çevrilmiş görüntü örneği, b) kaydırılmış görüntü örneği, c) gürültü eklenmiş görüntü örneği, d) döndürülmüş görüntü örneği.

Yukarıda verilen görseller daha önceden bahsedilen her bir yöntemin tek bir kod altında çalıştırılması ile elde edilmiştir. Yöntemlerin sıra ile çalıştırılmasına nazaran tek bir dizinde toplanması sonuca ulaşılırken geçen süreyi oldukça kısalttığı için tercih edilmektedir. Görüntü işleme tekniklerinin kullanılmasında zaman kazandıran bir diğer etmen ise resimlerin tek kanal üzerinden işlenmesidir. Görsel verilerde renkler kanallar sayesinde oluşturulmaktadır ve renkli görüntüler 3 kanaldan oluşmaktadırlar. Her bir kanal, bir aradayken beyaz rengi veren mavi, yeşil ve kırmızı rengi ifade etmektedir. Renkli bir görüntünün işlenmesi istenilirse bu üç kanalın her biri üzerinde işlem yapılması gerekmektedir. Bunun aksine tek kanallı görseller gri resimlerden oluşmaktadır ve görüntünün işlenmesi sadece tek kanal üzerinde gerçekleşmektedir. Gri resimler görüntü matrisi üzerindeki her pikselin değerinin maksimum ve minimum olması ile sırası ile beyaz ve siyah olarak göz tarafında algılanmaktadır. Yani istenilen pikselin matematiksel değeri maksimum ise o piksel beyaz olarak algılanır ve pikselin açık olduğu olarak yorumlanır aksine piksel değeri sıfır olarak belirlenir ise bu piksel siyah olarak yancaktır bu da pikselin kapatıldığı anlamına gelmektedir. Bu sayede görüntü

verilerinin işlenmesi için gerekli olan süre ciddi oranlarda düşürülmüş olur. Elde edilmek istenen işlenmiş görsel veriler işlem sürenin kısaltılması amacı ile ilk olarak gri görsellere dönüştürülerek sürece başlanmıştır. Herbir sinyal işleme tekniği için birer fonksiyon oluşturulmuş ve bu fonksiyonlar bir diziye atanmıştır. Bu sayede dizi içerisinde her bir resim için rastgele bir sinyal işleme tekniği seçilebilmiştir. Elde edilen her bir işlenmiş görsel tekrar renkli görsele dönüştürülerek kayıt altına alınmıştır. Hazırlanan koda ait akış diagramı Şekil 2.14’de verilmektedir.



Şekil 2.14 Görüntü eşleştirme için önerilen yöntemin akış diyagramı.


Model de kullanılmak üzere görsel veriler ile veri seti hazırlanması için hazırlanana çalışmada görsel veriler Şekil 2.14’de görülen akış diyagramı izlenerek türetilmiştir. YSA model eğitimlerinde kullanılan veri setlerinin oluşturulduğu belirli sınıflara ait örnek sayılarının eşit olması model verimini olumlu yönde etkilediği için bu yönteme başvurulmuştur. Hazırlanan programın sırası ile görsel verilere ulaşması sağlanmış ve işleme alınan her bir görüntü için rastgele bir türetme yöntemi ataması hazırlanan program tarafından gerçekleştirilmiştir. Türetilcek görüntü kümesi içerisindeki son resme ulaşana kadar her yeni görüntü için aynı süreç tekrarlanmaktadır. Elde edilen sonuçlar türetilmiş resimler olarak kaydedilmiş ve YSA modeli için veri seti oluşmaya başlamıştır. Görüntü verisi türetme, hazır veri seti bulmanın zor olduğu alanlarda çalışmaların yapılabilmesi için sıklıkla kullanılan bir yöntemdir. Türetme işlemi sayesinde istenilen büyüklükte veri seti oluşturulabilmektedir.



BÖLÜM 3

LEHİM HATALARININ TESPİTİNDE DERİN ÖĞRENME YÖNTEMİ

Bu bölümde sınıflandırıcı için kullanılan ESA açıklanacaktır. ESA görüntülerin özelliklerini ayırıştırma kabiliyeti nedeniyle pratik uygulamalarda çok başarılıdır ve segmentasyon ve sınıflandırma gibi alanlarda yaygın olarak kullanılmaktadır (Ye 2019, Jiang, Cheng and Tao 2012). Daha az ön işleme kullanmaları, onları diğer görüntü sınıflandırma algoritmalarından daha kullanışlı hale getirir. Kendi işlerinde birçok farklı mimariye sahiptirler (Yoo, Kim and Kim 2020, Indolia, Goswami, Mishra and Asopa 2018). Bu çalışmada ESA, ReLu aktivasyon fonksiyonu ile birlikte kullanılmış ve yapısı Şekil 3.1'de sunulmuştur.



Şekil 3.1 Evrişimli sinir ağı yapısı.

ESA'nın çalışması için işlenen görüntü verilerinden elde edilen eğitim verileri, sinir ağı girişine gönderilir. Giriş verisinin sınıfı, evrişim, etkinleştirme, havuzlama, yumuşatma, tam bağlantı ve sınıflandırma katmanları aracılığıyla işlenmesiyle elde edilir.


3.1 EVRİŞİMLİ SİNİR AĞI (ESA) GENEL MODELİ

ESA, bir girdi ve bir çıktı katmanının birden fazla gizli katman ile birlikte kullanılmasından oluşan genel bir yapay sinir ağı (YSA) modelidir. Modele sunulan giriş verisi bir nöron tarafından alınır ve katmanlarda bazı fonksiyonlara tabi tutularak çıkış verisine ulaşılır (Indolia,

Goswami, Mishra and Asopa 2018, Albawi, Mohammed and Al-Zawi 2018). Genele olarak fonksiyonun formülasyonu 3.1’de gösterildiği gibidir.

