



**OTOMATİK OPTİK İNCELEME CİHAZLARININ  
TASARIMI VE BASKI DEVRE KART KUSURLARININ  
SINIFLANDIRILMASI**

**DESIGN OF AUTOMATED OPTICAL INSPECTION DEVICE  
AND CLASSIFICATION OF PRINTED CIRCUIT BOARD  
DEFECTS**

**MUSTAFA ERYILMAZ**

**PROF. DR. ATİLA YILMAZ**

**Danışman**

Hacettepe Üniversitesi

Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin

Elektrik ve Elektronik Mühendisliği Anabilim Dalı için Öngördüğü

YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.

Ocak 2024

## ÖZET

# OTOMATİK OPTİK İNCELEME CİHAZLARININ TASARIMI VE BASKI DEVRE KART KUSURLARININ SINIFLANDIRILMASI

**MUSTAFA ERYILMAZ**

**Yüksek Lisans, Elektrik ve Elektronik Mühendisliği**

**Danışman: Prof. Dr. Atila YILMAZ**

**Şubat 2024, 89 sayfa**

Baskı Devre Kartı (BDK) üretim hatlarında ortaya çıkabilecek kart hatalarının tespiti gün geçtikçe kartın karmaşıklığının artması, kullanılan devre elemanı sayısı artışı ve boyutunun küçülmesi veya değişmesi sebebiyle zorlaşmakta ve istenen hızda olamamaktadır. Bu noktada hata tespitinin hızlı ve güvenilir olması, sinyal işleme yöntemlerinin doğru kullanılması ile başarılı bir tespit oranı yakalanması bu tür cihaz ve yazılımlarından beklenen isterlerdir. Bu tezde öncelikle sahada kullanılabilir, taşınabilir ve sabit Otomatik Optik İnceleme (OOİ) cihazları kadar güvenilir ve doğruluk oranı yüksek bir cihaz geliştirilmesi planlanmıştır. Ticari ve bilimsel anlamda bu tür taşınabilir bir cihaz kaynaklarda ve markette bulunmamaktadır. Bununla birlikte yapay zeka tabanlı sistemlerde bu başarı veritabanının genişliğine ve niteliğine bağlıdır. Tez çalışması kapsamında görüntü setleri toplanmış ve dört BDK hatası (eksik lehim, kaymış devre elemanı, kısa devre ve kalkmış devre elemanı) için veri bankası kurulmuştur. Nitelikli ve yeni hataları içeren veri elde etmek her zaman sağlanabilecek bir özellik olmaktan uzaktır. Bu nedenle başlangıç başarı oranı düşük olsa bile veri toplam süreç içinde başarı oranını yükselten, eksik veya yanlış tespitlerde bilgisini güncelleyip öğrenmeye devam eden bir sistem tasarlanmıştır. Çevrimde kullanıcı olarak tanımlanan sistemde kullanıcı bilgisi sisteme geri dönüt olarak dahil edilmiş ve öğrenme

süreci hata tespit başarı oranını yükseltebilmek için sürekli eğitim altyapısı tasarlanmıştır. Bu tezde ayrıca görüntülerin çözümü ve takibi için arayüz tasarlanmış, derin öğrenme tabanlı algoritmalar ile model eğitim ve hata tespit altyapısı geliştirilmiştir. Sistemin bildiği bilgiler ve kullanıcı dönütü ile kazandığı bilgiler birlikte bir döngü içinde birleştirilerek hata tespitlerinin başarıları artırılmıştır. Modeller için bileşik ve ayrık ağlarda eğitim çevrimi kullanılmış ve aralarında sürekli bir karşılaştırma ile anlık olarak en başarılı ağ hata tespiti amaçlı tercih edilmiştir. Örnek bir çevrim ile bileşik model kısa devre hatasında ayrık modele göre daha üstün başarı gösterip yüzde 97.64 başarı oranı yakalamıştır. Eksik lehim hatasında da ayrık modele daha yüzde 77.77 ile başarılı bir sonuç gösterip karar biriminde tercih edilmiştir. Tasarlanan sistemde eğitilmiş ağ öğrendiği hatalarda daha başarılı ve zamanla öğrendiği yeni hatalarda kullanıcı isterlerini de kullanarak yeni hatalara uyum sağlamak ve hızlı hata tespiti sağlayan YOLO algoritması ile üretim hattında önemli olan hız unsurunu da korumaktadır.

**Keywords:** BDK analizi, OOI, Sinir Ağları, Derin Öğrenme



## **ABSTRACT**

### **DESIGN OF AUTOMATED OPTICAL INSPECTION DEVICE AND CLASSIFICATION OF PRINTED CIRCUIT BOARD DEFECTS**

**MUSTAFA ERYILMAZ**

**Yüksek Lisans, Elektrik ve Elektronik Mühendisliği Ana Bilim Dalı**

**Supervisor: Prof. Dr. Atila YILMAZ**

**Ocak 2024, 89 pages**

Detection of card errors that may occur in Printed Circuit Board (PCB) production lines becomes more difficult day by day due to the increasing complexity of the board, the increase in the number of circuit elements used and the decrease or change in size, and it cannot occur at the desired speed. At this point, fast and reliable error detection and a successful detection rate with the correct use of signal processing methods are the requirements expected from such devices and software. In this thesis, it is primarily planned to develop a device that can be used in the field and is as reliable and accurate as portable and fixed Automatic Optical Inspection (AOI) devices. In commercial and scientific terms, such a portable device is not available in the sources and in the market. However, in artificial intelligence-based systems, this success depends on the breadth and quality of the database. Within the scope of the thesis study, image sets were collected and a data bank was established for four PCB errors (missing solder, slipped circuit element, short circuit and lifted circuit element). Obtaining qualified data containing new errors is far from always achievable. For this reason, even if the initial success rate is low, a system has been designed that increases the success rate in the total data process and continues to update and learn its information in case of missing or incorrect detections. In the system defined as a user in the loop, user information is included in the

system as feedback and a continuous training infrastructure is designed to increase the error detection success rate of the learning process. In this thesis, an interface for analyzing and tracking images was also designed, and a model training and error detection infrastructure was developed with deep learning-based algorithms. The success of error detection is increased by combining the information known by the system and the information gained through user feedback in a loop. Training cycles were used in compound and discrete networks for the models, and with a constant comparison between them, the most successful network was instantly selected for error detection. With an example cycle, the composite model showed superior success compared to the discrete model in short circuit error and achieved a success rate of 97.64 percent. In case of missing solder error, the discrete model showed a more successful result with 77.77 percent and was preferred in the decision-making unit. In the designed system, the trained network is more successful in the errors it has learned and adapts to new errors by using the user requests in the new errors it has learned over time and maintains the speed element that is important in the production line with the YOLO algorithm that provides fast error detection.

**Keywords:** PCB analysis, AOI, Neural Networks, Deep Learning

## TEŞEKKÜRLER

Bu çalışma ve yüksek lisansım boyunca değerli bilgi ve tecrübelerinden yararlandığım ve bana akademik hayat içinde ve dışında her anlamda koçluk yapan, emeğini esirgemeyen danışman hocam Prof. Dr. Atila Yılmaz'a tüm içtenliğimle teşekkür ederim.

Lisans hayatımdan itibaren bana daima her konuda rehberlik yapan, destek olan ve bu desteğini her zaman hissettiren Doç. Dr. Dinçer Gökçen'e teşekkürü bir borç bilirim.

Tüm proje boyunca göstermiş olduğu destek ve ilgiden dolayı Doç. Dr. Seniha Esen Yüksel Erdem'e çok teşekkür ederim.

Jüri üyelerim olan Prof. Dr. Ziya Telatar ve Dr. Öğr. Üyesi Yakup Özkazanç'a tez değerlendirme sürecime katıldıkları için teşekkür ederim.

Çalıştığımız projedeki yardımlarından ötürü Hakan Tırak, Mehmet Tileği, Metehan Çil, Sedat Aktürk ve Göksel Sözeri çalışma arkadaşlarıma şükranlarımı sunarım.

Proje süreci boyunca sağlamış oldukları teknik ve altyapı desteklerinden ötürü ASELSAN'a teşekkürlerimi sunarım.

Beni bugünlere getiren aileme bıkmadan, usanmadan her zaman yanımda oldukları, beni destekledikleri, sevdikleri için teşekkürler...