$$F(X, W) = Y \quad (3.1)$$

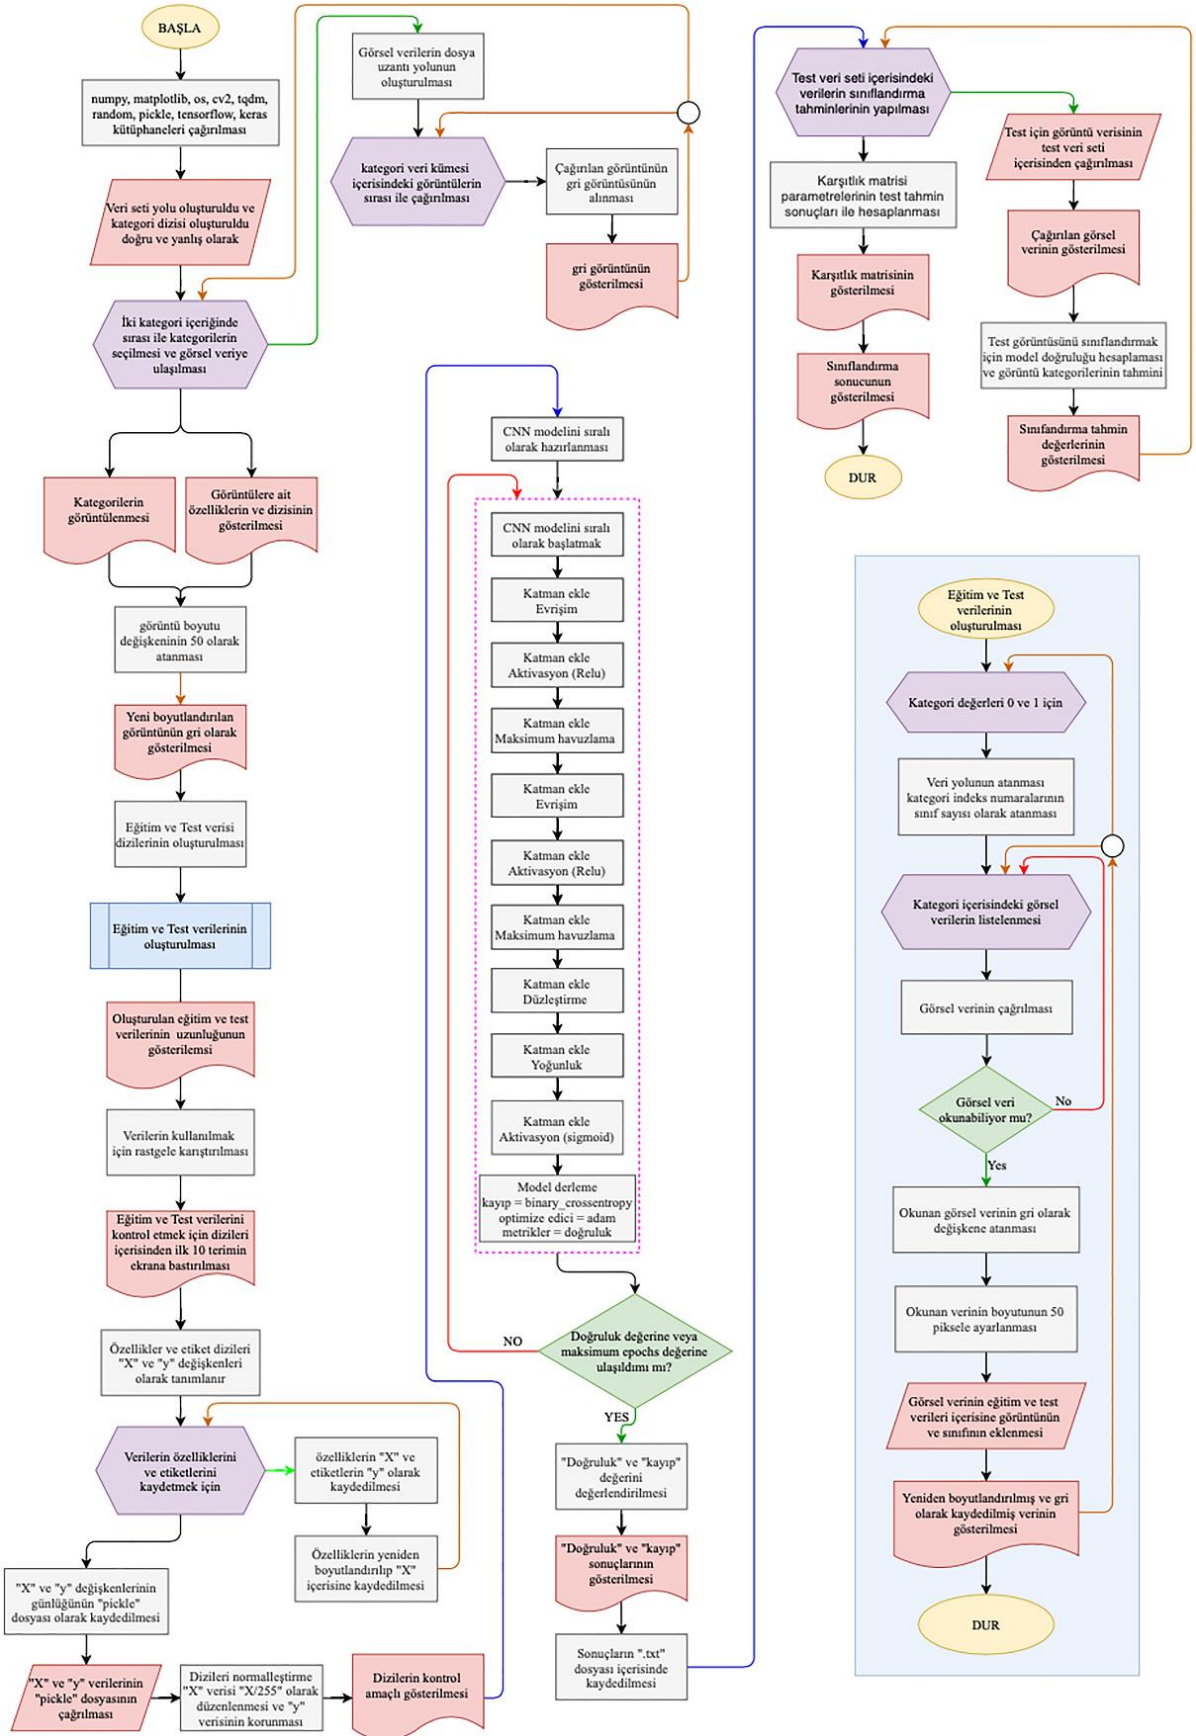
Burada X giriş verisini vektörel olarak temsil ederken Y ise çıkış vektörünü temsil etmektedir. W, iki bitişik katmanın nöronları arasındaki bağlantının ağırlık vektörüdür. Ağırlık vektörü bağlantının gücünü temsil etmek için kullanılmaktadır. Sınıflandırma işlemi de bu ağırlık vektörü ile gerçekleştirilmektedir. ESA ağırlık vektörü yardımı ile elde edilen bağlamsal bilginin doğrultusunda verilerin sınıflandırılmasını gerçekleştirebilmesi yeteneğinden dolayı sınıflandırma süreçlerinde en çok kullanılan modeldir. Sinir ağının işleyişi Şekil 3.2’de sunulmuştur (Yoo, Kim and Kim 2020, Perez and Wang 2017).



Şekil 3.2 Evrişimli sinir ağına ait temel bileşenler.

Temelde bir ESA, evrişim katmanı havuzlama katmanı aktivasyon katmanı ve tam bağlantı katmanı olmak üzere 4 bileşenden oluşmaktadır. Temel bir evrişimli sinir ağı modelinin bileşenlerinin ilevselliği Şekil 3.3’de verildiği gibi sembolize edilmiştir.


Kullanılması tercih edilen ESA modeli AlexNet mimarisi ile hazırlanmıştır. AlexNet mimarisi birbirini takip eden evrişim ve havuzlama katmanlarından oluşmaktadır. Evrişim katmanında aktivasyon fonksiyonu olarak doğrultulmuş doğrusal birim (Rectified Linear Unit-ReLu) aktivasyon fonksiyonu kullanılmaktadır. Hazırlanan her bir evrişim katmanına sunulan görsel veriler üzerinde 3x3 lük bir filter kullanılarak taratılarak bölgesel ağırlık vektörleri elde edilmiştir. Bu sayede sınıflandırma için en önemli bölgeler ağırlık vektörleri sayesinde belirlenmektedir. Evrişim katmanında ağırlık vektörleri yardımı ile elde edilen katman çıkış verileri bir sonraki katmanda yani havuzlama katmanında işlenir. 2 × 2’lik bir filtre yardımı ile filtre içerisinde bulunan verilerin ağırlık vektörü ile etkileşimi sonucu en önemli olan veriyi saklar. Önemli bölgeleri saklamasından dolayı hesaplama karmaşıklığını azaltmak için kullanılır. Bu süreçte giriş verisini işlemek için hazırlanan filter içerisindeki en önemli veriyi tuttuğu için bazı bilgilerin kaybolması kaçınılmaz bir durumdur.



Şekil 3.3 Lehim kusurlarını tespit etmek için önerilen modelin akış diyagramı.

3.2 EVRİŞİM KATMANI

Evrışimli yapay sinir ağının temel katmanıdır. Bu katmana sunulan giriş görüntüsü matris olarak işlem görür. Katmanda, bir filtre kullanarak görüntünün özellikleri elde edilir. Genellikle filtreler 3×3 yada 5×5 boyutlarında seçilebilmektedir. Sonuç olarak görüntünün özellik haritasını ortaya koymaktadır (Yoo, Kim and Kim 2020). Bu çalışmada, evrişim katmanı Şekil 3.4’de olduğu gibi ifade edilebilir.




Şekil 3.4 Evrişim katmanı çalışma prensibi.

Evrışim katmanında ardarda bulunun katmanlardaki bazı nöronlar birbirlerine ilgili alanlar aracılığı ile bağlantılıdır. Bu ilgili alan bir önceki katmanda belirli bir bölgeye ağırlık vektörü ile bağlantılıdır bu da belirlenmiş bölge içerisindeki tüm nöronlarda ağırlık vektörü aynı değere sahiptir. Bu benzerlik üzerinden farklı kısımlarda bulunan benzer özellikler tespit edilebilmektedir. Giriş olarak sunulan görüntünün bölgesel özellikleri evrişim katmanında elde edilmiş olur.