# CONTENTS

	<u>Sayfa</u>
ÖZET .....	i
ABSTRACT .....	iii
TEŞEKKÜRLER .....	v
İÇİNDEKİLER .....	vi
ÇİZELGELER .....	viii
ŞEKİLLER .....	ix
KISALTMALAR .....	xi
1. GİRİŞ .....	1
1.1. Tez Kapsamı .....	1
1.2. Otomatik Optik İnceleme Cihazı .....	2
1.3. Organizasyon .....	6
2. ELEKTRONİK MEKANİK TASARIM .....	7
2.1. Mekaniksel Çalışmalar .....	8
2.1.1. Ana iskelet .....	9
2.1.2. Kamera Hareketi .....	10
2.1.3. LED Kart Devresi .....	11
2.1.4. Cihaz Hareketi .....	14
2.1.5. Diğer Tasarım Birimleri .....	15
2.2. Donanımsal Çalışmalar .....	17
2.2.1. Mikrodenetleyici ve Denetim Ünitesi .....	17
2.2.2. Güç Birimi .....	18
2.2.3. Step Motorlar .....	18
2.2.4. Motor Sürücü Devreleri .....	19
2.2.5. Duyarga ve Eyleyiciler .....	19
2.2.6. Kamera ve Elektronik Elemanlar .....	19
2.3. Görüntü Alma Teknikleri .....	22
3. SİSTEM YAZILIM TASARIMI .....	24

3.1. Arayüz Tasarımı .....	24
3.1.1. Ana Ekran .....	24
3.1.2. Görüntü Alma Ekranları .....	25
3.1.3. Sonuçlar Ekranı .....	28
3.1.4. Veri Tabanı Ekranı .....	30
3.1.5. Detaylı Bakış Ekranı .....	31
3.1.6. Veri Etiketleme Ekranı .....	32
3.1.7. LED Düzenleme Ekranı .....	34
3.1.8. Ayarlar Ekranı .....	35
3.2. Yazılım Tasarımı .....	37
3.2.1. Cihaz Denetim ve Haberleşme .....	37
3.2.2. Kamera Yazılımı .....	38
3.2.3. Veri Depolama ve Analizi .....	39
3.2.4. Görüntü Etiketleme .....	41
4. ÖNERİLEN YÖNTEM ALTYAPISI VE TASARIMI .....	43
4.1. Derin Öğrenme .....	43
4.1.1. Derin Öğrenme Yapısı .....	43
4.1.2. Sadece Bir Kere Bak (You Only Look Once (YOLO)) Algoritması .....	45
4.1.3. Hata Tespit Algoritması .....	48
4.1.4. Model Eğitimi .....	48
4.2. Öğrenen Sistem Tasarımı .....	49
4.2.1. Ayrık ve Bileşik Modeller ile Hata Tespit İyileştirmesi .....	49
4.2.2. Model Eğitimi .....	51
4.2.3. Öğrenen Yapı ile Hata Tespit İyileştirmesi .....	56
5. DENEYSEL SONUÇLAR .....	64
5.1. Hata Tespiti Başarı Oranları - TEST 1 .....	64
5.2. Ayrık ve Bileşik Model Karşılaştırması - TEST 1 .....	65
5.3. Eğitim İşlemi .....	68
6. SONUÇ .....	71
7. TEŞEKKÜR .....	73

## ÇİZELGELER

	<u>Sayfa</u>
Table 2.1 Üzerinde Çalışılan Kamera Model ve Özellikleri .....	21
Table 5.1 TEST 1 - Eşik Değeri 0.1 için Başarı Oranları .....	65
Table 5.2 TEST 1 - Eşik Değeri 0.4 için Başarı Oranları .....	65

## ŞEKİLLER

	<u>Sayfa</u>
Şekil 2.1 Cihaz ve bilgisayar görüntüsü .....	8
Şekil 2.2 Cihaz içi ve BDK .....	8
Şekil 2.3 Ana iskelet teknik ve 3D çizimi .....	10
Şekil 2.4 LED kartı Şeması .....	11
Şekil 2.5 LED kartı BDK tasarımı .....	11
Şekil 2.6 LED kartı pertinaks üzerinde tasarım .....	12
Şekil 2.7 LED kartı gömülü yazılım akış diyagramı .....	13
Şekil 2.8 Doğrusal step motor.....	14
Şekil 2.9 Doğrusal step motor görüntü alımı .....	15
Şekil 2.10 Donanım blok diyagramı .....	17
Şekil 2.11 Kamera görüş alanı.....	20
Şekil 2.12 Tercih edilmiş kamera: UC130MPA .....	22
Şekil 2.13 Görüntü tarama teknikleri, a. Sabit tarama, b. Konum bazlı tarama....	23
Şekil 3.1 Ana menü ekranı .....	24
Şekil 3.2 Görüntü alma - Test ekranı .....	26
Şekil 3.3 Görüntü alma - Konum ekranı .....	27
Şekil 3.4 Görüntü alma - Görüntü Alma ekranı .....	28
Şekil 3.5 Sonuç ekranı.....	29
Şekil 3.6 Veri tabanı ekranı.....	30
Şekil 3.7 Detaylı bakış ekranı .....	32
Şekil 3.8 Görüntü etiketleme ekranı 1 .....	33
Şekil 3.9 Görüntü etiketleme ekranı 2 .....	33
Şekil 3.10 LED düzenleme ekranı.....	35
Şekil 3.11 Ayarlar ekranı - Hareket Ayarları.....	36
Şekil 3.12 Ayarlar ekranı - Hareket Ayarları.....	36
Şekil 3.13 Ayarlar ekran - Kayıt.....	37

Şekil 3.14	Dosya düzeni - Kart bilgisi .....	40
Şekil 3.15	Dosya düzeni - Kart yüzü .....	40
Şekil 3.16	Dosya düzeni - LED renkleri .....	40
Şekil 3.17	Dosya düzeni - Görüntüler .....	40
Şekil 3.18	Örnek görüntü etiketleme 1 .....	42
Şekil 3.19	Örnek görüntü etiketleme 2 .....	42
Şekil 4.1	Sinir ağları [1] .....	44
Şekil 4.2	Birçok evrimsel katmanlı bir ağ örneği [2] .....	45
Şekil 4.3	YOLO sistem mimarisi [3] .....	47
Şekil 4.4	YOLO tespit şeması [4] .....	47
Şekil 4.5	TXT dosyası .....	48
Şekil 4.6	Bileşik ve ayırık ağ yapısında eğitim ve karma sistem .....	50
Şekil 4.7	Önceden toplanmış veri seti .....	53
Şekil 4.8	Öğrenen yapı içinde çevrimde kullanıcının rolü .....	59
Şekil 4.9	Çevrimde kullanıcı gösterimi .....	60
Şekil 4.10	Öğrenen yapı ile hata tespitinde iyileşme .....	60
Şekil 4.11	Yönetim yazılım döngüsü .....	62
Şekil 4.12	Yazılımda önemli görevlerin ardışıl blokları .....	63
Şekil 5.1	TEST 2 - Kalkmış devre elemanı hatası karşılaştırması .....	67
Şekil 5.2	TEST 2 - Eksik lehim hatası karşılaştırması .....	67
Şekil 5.3	TEST 2 - Kısa devre hatası karşılaştırması .....	68
Şekil 5.4	TEST 2 - Kaymış devre elemanı hatası karşılaştırması .....	68
Şekil 5.5	Eğitim işlemleri ekranı .....	69
Şekil 5.6	Eğitim işlemleri - 1 .....	70
Şekil 5.7	Eğitim işlemleri - 2 .....	70
Şekil 5.8	Eğitim işlemleri - 3 .....	71



## KISALTMALAR

<b>BDK</b>	:	<b>Baskı Devre Kartı</b>
<b>CAD</b>	:	<b>Computer Aided Design</b>
<b>CNN</b>	:	<b>Convolutional Neural Networks</b>
<b>FOV</b>	:	<b>Field Of View</b>
<b>GPU</b>	:	<b>Graphics Processing Unit</b>
<b>OOİ</b>	:	<b>Otomatik Optik İnceleme</b>
<b>LED</b>	:	<b>Light Emitting Diode</b>
<b>RGB</b>	:	<b>Red Green Blue</b>
<b>UART</b>	:	<b>Universal Asynchronous Receiver Transmitter</b>
<b>VAC</b>	:	<b>Volts Alternating Current</b>
<b>YOLO</b>	:	<b>You Only Look Once</b>