3.3 AKTİVASYON KATMANI

Aktivasyon katmanı, evrişim katmanı çıktılarını lineer olmayan işlemlere tabi tutan katmandır. Çeşitli aktivasyon fonksiyonlarına sahip olan katmandan bu çalışma için doğrultulmuş doğrusal birim olarak bilinen ReLu (Rectified Linear Unit-ReLu) aktivasyon fonksiyonu seçilmiştir. ReLu aktivasyon fonksiyonu negatif değerler ile işlem yapmak yerine negatif değerleri sıfıra atar. Yani sıfırdan küçük değerler için sonuç sıfırken, sıfırdan büyük olan değerler için sonuç olarak kendi değerini döndürür. Formülü ve grafiği aşağıdaki Şekil 3.5’de verilmektedir.



Şekil 3.5 ReLu formülü ve grafiği.


Evrişimli sinir ağı yapısında genellikle en çok tercih edilen aktivasyon fonksiyonu sigmoid aktivasyon fonksiyonudur. Ancak ReLu’nun kısmi türevlerinin hesaplanmasının kolaylığı ve gradyanların kabyolmasını engellemesi yönünden sigmoid fonksiyonuna nazaran daha iyi olduğunu kanıtlamıştır. Ayrıca eğitim sürelerine bakıldığında sigmoid fonksiyonu ReLu fonksiyonundan daha yavaştır. Sigmoid ve ReLu aktivasyon fonksiyonu matematiksel olarak,

$$f(x) = \max(0, x) \quad (3.2)$$

şeklinde ifade edilir. Burada x ReLu girişine gelen verinin sayısal değerini ifade etmektedir.

3.4 HAVUZ KATMANI

Sinir ağı üzerinde oluşabilecek uyumsuzlukları belirlemek için işlenmiş veri üzerinde karşılaşılabilecek kayma boyutunu, ağ parametrelerini ve hesaplama işlemi sayısını azaltarak gerçekleştiren katmandır. Bu çalışmada havuzlama işlemleri içerisinde en popüler olan maksimum havuzlama algoritması kullanılmıştır (Gómez-Ríos, Tabik, Luengo, Shihavuddin, Krawczyk and Herrera 2020). Maksimum havuzlama, resim üzerine uygulanan bir filtre ile en büyük değeri çıktı olarak seçen ve anlamlı bilgiyi içeren daha küçük çıktıları sinir ağının doğru karara ulaşabilmesi için kullanmaktadır. 4×4 boyutlarına sahip bir resim üzerinde 2×2 'lik bir filtre Şekil 3.6'da gösterilmektedir.




Şekil 3.6 Maksimum havuzlama katmanı prensibi.

Havuzlama katmanı girişine gelen veriyi kullanarak daha küçük ve anlamlı bilgiyi içeren bir çıkış vektörü oluşturmaktadır. Maksimum havuzlama dışında kullanılan bir diğer havuzlama tekniği ise ortalama havuzlama tekniğidir. Görsel veriden elde edilen veri boyutunu çok önemli ölçüde küçülten maksimum havuzlama tekniği ortalama havuzlama tekniğine göre en çok kullanılan yöntemdir.

3.5 DÜZLEŞTİRME KATMANI

Tam bağlantı katmanı için giriş verilerini oluşturan ve hazırlayan katmandır. Bu katmanda bulunan veriler evrişim katmanı ve havuzlama katmanlarından alınan verilerin tek boyutlu bir diziye dönüştürülmüş biçimleridir (Hossin and Sulaiman 2015). Düzleştirme katmanı temel olarak Şekil 3.7'de gösterildiği gibi çalışır.



Şekil 3.7 Maksimum havuzlama katmanı prensibi.

3.6 TAM BAĞLANTI KATMANI

Bu katmanda, düzleştirme katmanından gelen tek boyutlu matris formunda bulunan veriler işlenir. Nöronlar arası bağlantı giriş olarak sunulan veriler göz önüne alınarak ardışık olarak birbirlerine bağlanır. Katmanın çıktısı, ağırlık vektörü ve bir önceki katmanın çıktısı olarak tam bağlantı katmanının girişine sunulan giriş vektörünün noktasal çarpının gerçekleştirilmesi ile sağlanır. Bu katman sayesinde sınıflandırma için son özellikler seçilmiş olur (Yoo, Kim and Kim 2020).

3.7 SINIFLANDIRMA KATMANI

Sınıflandırma katmanında, sınıf çeşitli sınıflandırıcılar kullanılarak belirlenir. Çoğunlukla sınıflandırıcı olarak softmax tercih edilmesine rağmen bu çalışmada 2 sınıf kullanılmasından dolayı sınıflandırıcı olarak binary crossentropy tercih edilmiştir. Binary crossentropy kendilerine yöneltilen soruya doğru veya yanlış, hep veya hiç olarak yalnız iki seçenek ile yanıt veren logaritmik kayıp fonksiyonudur. Bu logaritmik fonksiyonun çıktısı olarak doğru ve yanlış sınıflandırılır (Yoo, Kim and Kim 2020).

3.8 OPTİMİZASYON

Optimizasyon, ağ tarafından üretilen çıktı değeri ile gerçek değer arasındaki farkı mutlak minimuma indirgeyerek öğrenmeyi daha verimli hale getirmek amacı ile kullanılan yöntemdir. Bu çalışmada optimizasyon metodu olarak Uyarlanabilir Moment Tahmini (Adaptive Moment Estimation-Adam), Kök ortalama kare yayılım (Root mean square prop-RMSprop) ve AdaMax algoritmaları kullanılarak sistemin verimliliği kıyaslanmıştır (Kingma and Ba 2017).

Adam optimizasyonu, Gradyan İniş (Gradient Descent) temelli bir optimizasyon yöntemidir ve geçmiş eğimlerin karelerinin üssel olarak ağırlıklandırılmış ortalamalarının (v_t) kullanılmasının yanında, momentum değişikliklerini (m_t) de önbellekte saklar. Model içerisinde verimi iyileştirmek için kullanılır ve matematiksel ifadesi aşağıda verildiği gibidir,

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (3.3)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (3.4)$$

$$m'_t = \frac{m_t}{1 - \beta_1^t}, v'_t = \frac{v_t}{1 - \beta_2^t} \quad (3.5)$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{v'_t + \epsilon}} m'_t \quad (3.6)$$

Verimliliği arttırmak için optimum nokta aranması esnasında karşılaşılan salınımları ortadan kaldırarak hedefe gitme hızını arttırmayı, öğrenme katsayısının değerinin momentumlu gradientlerin karelerini alınması ile sabit katsayı probleminin üstesinden gelerek başarmaktadır.

Yukarıda verilen her bir işlem içerisinde kullanılan terimlerin açıklamaları, η adım boyutunu, β_1, β_2 moment tahminleri için üssel azalma oranlarını gösterir ve 0 ile 1 arasında seçilmelidir, v_t geçmiş eğimlerin karelerinin üssel ağırlık ortalamalarını, m_t momentum değişikliklerinin ön belleğe alınmasını, θ_t ilk parametre vektörüdür. g_t , t zaman aşımındaki stokastik hedefi belirtmektedir, ϵ ise 10^{-8} olarak tanımlanmaktadır ve u_t üssel ağırlıklı sonsuzluk normunu belirtmektedir (Kingma and Ba 2017).

RMSprop optimizasyonu Adam optimizasyonuna benzer şekilde Gradyan iniş (Gradient Descent) optimizasyon yöntemini temel alır. RMSprop optimizasyon yöntemi, öğrenme katsayısının aşırı küçültme sorununa bir çözüm sunmak amacı ile ortaya atılmıştır. Sorunu çözmek amacı ile geçmiş eğitimlerde elde edilen tüm eğimlerim karelerinden elde edilen değerleri kullanmak yerine, miktarı belirli bir çerçeve boyutu ile sınırlandırılmıştır. RMSprop optimizasyonunun matematiksel ifadesi,

$$E[g^2]_t = 0.9E[g^2]_{t-1} + 0.1g_t^2 \quad (3.7)$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{E[g^2]_t + \epsilon}} g_t \quad (3.8)$$

$$g_t = \nabla_{\theta_t} J(\theta_t) \quad (3.9)$$

Yukarıda verilen her bir işlem içerisinde kullanılan terimlerin açıklamaları, η adım boyutunu, θ_t ilk parametre vektörüdür, g_t t zaman aşımındaki stokastik hedefi belirtmektedir, $\epsilon 10^{-8}$ olarak tanımlanmaktadır, E beklenen değer ve J en aza indirgenmesi gereken nesnel fonksiyonu temsil eder. (Kingma and Ba 2017).

AdaMax optimizasyonu da Gradyan iniş (Gradient Descent) optimizasyon yöntemini temel alır. AdaMax, sonsuzluk normuna dayanan bir Adam optimizasyon yöntemi çeşididir. AdaMax optimizasyonu özellikle karşılaştırma modellerinde Adam optimizasyonuna üstün gelebilir. Adam'ın aksine, bu algoritmanın seyrek uygulaması sadece değişken dilimleri ve buna karşılık gelen m_t , v_t terimlerini ileri geçişte değişkenin o kısmı kullanıldığında günceller. Bu seyrek davranışın yoğun davranışla zıt olduğu anlamına gelir. AdaMax optimizasyonunun matematiksel ifadesi şu şekilde modellenmiştir,

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) |g_t|^2 \quad (3.10)$$

$$v_t = \beta_2^p v_{t-1} + (1 - \beta_2^p) |g_t|^p \quad (3.11)$$

$$u_t = \beta_2^\infty v_{t-1} + (1 - \beta_2^\infty) |g_t|^\infty = \max(\beta_2 \cdot v_{t-1}, |g_t|) \quad (3.12)$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{u_t} m'_t \quad (3.13)$$

Yukarıda verilen her bir işlem içerisinde kullanılan terimlerin açıklamaları, v_t geçmiş eğimlerin karelerinin üssel ağırlık ortalamalarını, η adım boyutunu, β_2 moment tahminleri için üstel azalma oranlarını gösterir ve 0 ile 1 arasında seçilmelidir, θ_t ilk parametre vektörüdür. g_t t zaman aşımındaki stokastik hedefi belirtmektedir ve u_t üstel ağırlıklı sonsuzluk normu olarak tanımlanmaktadır (Kingma and Ba 2017).

3.9 EVRİŞİMLİ SINIR AĞI (ESA) MİMARİLERİ

Yukarıda anlatılan evrişimli ağın içerisinde gerçekleştirilen işlemler ile oluşturulan model bütünleri ile evrişimli sınır ağı mimarileri oluşturulmaktadır. Aşağıda bazı mimariler tanıtılmaktadır (Indolia, Goswami, Mishra and Asopa 2018, Albawi, Mohammed and Al-Zawi 2018).

3.9.1 LeNet-5 Mimarisi

Yann LeCun ve ekibinin sayıların okunması amacı ile 1998 yılında ilk başarılı örneğinin yayınlandığı evrişimli sinir ağı modelidir. Aktivasyon fonksiyonu olarak sigmoid ve hiperbolik tanjant fonksiyonları kullanılan mimaride, maksimum havuzlama yerine türetilmiş ortalama havuzlama işlemi gerçekleştirilmektedir. Mimari sayıların okunması üzerine geliştirildiği için 0-9 aralığında bulunan rakamların sınıflandırılabilmesi amacı ile 10 sınıflı softmax barındırmaktadır.

3.9.2 AlexNet Mimarisi

Alex Krizhevsky, Ilya Sutskever and Geoffrey Hinton tarafından geliştirilmiştir ve evrişimli sinir ağı modelleri ve derin öğrenmenin 2012 yılında tekrar ilgi odağı olarak gündeme gelmesine yol açan mimaridir. Evrişim ve havuzlama katmanlarının tekrarlanması sebebi ile LeNet mimarisi ile oldukça benzerdir. Model doğrultulmuş doğrusal birim yani ReLu ile maksimum havuzlama yöntemleri ile oluşturulmaktadır. Grafik işlem birimi (GPU) üzerinde çift parçalı olarak oluşturulabilmektedir. ImageNet ILSVRC yarışmasında %74,3'ten %83,6'ya çıkarmayı başardığı sınıflandırma doğruluk oranı ile sınıflandırma işlemlerinde çok etkili bir mimari olduğunu kanıtlamıştır.

3.9.3 VGG-16 Mimarisi

Diğer modellerden evrişim katman sayısı ile ayrılan basit bir ağ modelidir. Evrişim katmanları 2'li yada 3'lü kullanılır. Her bir katman sonucunda elde edilen ağırlık vektörleri birbirinden farklıdır. Bu sayede katman sayısının her artışı ağırlık vektörleri ile oluşturulan filtreler ile elde edilen öznitelikler sunulan görüntü verisinin derinliğini simgeler.


3.9.4 ResNet Mimarisi

Diğer modellerden farklı bir mantıkla, ağ modellerinin eskiye nazaran daha derinleşmeye başladığı bir modeldir. Diğer modellerde olmayan, artık değerlerin geri beslenmesi ile oluşturulan ResNet modeli her bir artık değer sonrakı katmanlara besleyen bloklar içerir. Bu özellik onu klasik modellerden ayırmaktadır. Daha hızlı bir eğitim süresine sahiptir. Teoride, başarımın model içerisindeki katman sayısının artmasıyla artacağının düşünülmesine rağmen


elde edilen deneyimler ve gözlemler sayesinde bu varsayımın doğru olmadığı anlaşılmıştır ve ResNet modeli oluşturulmuştur.

3.10 GÖRÜNTÜ İŞLEME

Girişi bir fotoğraf veya video verisi olan ve sunulan veri üzerinde sinyal işleme teknikleri yardımı ile istenilen bilginin elde edilmesini amaçlayan sinyal işleme yöntemidir. Sınıflandırıcı sonucu doğru ve yanlış sınıflarına ayrıştırılan veri seti, orijinal görüntü üzerinde görüntü işleme teknikleri yardımı ile belirlenerek sinir ağı modeli çıktılarının konumları belirlenebilmektedir. Öncelikle asıl resim ve şablon görüntüler tek kanallı gri görüntüye dönüştürülerek işlem süresi 3 kanallı renklendirilmiş kırmızı yeşil ve mavi (Red Green Blue-RGB) kanallı görüntüler ile yapılan çalışmalara nazaran hızlandırılır (Park, Hwang, Lee and Kim 2020). Şablonun asıl resim üzerindeki konumunun belirlenebilmesi için şablon genişlik ve yükseklik ölçüleri belirlenir ve bu değerler yardımı ile eşleştirme işlemi yapılır. Sonuç olarak şablon benzerliğinin yakalandığı ilk nokta üzerinden genişlik ve yükseklik değerleri ile oluşturulan alan içerisinde bulunan görüntüye ait piksellerin istenilen oranda uyuşması bize eşleşme sonucunu verir. Şekil 3.8’de doğru uygulamaya dair şablon örnekleri paylaşılmaktadır.




(a)




(b)

Şekil 3.8 Şablon örnekleri (a) doğru şablon örneği 1 (b) doğru şablon örneği 2.

Şekil 3.9’da BDK üzerinde belirlenmiş bir bölgeye ait orijinal görüntü ve doğru uygulama örneklerinin belirtildiği görseller sunulmaktadır.



(a)



(b)


Şekil 3.9 Lehim hatalarını tespit etmek için görüntü eşleştirme örnekleri (a) orijinal görüntü (b) eşleşen görüntü.

Şekil 3.10’da hata sınıflarından eksik lehim ve fazla lehim örnekleri sunulmaktadır.



Şekil 3.10 Şablon örnekleri (a) eksik lehim şablon örneği (b) fazla lehim şablon örneği.