# 1. GİRİŞ

Günümüzde, tasarımı yapılan devrelerinin karmaşık yapıları değerlendirildiğinde üretimde çok sayıda devre elemanının kullanılması kaçınılmazdır. Ancak devre elemanlarının sayısının artması, üretimi yapılacak kartlardan devre elemanlarının boyutlarına kadar birçok alt bileşenin küçülmesini zorunlu hale getirmiştir. Özellikle üretimi yapılan sistemlerin sayısının artmasıyla, üretim aşamasında kart inceleme güvenilirliği ve kart inceleme hızının önemi giderek artmıştır. Otomatik Optik İnceleme (OOİ) cihazı değişik boyut ve kılıflardaki elektronik devre elemanlarının Baskı Devre Kartı (BDK) üzerine montajlarını ve montaj öncesinde BDK durumunu hızlı ve doğru bir şekilde incelenmesini sağlar. Üretim maliyetlerinin yanı sıra inceleme maliyetlerinin yükünü azaltmak için OOİ kritik bir cihazdır. Her bir aşamaya entegre edilen OOİ cihazıyla kontrol, üretim sürecinde erken sorunları yakalamak için kullanılabilir. Arızalar, buldukları üretim süreci boyunca daha fazla devre elemanı montajı gerçekleşmeden ya da başka üretim aşamaları uygulamadan tespit edilebilir. Bu tezden beklendiği ifade edilen sistemin düşük maliyetli görüntü işleme tabanlı bir hata bulma sistemi tasarımının yani sıra sahada kullanılacak taşınabilir bir çözümü de içermesi öngörülmüştür.

## 1.1. Tez Kapsamı

Tez kapsamında BDK'larını detaylı ve yüksek çözünürlükte görüntü alabilen taşınabilir bir OOİ cihazı tasarlanmış ve bu görüntüler üzerinde hataların tespiti için öğrenen bir yapı kurulmuştur. Hata tespiti için kullanılan modeller bileşik (tüm hata sınıfları birlikte) ve ayrık (her hata sınıfı ayrı) olarak eğitilmiş ve her bir sınıf başarı oranları karşılaştırılıp seçili sınıf için başarı oranı yüksek olan tercih edilmiştir.

Tez çalışması kapsamında görüntü setleri toplanmış ve dört BDK hatası (eksik lehim, kaymış devre elemanı, kısa devre ve kalkmış devre elemanı) için veri bankası kurulmuştur. Görüntülerin taranması, etiketlenmesi, incelenmesi ve üzerinde hata tespiti yapılabilmesi için arayüz geliştirilmiştir. Hata tespitinde kullanılan modellerin eğitim süreçleri geliştirme

aşamasının dışında da sürekli kılınmış, kullanıcı geri dönütleri de modellerin eğitimi için kullanılmıştır. Eğitim sürecine en az seviyede kullanıcı dahil edilip, araka planda devam eden otonom bir eğitim süreci oluşturulmuştur. Eğitim sürecinin yönetimi kararları öğrenen yapı algoritması ile alınmaktadır.

Sistem geliştirilme aşamasında sahip olduğu bilgilere bağımlı kalmayıp, görüntü tarama işlemleri devam ettikçe var olan ve yeni karşılaşılan hatalar için hata tespit başarı oranını artırmaktadır.