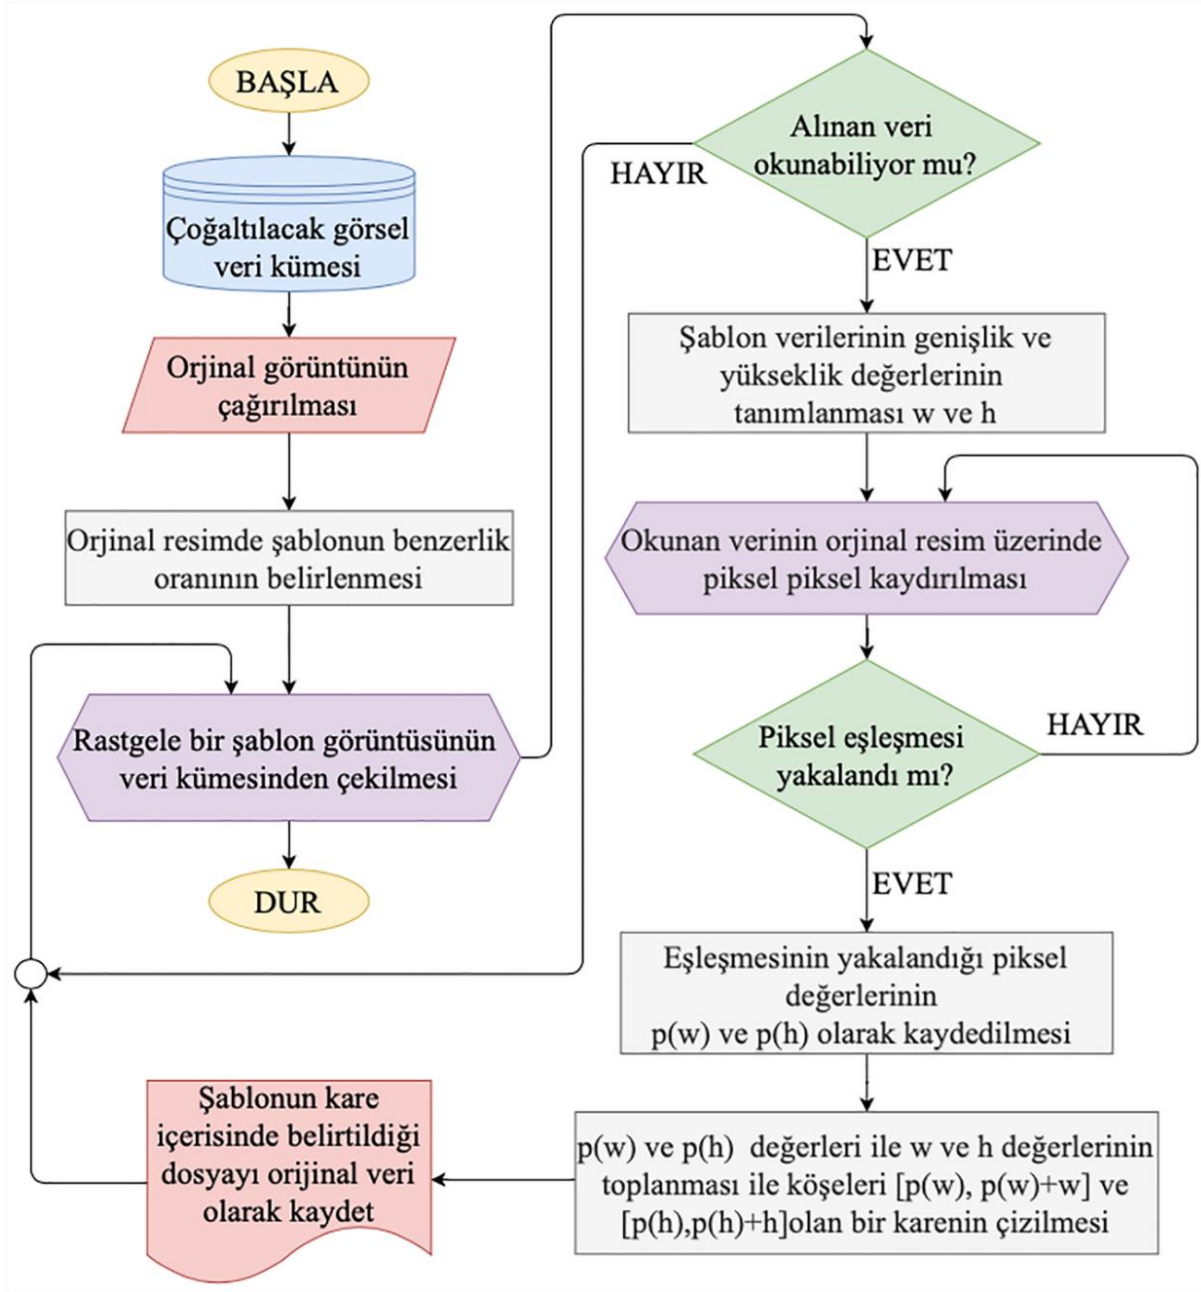
Şekil 3.11’de BDK üzerinde belirlenmiş bir bölgeye ait original görüntü üzerinde eksik lehim ve fazla lehim hatalarının tespiti gösterilmektedir.



Şekil 3.11 a) Lehim hatalarını tespit etmek için görüntü eşleştirme örnekleri (a) orijinal görüntü (b) eşleşen görüntü.

Görüntülerin eşlenmesi, veri seti içerisinde bulunan tüm verilerin sisteme yüklenecek olan bir BDK görsel verisi üzerinde sırası ile aranması ve eşleşen verilerin hata türüne özel renklerle belirtilmesi ile gerçekleştirilmektedir. Kullanılan sistemin hibrit olarak çalışması sistemin ESA çıktıları sonucu sınıflandırılan veriler doğrultusunda hatalı sonuçlar vermesine sebebiyet verebilmektedir. Bu sebeple ESA modeli sonucunun performansı akabinde gerçekleşen görüntü eşleştirme yönteminin sonucunu da etkileyecektir. Bu sorunun üstesinden gelinmesi için optimizasyon algoritmaları kullanılmaktadır. Önerilen modelde en verimli sonucun elde edilebilmesi ve hatanın en aza indirgenebilmesi için optimizasyon algoritmaları sırası ile sistemde denenmiş ve görüntü işleme safhasında veri seti içerisinde tanımlanan hata sınıflarının eksiksiz olarak tanımlanması gerçekleştirilmiştir.

Şablonların orijinal resim üzerinde görüntü eşleştirilmesi ile aratılıp görsel olarak sunulmasını gerçekleştirebilmek için hazırlanmış hibrit sistemin ilgili kısmının akış diyagramı Şekil 3.12’de sunulmaktadır.



Şekil 3.12 Görüntü eşleştirme için önerilen yöntemin akış diyagramı.




BÖLÜM 4

DENEYSEL SONUÇLAR VE TARTIŞMA

Bu bölümde, daha önce bahsedilen yöntemlerle hazırlanan veri setinin işlenmesi ele alınmaktadır. Öncelikle görüntü işleme teknikleriyle işlenen veriler ESA beslemek için hazırlanmış ve sinir ağı kullanılarak elde edilen veriler görüntü işleme teknikleriyle işlenmiştir. Veri seti ESA ile iki sınıfa ayrılmış ve görüntü işleme yöntemleriyle altı alt kategoriye ayrılmıştır. Ayrıca sonucun verimliliği Adam, RMSprop ve AdaMax optimizasyon yöntemleri ile karşılaştırılarak en verimli sistem elde edilmeye çalışılmıştır.


4.1 KREM LEHİM VERİ SETİ

Çalışmada veri seti, krem lehim uygulanmış kartların 3840x2160 çözünürlükte resimleri toplanarak veri seti hazırlanmıştır. Toplamda 274 adet ham kart görüntüsü, yüksek çözünürlüklü olması nedeni ile görüntü işleme ve sinir ağı eğitiminde yaşanabilecek uzun işlem süresi ve yetersiz sistem gereksinimlerinin üstesinden gelebilmek için daha küçük boyutlu ham verilere dönüştürülmüştür. Sınıflandırılmak istenen ped bölgelerinden doğru ve hatalı uygulamalar için veri seti elde edilmiştir. Sistemin daha verimli çalışabilmesi için veri seti içerisindeki her bir görsel veri yeniden boyutlandırılarak her bir görüntünün piksel değeri 50×50 olarak ayarlanmıştır. Sistem için hazırlanan giriş veri seti örneklerine ait görseller Şekil 4.1’de doğru ve hatalı uygulama görselleri sunulmaktadır.




Şekil 4.1 Veri seti örnekleri (a) doğru uygulama (b) doğru uygulama 2 (c) yanlış uygulama 1 (d) yanlış uygulama 2.

Şekil 4.2’de falza ve eksik lehim hatasına ait ikişer görsel veri sunulmaktadır.



Şekil 4.2 Veri seti örnekleri (a) fazla lehim hatası 1 (b) fazla lehim hatası 2 (c) eksik lehim hatası 1 (d) eksik lehim hatası 2.

Şekil 4.3’de kısa devre ve yabancı malzeme hataları uygulamalarına ait 2 görsel veri sunulmaktadır.



Şekil 4.3 Veri seti örnekleri (a) kısa devre hatası 1 (b) kısa devre hatası 2 (c) yabancı malzeme hatası 1 (d) yabancı malzeme hatası 2.