## **1.2. Otomatik Optik İnceleme Cihazı**

Otomatik Optik İnceleme (OOİ) cihazı elektronik BDK'ların üretim aşamalarında ve müşteriye teslim etmeden önce sıklıkla kullanılan teçhizattır. OOİ, değişik boyut ve kılıflardaki elektronik devre elemanlarının BDK üzerine montajlarını ve montaj öncesinde BDK durumunu hızlı ve doğru bir şekilde incelenmesini sağlar. Örneğin; elektronik devre elemanı montajının ilk aşamasında, BDK kartı üretimden geldikten sonra montaja uyumlu olup olmadığının bilgisi için OOİ cihazı kullanılmaktadır. Montaja uyumlu olan kartların belirlenmesinin ardından lehim işlemi yapılır ve lehim işleminin istenilen özelliklerde gerçekleşip gerçekleşmediğinin tespiti yine OOİ cihazıyla yapılmaktadır. Bu şekilde her bir aşamaya entegre edilen OOİ cihazıyla kontrol, üretim sürecinde erken sorunları yakalamak için kullanılabilir. Arızalar, buldukları üretim süreci boyunca daha fazla devre elemanı montajı gerçekleşmeden ya da başka üretim aşamaları uygulamadan tespit edilebilmektedir. Bu süreç, üretim hattından çıkan ürünün yüksek kalitede olmasını ve ürünlerin tasarım kriterlerini sağlamasını ve imalat hatalarından mümkün olduğunca arındırılmış bir şekilde çıkmasını desteklemektedir. Ürüne özgü sorunların yanı sıra lehim ve montaj alanındaki süreç problemleri belirlenebilir ve hızlı bir şekilde çözüm üretilebilir.

OOİ dışında

- Devre üzerinde test (Ing. In-circuit test),
- Otomatik X-Işını Muayene (Ing. Automated X-Ray Inspection),

- Termal görüntüleme analizi,
- Lazer ile boyutsal ölçümlerin karşılaştırılması,
- Farklı aydınlatma teknikleri altında analiz (Floresan ve Akkor Aydınlatma, Kızılötesi (IR) ve Ultra-violet (UV) Aydınlatma),

aşamaları üretim bantlarında kullanılmaktadır.

Market and Markets tarafından yayınlanan rapora göre OOİ cihazlarının pazarının 2024 yılında 774 milyon dolara ulaşması beklenmektedir [5]. Sektörün önde gelen firmaları Nordson Corporation, AOI Systems, Saki Corporation, CyberOptics Corporation, ViscomAG, Machine Vision Products, Omron Corporation, Kurtz Ersä ve Koh Young Technology olarak sıralanmaktadır. Türkiye’de OOİ üretimi gerçekleştiren bir firma bulunmamaktadır, ancak bazı firmaların bu konuda çalışma planı yaptıkları bilgisi alınmıştır. Bu konuda Aselsan ile birlikte bir cihaz tasarımı projesi tamamlanmıştır.

Kaynaklarda değerlendirilen yöntemler arasında görüntü çıkarma (image subtraction) algoritması yaygın olarak kullanılmıştır. Görüntü çıkarma yönteminin ilk örneklerinden olan bir çalışmada, araştırmacılar, yüksüz kartlarda (bare PCB) iletken hatların denetlenmesi amacıyla bir sistem tasarlamışlardır [6]. Bu çalışmada tasarlanan sistemin uzun süren işlem süresi (40x50 mm boyutlarında bir kart için 18 dakika) ve donanımsal gereksinimleri dikkate değer olumsuz tarafları olarak sıralanabilir. Bir diğer olumsuz husus ise, yapılan çalışmanın yüksüz BDK’larda gerçekleştirilmesi ve devre bileşenleri ile lehimlemeye dair hataları kapsamamasıdır.

Görüntü çıkarma yöntemini kullanarak yüksüz kartlarda beş farklı hatanın başarılı bir şekilde tespit edildiği görülmüştür [7]. Bu çalışmada, araştırma kapsamında üretilen sınırlı sayıda referans ve test kartları kullanılmış olup, herhangi bir sinyal ön işleme tekniği uygulanmamıştır. Nihai olarak, elde edilen siyah/beyaz örtüştürülmesi sonucu elde edilen veriden, birtakım kuralların gözetildiği bir algoritma yardımıyla kart türleri tespit edilmiştir. Benzer şekilde NI Vision Assistant yazılımı kullanılarak yapılan bir diğer çalışmada ise görüntü çıkarma yöntemine ek olarak kullanılan görüntü işleme platformundan elde edilen

özniteliklerden yararlanılmıştır. Bunun sonucunda alan, oryantasyon ve X-Y koordinatları gibi veriler kullanılarak basit bir algoritma tasarlanmıştır [8].