Veri toplama ve ön işleme başlığı altında verilen tekniklerle veri setini çoğaltarak sinir ağını beslemek amacıyla eğitim veri seti hazırlanmıştır. Sinir ağını beslemek için 291 doğru ve 291 yanlış görüntü verisi kullanılmıştır. Çizelge 4.1’de görüldüğü üzere eğitim sürecini test etmek için tahsis edilen test verileri görüldüğü üzere 33 doğru ve 33 yanlış görüntüden oluşmaktadır. Sistem toplam 582 veri ile eğitilmiş ve modele daha önceden gösterilmemiş olan 66 test verisi ile test edilmiştir. Eğitim ve test veri setleri sayıları bilgisi Çizelge 4.1’de gösterilmektedir.

Çizelge 4.1 Krem lehim veri seti havuzu.

Sınıflar	Veri	Eğitim Verisi	Test Verisi	Toplam
Doğru	324	291	33	324
Yanlış	324	291	33	324
Toplam	648	582	66	648

Eğitim için hazırlanan veri setinin görüntü işleme ile eşleştirilmesi ile kart üzerinde yanlış sınıflandırılmış örneklerin tespiti sağlanmıştır. Bu amaçla hazırlanan krem lehim veri seti doğru uygulama olarak yeniden düzenlenmiş ve yanlış uygulama türleri olarak tekrar düzenlenerek

krem lehim uygulaması hata kategorileri oluşturulmuştur. Katogoriler Çizelge 4.2’de gösterilmektedir.

Çizelge 4.2 Krem lehim hata türleri ve elde edilen veri seti içerisindeki örnek sayıları

Hata Türleri	Örnekler
Doğru	324
Düzeltilemez	51
Eksik Lehim	60
Fazla Lehim	86
Kısa Devre	60
Tanımlanmamış Obje	67

4.2 PERFORMANS ÖLÇÜMLERİ

Bu çalışmada sınıflandırıcı performansını iyileştirmek için sınıflandırıcı ölçütü olarak doğruluk performans ölçütü kullanılmıştır. Karışıklık matrisi Çizelge 4.3’de verilmiştir. Metrik türleri, matematiksel ifadeleri ve karışıklık matrisi verileri ile elde edilen sonuçları Çizelge 4.4’de verilmiştir. Ölçütlerin ifade edilmesinde kullanılan değişkenler sırası ile doğru pozitif (True Positive – TP), doğru negatif (True Negative – TN), yanlış pozitif (False Positive – FP) ve yanlış negatif (False Negative – FN) olarak tanımlanmaktadır.

Çizelge 4.3 Karışıklık matrisi ve hesaplanan parametreleri.

Karışıklık Matrisi		Tahmin		Toplam
		Doğru	Yanlış	
Test Verisi	Doğru	TP=22	FN=11	33
	Yanlış	FP=0	TN=33	33
Toplam		22	44	66

Çizelge 4.4 Performans ölçütleri ve elde edilen değerleri.

Metrikler	Sonuçlar	Metrikler	Sonuçlar
Doğruluk	0.83	Hassasiyet	1.00
Duyarlılık	0.67	Geri Çağırma	0.40
Özgüllük	1.00	F-Ölçümü	0.80

Yukarıda verilen ölçütleri kısaca tanımlamak gerekirse; doğruluk ölçüsü, eğitimde kullanılan toplam örnek sayısı içerisinde doğru tahminlerin oranını belirlediğinden dolayı bu çalışmada kullanılmaktadır. Doğruluk ölçütünün matematiksel ifadesi,

$$(TP + TN) / (TP + FP + TN + FN) \quad (4.1)$$

Hassasiyet ölçütü, sınıflandırma sonucu doğru çıkan pozitif tahminlerin ölçülmesi için kullanılmaktadır. Hassasiyet ölçütünün matematiksel ifadesi şu şekilde modellenmiştir,

$$TP / (TP + FN) \quad (4.2)$$

Özgüllük ölçütü, sınıflandırma sonucu doğru çıkan negatif tahminlerin ölçülmesi için kullanılmaktadır ve özgüllük ölçütünün matematiksel ifadesi aşağıda verildiği gibidir,

$$TN / (TN + FP) \quad (4.3)$$

Kesinlik ölçütü, sınıflandırma sonucu pozitif olarak elde edilen sonuçlar arasında pozitif olarak doğru tahmin edilenlerin sayısını ölçmek için kullanılır. Kesinlik ölçütüne ait matematiksel ifade,

$$TP / (TP + FP) \quad (4.4)$$

Geri çağırma ölçütü, pozitif tahminlerin ne kadar doğru sınıflandırıldığını ölçmektedir. Geri çağırma ölçütünün değeri aşağıda verilen matematiksel ifade kullanılarak hesaplanır,

$$TP / (TP + TN) \quad (4.5)$$

F-measure, geri çağırma ve kesinlik ölçütleri arasındaki harmonik ortalamadır ve F-ölçümü matematiksel ifadesi aşağıda verildiği gibidir.

$$2*TP / (2*TP + FP + FN) \quad (4.6)$$


4.3 DENEYSEL SONUÇLAR

Bu bölümde 100 dönemlik eğitim ile çalışan kodun üç farklı optimizasyon yöntemi kullanılarak elde edilen performans sonuçları karşılaştırılmıştır. Her şeyden önce, her üç yöntem için elde edilen performans oranları aşağıdaki Tablo 4.5'de verilmiştir. Yukarıda verilen tablolardan elde edilen sonuçlara göre AdaMax optimizasyonunun başarı oranının RMSprop ve Adam optimizasyon yöntemlerine göre daha verimli olduğu görülmektedir. Üç optimizasyon yönteminin her biri ile elde edilen performans ve kayıp grafikleri, görsel karşılaştırma yapmak için aşağıda sunulmuştur.


Çizelge 4.5 Optimizasyon türlerine ait verim ve kayıp çizelgesi.

Optimizasyon	Verim	Kayıp
AdaMax	% 96.40	% 13.56
RMSprop	% 94.67	% 32.46
Adam	% 95.53	% 30.91

100 iterasyonda AdaMax optimizasyonunun performans ve kayıp grafikleri sırası ile Şekil 4.4 ve Şekil 4.5'te sunulmaktadır,




Şekil 4.4 AdaMax optimizasyonunun doğruluğu ve doğrulama doğruluğu karşılaştırması.




Şekil 4.5 AdaMax optimizasyonunun kayıp ve doğrulama kaybı karşılaştırması.

100 iterasyonda RMSprop optimizasyonunun performans ve kayıp grafikleri sırası ile Şekil 4.6 ve Şekil 4.7’de sunulmaktadır,




Şekil 4.6 RMSprop optimizasyonunun doğruluğu ve doğrulama doğruluğu karşılaştırması.




Şekil 4.7 RMSprop optimizasyonunun kayıp ve doğrulama kaybı karşılaştırması.

100 iterasyonda Adam optimizasyonunun performans ve kayıp grafikleri sırası ile Şekil 4.8 ve Şekil 4.9’da sunulmaktadır,




Şekil 4.8 Adam optimizasyonunun doğruluğu ve doğrulama doğruluğu karşılaştırması.




Şekil 4.9 Adam optimizasyonunun kayıp ve doğrulama kaybı karşılaştırması.

Elde edilen grafiklerde verimi en yüksek olan yöntemin AdaMax optimizasyonu yöntemi olduğu görülmektedir. Karşılaştırma grafikleri Şekil 4.10 ve Şekil 4.11’de sunulmaktadır.



Şekil 4.10 AdaMax, RMSprop ve Adam optimizasyonlarının performans karşılaştırması.




Şekil 4.11 AdaMax, RMSprop ve Adam optimizasyonlarının kayıp karşılaştırması.


Grafiklerden ve performans değerlerinden de görülebileceği üzere ReLu algoritması ile birlikte AdaMax optimizasyon yöntemi kullanılarak RMSprop ve Adam optimizasyon yöntemlerine kıyasla daha verimli sonuçlar elde edilmiştir.

ReLu Algoritması ve AdaMax optimizasyonu ile elde edilen sınıflandırma sonuçları, orijinal görüntü ile eşleştirilerek her sınıf için ayrı renklerle işaretlenmiştir. Görüntü eşleştirme, orijinal görüntü üzerinde şablon ile ortak pikselleri belirleyerek sürekli benzerliğin yakalandığı piksel konumlarının kayıt edilmesi ile başlar. Ardından, sınıflandırılmış görüntüler orijinal görüntü üzerinde kare çerçeveler ile belirtilir. Kare çerçeveler kayıt altına alınan piksel konumları üzerinden hatanın uzunluğu ve yüksekliği ölçülerek kullanılarak çizilir.