Görüntü çıkarma yöntemi ile morfolojik bölütleme yöntemini kullanan araştırmacılar, 14 farklı hata tipini 11 farklı grupta sınıflandırma yaptıklarını raporlamışlardır [9]. PCB kartlarını hatalı ve hatasız olarak iki sınıfa ayıran robotik görsel denetleme sistemi tasarımına yönelik bir çalışmada, araştırmacılar öncelikle elde edilen gri tonlu görüntünün kontrastını artırmak ve arka plandan ayırtmak amacıyla çeşitli ön işleme yöntemleri uygulamışlardır. Daha sonraki adımda, tasarlanan görüntü bölütleme yöntemiyle PCB kart görüntüsü arka plan görüntüsünden ayrıştırılmıştır. Sınıflandırma adımında ise referans kart görüntüsü ile örtüştürülerek hatalı ve hatasız olarak sınıflandırma yapılmıştır [10]. Farklı bir bölütleme yöntemi kullanan bir çalışmada ise referans görüntü ile test görüntüsü alt bloklara ayrıldıktan sonra özgün lineer bir dönüşüm uygulanarak görüntülerde gürültü ve aydınlatma kusurlarının etkisinin azaltılması hedeflenmiştir. Daha sonraki adımlarda her bir blok için benzerlik testleri uygulanarak hataların yerleri blok bazında tespit edilmiştir [11]. Görüntü çıkarma yöntemlerinin çeşitli varyantlarının bir arada kullanıldığı bir çalışmada farklı hata tiplerine yönelik farklı algoritmalar tasarlanmıştır. Sonuç olarak, görüntü çıkarma yöntemlerinin kullanıldığı çalışmalarda farklı hata türlerine yönelik farklı teknikler geliştirildiği raporlanmıştır [12].

Görüntü çıkarma işleminin sonucunda elde edilen veriden birtakım öznitelikler elde edilerek makine öğrenmesi yöntemlerinden k-NN sınıflandırıcısı ile sınıflandırma çalışması yapılan bir çalışmada ise araştırmacılar 14 farklı hata türünü sınıflandırdıklarını raporlamışlardır [13]. Gözetimsiz öğrenme yöntemiyle referans kartta bulunan iletken yollar ve iletken kontakların grafik modeli oluşturulan bir çalışmada ise BDK'ların farklı aydınlatma koşullarında testleri yapılmıştır.

Önerilen algoritmanın değişik aydınlatma ortamlarında başarılı sonuçlar verdiği raporlanmıştır [14, 15]. Bir diğer referans temelli çalışmada ise görüntü çıkarma yöntemi uygulandıktan sonra elde edilen veriden üç farklı indis üretilip, 3x3 boyutunda bir filtre ile

piksel bazında eleme yapılmıştır [16]. Bu sayede gürültü ve aydınlatmadan kaynaklanan sorunların önlenmesi hedeflenmiştir.

Makine öğrenmesi algoritmalarının lehim bileşenlerini sınıflandırma amacıyla kullanıldığı karma bir optik denetleme sisteminin önerildiği bir çalışmada ise ayırık kosinüs dönüşümü, ayırık dalgacık dönüşümü ve log Gabor filtre öznelik üretmek için kullanılmıştır. Bu çalışmada, elde edilen üç farklı öznelik kümesinin ayrı ayrı sınıflandırma başarımı gözlemlenmiştir. Daha sonra, üç farklı yöntem ile elde edilen özneliklerin bir arada kullanılması önerilerek sınıflandırma başarımında iyileşme sağlandığı gözlemlenmiştir. Araştırmacılar son aşamada elde edilen bileşik öznelik kümesini lineer lojistik regresyon analizi ile sınıflandırıcıyı eğitmek amacıyla kullanarak lehim hatalarının tespit edilmesinde iyileşme sağlamışlardır [17].

Referans bilgisi olmadan lehim bileşenlerinin istatistiksel özneliklerinden yararlanılarak lehim köprüsü (solder bridge) hatalarının tespit edildiği bir çalışmada araştırmacılar özgün bir algoritma tasarlamışlardır. Bu çalışmada gri seviye görüntülerden elde edilen ışık yoğunluğunun histogram istatistikleri kullanılarak lehim köprüsü problemleri kural tabanlı bir algoritma ile tespit edilmiştir [18].