AdaMax optimizasyonu ile elde edilmiş performans sonuçlarına göre sınıflandırılan veri seti ile birlikte görüntü eşleştirme çalıştırıldığında ilk kart için eşleşme sonuçları yüksek verim ile elde edilmiştir. Uygulamaya dair örnek Şekil 4.12’de orijinal resim ile birlikte gösterilmektedir.




(a)




(b)

Şekil 4.12 (a) Orijinal görüntü (b) AdaMax optimizasyonu sonucu tespit edilen hatalar ve renksel ifadeleri, kusur kategorilerine göre sınıflandırılan lehim pedi konumları, sırasıyla doğru için mavi, düzeltilemez için kırmızı, eksik lehim için camgöbeği, fazla lehim için yeşil, kısa devre için sarı ve tanımlanmamış nesne için mor.

AdaMax optimizasyonuna en yakın performansa sahip RMSprop optimizasyonu ile elde edilen sınıflandırma sonuçlarının görüntü eşleştirme çalıştırıldığında ilk kart için eşleşme sonuçları AdaMax optimizasyonuna oranla daha düşük olduğu görülmektedir. Şekil 4.13’de orijinal resim ile birlikte görüntü eşleştirme sonucu gösterilmektedir.




(a)




(b)

Şekil 4.13 (a) Orijinal görüntü (b) RMSprop optimizasyonu sonucu tespit edilen hatalar ve renksel ifadeleri, kusur kategorilerine göre sınıflandırılan lehim pedi konumları, sırasıyla doğru için mavi, düzeltilemez için kırmızı, eksik lehim için camgöbeği, fazla lehim için yeşil, kısa devre için sarı ve tanımlanmamış nesne için mor.

AdaMax optimizasyonu ile elde edilmiş performans sonuçlarına göre sınıflandırılan veri seti ile birlikte görüntü eşleştirme çalıştırıldığında ilk kart gibi ikinci kart içinde eşleşme sonuçları yüksek verim ile elde edilmiştir. Uygulamaya dair örnek Şekil 4.14’de orijinal resim ile birlikte gösterilmektedir.




(a)




(b)

Şekil 4.14 (a) Orijinal görüntü (b) AdaMax optimizasyonu sonucu tespit edilen hatalar ve renksel ifadeleri, kusur kategorilerine göre sınıflandırılan lehim pedi konumları, sırasıyla doğru için mavi, düzeltilemez için kırmızı, eksik lehim için camgöbeği, fazla lehim için yeşil, kısa devre için sarı ve tanımlanmamış nesne için mor.

AdaMax optimizasyonuna en yakın performansa sahip RMSprop optimizasyonu ile elde edilen sınıflandırma sonuçlarının görüntü eşleştirme çalıştırıldığında ikinci kart için eşleşme sonuçları AdaMax optimizasyonuna oranla daha düşük olduğu görülmektedir. Şekil 4.15’de orijinal resim ile birlikte görüntü eşleştirme sonucu gösterilmektedir.




(a)




(b)

Şekil 4.15 (a) Orijinal görüntü (b) RMSprop optimizasyonu sonucu tespit edilen hatalar ve renksel ifadeleri, kusur kategorilerine göre sınıflandırılan lehim pedi konumları, sırasıyla doğru için mavi, düzeltilemez için kırmızı, eksik lehim için camgöbeği, fazla lehim için yeşil, kısa devre için sarı ve tanımlanmamış nesne için mor.

AdaMax optimizasyonu ile elde edilmiş performans sonuçlarına göre sınıflandırılan veri seti ile birlikte görüntü eşleştirme çalıştırıldığında üçüncü kart için eşleşme sonuçları yüksek verim ile elde edilmiştir. Uygulamaya dair örnek Şekil 4.16’de orijinal resim ile birlikte gösterilmektedir.




(a)




(b)

Şekil 4.16 (a) Orijinal görüntü (b) AdaMax optimizasyonu sonucu tespit edilen hatalar ve renksel ifadeleri, kusur kategorilerine göre sınıflandırılan lehim pedi konumları, sırasıyla doğru için mavi, düzeltilemez için kırmızı, eksik lehim için camgöbeği, fazla lehim için yeşil, kısa devre için sarı ve tanımlanmamış nesne için mor.

AdaMax optimizasyonuna en yakın performansa sahip RMSprop optimizasyonu ile elde edilen sınıflandırma sonuçlarının görüntü eşleştirme çalıştırıldığında üçüncü kart için eşleşme sonuçları AdaMax optimizasyonuna oranla daha düşük olduğu görülmektedir. Şekil 4.17’de orijinal resim ile birlikte görüntü eşleştirme sonucu gösterilmektedir.




(a)




(b)

Şekil 4.17 (a) Orijinal görüntü (b) RMSprop optimizasyonu sonucu tespit edilen hatalar ve renksel ifadeleri, kusur kategorilerine göre sınıflandırılan lehim pedi konumları, sırasıyla doğru için mavi, düzeltilemez için kırmızı, eksik lehim için camgöbeği, fazla lehim için yeşil, kısa devre için sarı ve tanımlanmamış nesne için mor.

AdaMax optimizasyonu ile elde edilmiş performans sonuçlarına göre sınıflandırılan veri seti ile birlikte görüntü eşleştirme çalıştırıldığında dördüncü kart için eşleşme sonuçları yüksek verim ile elde edilmiştir. Uygulamaya dair örnek Şekil 4.18’de orijinal resim ile birlikte gösterilmektedir.




(a)




(b)

Şekil 4.18 (a) Orijinal görüntü (b) AdaMax optimizasyonu sonucu tespit edilen hatalar ve renksel ifadeleri, kusur kategorilerine göre sınıflandırılan lehim pedi konumları, sırasıyla doğru için mavi, düzeltilemez için kırmızı, eksik lehim için camgöbeği, fazla lehim için yeşil, kısa devre için sarı ve tanımlanmamış nesne için mor.

AdaMax optimizasyonuna en yakın performansa sahip RMSprop optimizasyonu ile elde edilen sınıflandırma sonuçlarının görüntü eşleştirme çalıştırıldığında dördüncü kart için eşleşme sonuçları AdaMax optimizasyonuna oranla daha düşük olduğu görülmektedir. Şekil 4.19'de orijinal resim ile birlikte görüntü eşleştirme sonucu gösterilmektedir.



(a)



(b)

Şekil 4.19 (a) Orijinal görüntü (b) RMSprop optimizasyonu sonucu tespit edilen hatalar ve renksel ifadeleri, kusur kategorilerine göre sınıflandırılan lehim pedi konumları, sırasıyla doğru için mavi, düzeltilemez için kırmızı, eksik lehim için camgöbeği, fazla lehim için yeşil, kısa devre için sarı ve tanımlanmamış nesne için mor.

Şekil 4.12 (b) ile Şekil 4.19 (b) aralığında resimler incelendiğinde görülebileceği üzere AdaMax optimizasyonu ile yapılan çalışma sonucu RMSprop optimizasyonu ile yapılan çalışmaya nazaran hataların tespitinde daha başarılı olmuştur. Hataların daha verimli sınıflandırılması, hataların görsel olarak belirtilmesini kolaylaştırdığı gözlenmiştir.



BÖLÜM 5

SONUÇLAR VE ÖNERİLER

Baskı devre kartlarının dizgi işlemleri sırasında karşılaşılan lehimleme hatalarının fark edilmesi ve bu hataların önlenmesi üretim süreçlerinin verimliliği açısından oldukça önemlidir. Bu çalışmada, BDK'lara uygulanan krem lehimdeki kusurlardan kaynaklanan hatalı üretimi önlemek için derin öğrenmeye dayalı, krem lehim kusurlarını görüntü işleme teknikleri kullanarak sınıflandıran hibrit bir yöntem kullanılmaktadır. Model kart görüntüsü üzerinde bulunan hatalı uygulamaların yerlerini göstermeyi amaçlamaktadır. Amaç yanlış uygulamaların erken safhada fark edilmesi ile verimliliğin artırılmasıdır. Ek olarak, YSA modelinde optimizasyon yöntemlerinin verimlilik üzerindeki etkileri incelenmiş ve karşılaştırılmıştır. Burada önerilen YSA modeli, AlexNet mimarisi üzerinde ReLu aktivasyon fonksiyonu kullanılarak oluşturulmuştur ve karşılaştırmalar sonucunda bu model, oldukça verimli olan AdaMax optimizasyon yöntemi ile desteklenmiştir. Elde edilen verilerle RMSprop ve Adam yöntemlerine göre AdaMax optimizasyon yönteminin %96.40 başarı oranıyla ve 100 iterasyon döngüsünde sonuçlara ulaşmada daha verimli olduğu görülmüştür. Sınıflandırıcılarda verimlilik, doğru tahminlerin oranı ile hesaplandığından, kriter olarak doğruluk ölçüm yöntemi kullanılmaktadır. 648 görsel veri içeren ve bu araştırma için özel olarak hazırlanan veri seti kullanılarak ESA beslenmiştir. ESA veri seti içerisinde bulunan görüntüleri doğru ve yanlış olmak üzere iki başlık altında sınıflandırmaktadır. Hatalı lehim, eksik lehim, fazla lehim, kısa devre, tanımsız nesne olarak sıralanabilen ve doğru uygulama içeren altı sınıf örnek, görüntü işleme teknikleri uygulanarak baskılı devre kartının orijinal görüntüsü ile eşleştirilir. Eşleştirmeler sonucunda sınıf konumları çerçevelenir. Görüntü eşleştirmenin başarımı ESA'nın başarımı ile yükselmektedir. Çalışma içerisinde en verimli olduğu görülen AdaMax optimizasyonu ile elde edilmiş görüntü eşleştirmesi sonuçlarının yanı sıra bu veriler ile kıyaslayabilmemiz adına AdaMax optimizasyonuna en yakın verim değerine sahip RMSprop optimizasyonu ile elde edilen model sonuçları kullanılarak da görüntü eşleştirmesi yapılmıştır. RMSprop optimizasyonunun doğru ve yanlış sınıflandırma veriminin düşük olması sebebiyle

hatalı olarak sunulan şablonların bir kısmının yanlış tespit edildiği gözlemlenmiştir. Bunun sonucunda görüntü eşleştirme sürecinde hataların atlandığı gözlenmiştir. Sonuç olarak önerilen model ile görüntü işleme yöntemlerinin birlikte kullanımının hatalı lehimleme uygulamalarının belirlenmesinde AlexNet mimaris altında ReLu aktivasyon fonksiyonunun AdaMax optimizasyonu ile birlikte kullanılması ile elde edilen modelin başarımının oldukça yüksek olduğu görülmektedir. İleriki çalışmalarda modelin başarımının artırılması için veri setinin genişletilmesi ile modelin başarımının tekrar test edilmesi düşünülmektedir. Elde edilen sonuçlar doğrultusunda YSA'nın melez yapıda çok katlı olarak modellenmesi ve sınıflandırıcı algoritmalarının etkileri de incelenecektir.



KAYNAKLAR

- Albawi S, Mohammed T A and Al-Zawi S** (2018) Understanding of a Convolutional Neural Network. *International Conference on Engineering and Technology*, August 21-23, Antalya, Turkey, *IEEE Conference Publications*, ISBN: 978-1-5386-1949-0, e-book, 1-6.
- Chauhan A P S and Bhardwaj A C** (2011) Detection of Bare PCB Defects by Image Subtraction Method using Machine Vision. *Proceedings of the World Congress on Engineering*, 2: 1597-1601.
- Gedraite E S and Hadad M** (2011) Investigation on the Effect of a Gaussian Blur in Image Filtering and Segmentation. *International Symposium on Electronics in Marine*, September 14-16, Zadar, Croatia, *IEEE Conference Publications*, ISBN: 978-953-7044-12-1, e-book, 393-396.
- Gómez-Ríos A, Tabik S, Luengo J, Shihavuddin A S M, Krawczyk B and Herrera F** (2020) Towards Highly Accurate Coral Texture Images Classification using Deep Convolutional Neural Networks and Data Augmentation. *Expert Systems with Applications*, 118: 315-328.
- Hossin M and Sulaiman M N** (2015) A Review on Evaluation Metrics for Data Classification Evaluations. *International Journal of Data Mining & Knowledge Management Process*, 5(2): 1-11.
- Huang W and Wei P** (2019) A PCB Dataset for Defects Detection and Classification. *Journal of Latex Class Files*, 14(8):1-9.
- Hussain Z, Gimenez F, Yi D. and Rubin D** (2017) Differential Data Augmentation Techniques for Medical Imaging Classification Tasks. *American Medical Informatics Association Symposium Proceedings*, 2017: 979-984.
- Indolia S, Goswami A K, Mishra S P and Asopa P** (2018) Conceptual Understanding of Convolutional Neural Network-A Deep Learning Approach. *Procedia Computer Science*, 132: 679-688.
- Jiang J, Cheng J and Tao D** (2012) Color Biological Features-based Solder Paste Defects Detection and Classification on Printed Circuit Boards. *IEEE Transactions on Components, Packaging and Manufacturing Technology*, 2(9): 1536–1544.
- Kasturkar A and Lokhande S D** (2016) PCB Fault Detection by Image Processing Tools : A Review. *International Journal of Innovative Research in Science, Engineering and Technology*, 5(6): 10634-10639.
- Kingma D P and Ba J L** (2017) Adam: A Method for Stochastic Optimization. *3rd International Conference for Learning Representations Proceedings*, 2017: 1-15.

KAYNAKLAR (devam ediyor)

- Mikołajczyk A and Grochowski M** (2018) Data Augmentation for Improving Deep Learning in Image Classification Problem. *International Interdisciplinary PhD Workshop*, May 9-12, Poland, *IEEE Conference Publications*, ISBN: 978-1-5386-6143-7, e-book, 117-122.
- Mohanty R, Shah V, Haugen P and Holte L** (2008) Solder Paste Inspection Technologies : 2D-3D Correlation. *APEX Conference Proceedings*, 2008:1-8.
- Öztürk S ve Akdemir B** (2017) Detection of PCB Soldering Defects using Template Based Image Processing Method. *International Journal of Intelligent Systems and Applications in Engineering*, 4(5): 269-273.
- Park J Y, Hwang Y, Lee D and Kim J H** (2020) MarsNet: Multi-Label Classification Network for Images of Various Sizes. *IEEE Access*, 8: 21832-21846.
- Pramerdorfer C and Kampel M** (2015) A Dataset for Computer-Vision-based PCB Analysis. *14th IAPR International Conference on Machine Vision Applications*, May 18-22, Tokyo, Japan, *IEEE Conference Publications*, ISBN: 978-4-9011-2214-6, e-book, 378-381.
- Perez L and Wang J** (2017) The Effectiveness of Data Augmentation in Image Classification using Deep Learning. *arXiv preprint arXiv:1712.04621*.
- Wu H, Zhang X, Kuang Y, Ouyang G and Xie H.** (2013) Solder Joint Inspection based on Neural Network Combined with Genetic Algorithm. *Optik*, 124(20): 4110-4116.
- Ye J.** (2019) Two-stage Soldering Defect Detection with Deep Learning. *Degree Project in Information and Communication Tecnology, Second Cycle*, Stockholm.
- Yoo Y H, Kim U H and Kim J H** (2020) Convolutional Recurrent Reconstructive Network for Spatiotemporal Anomaly Detection in Solder Paste Inspection. *IEEE Transactions on Cybernetics*, 2020: 1-13.

ÖZGEÇMİŞ

Ali SEZER, 2018 yılında Zonguldak Bülent Ecevit Üniversitesi Elektrik ve Elektronik Mühendisliği bölümünden mezun oldu. 2018 yılında Zonguldak Bülent Ecevit Üniversitesi Fen Bilimler Enstitüsü Elektrik ve Elektronik Mühendisliği bölümünde tezli yüksek lisans eğitime başladı ve hala eğitime devam etmektedir. 2018-2020 yılları arasında Bozankaya Elektrikli Ticari Araçlar ve Raylı Sistemler Üretim Merkezi'nde Ar-Ge mühendisi olarak çalıştı. 2020 yılından itibaren TÜBİTAK'ta araştırmacı olarak çalışmaktadır. Araştırma ilgi alanları arasında lehim pastası inceleme süreçleri ve uygulamaları, yapay sinir ağı yapıları ve aktivasyon işlevi ve gradyan iniş optimizasyon yöntemleri bulunmaktadır.