Genetik algoritma kullanılarak yapılan bir çalışmada araştırmacılar, özel bir aydınlatma yöntemine gerek duymaksızın PCB kartlar üzerinde eksik bileşen tespit etmeye yönelik bir çalışma raporlamışlardır [19]. Bu çalışmada, görüntü çıkarma yöntemi kullanılarak genetik algoritmanın eğitiminde kullanılmıştır. Daha sonraki çalışmalarında aynı araştırma ekibi, farklı aydınlatma koşullarında ve farklı çözünürlüklerde çalışmalarını tekrarlamışlardır [20].

Lehim bileşenlerinin RGB renk dağılımı, alan ve konum gibi belirleyici özneliklerin kullanıldığı bir çalışmada ise sınıflandırma ağacı tekniği kullanılmıştır [21]. Bu çalışmada sekiz farklı lehim hata tipine yönelik geliştirilen algoritma daha sonra çeşitli optimizasyon yöntemleri ile iyileştirmeye tabi tutularak sonuçların iyileştirilmesi hedeflenmiştir. İstatistiksel örüntü tanıma yaklaşımlarında, Barlett ve arkadaşları [22] her lehim beş farklı özneliğe: temel gri düzeyi istatistikleri, 3 boyutlu gri düzey atalet (inertia) öznelikleri, yönlü gri düzeyi yüzey alan öznelikleri, ayırt edici geometri gri düzeyi

yüzey eğim öznitelikleri ve ikili görüntü bağı alan özniteliklerine bağlı olan iki iyi ve yedi hatalı tiplerden birisine sınıflandırmak Bayesian ve maksimum olabilirlik sınıflandırıcıları kullanmışlardır. Wu ve Zhang ise lehimin şeklini ve optik yansıma özelliklerini göz önüne alarak bir lehim kalitesini renk, alan, kütle merkezi ve sürekli pikseller öznitelikleri ile lehim görüntülerinin renk dağılımına bağlı olarak değerlendirmişlerdir [23].

### 1.3. Organizasyon

Üretim hattında BDK üzerinde karşılaşılan hataların tespitinde yapay zekâ tabanlı öğrenen algoritmalar ile her türlü farklı kart üzerinde inceleme yapabilen, sorunlu kartları görüntü işleme süreci ile değerlendirip, hatayı öğrenerek genelleme yapabilen, başarımlar açısından kaynaklarda verilen yöntemlere göre daha başarılı bir sistem hedeflenmektedir.

Yüzey montaj teknolojisindeki (İng. Surface Mount Technology - SMT) gelişmelerle çok küçük boyutlarda devre elemanlarının kullanılmaya başlanması ve BDK küçük boyutlara sıkıştırılmış ve çok katlı üretim aşamalarının kullanılması ürün denetiminin insan gözüyle yapılmasını zorlaştırmış hatta imkânsız hale getirmiştir. Özellikle üretimi yapılan sistemlerinin sayısının artmasıyla, inceleme hızının önemi giderek artmıştır. OOİ cihazı ile bu üretim hatlarında BDK incelemesinden ve hatalı BDK geç tespitinden dolayı ortaya çıkan zaman kayıplarını azaltmak ve insan gözü ile tespiti zor olan hataları da tespit ederek üretim hattında hız ve güvenilirliği arttırmak hedeflenmektedir.

Tezin organizasyonu şu şekildedir:

- Bölüm 1 hedefimizi, katkılarımızı ve tezin kapsamını sunar.
- Bölüm 2 projede geliştirilen elektronik ve mekanik tasarımı sunar.
- Bölüm 3 projede geliştirilen yazılım tasarımını sunar.
- Bölüm 4 uygulanan öğrenen yapı sistem tasarımını sunar.
- Bölüm 5 gerçekleştirilmiş test sonuçlarını gösterir.
- Bölüm 6 tezin özetini ve gelecekteki olası yönleri belirtir.

## 2. ELEKTRONİK MEKANİK TASARIM

Tez çalışmalarında kaliteli ve isterleri karşılayan görüntüler alınabilmesi için OOİ cihazı tasarlanmış ve üretilmiştir. Bu cihaz ile görüntü alımı esnasında farklı teknikler test edilebilmiş ve optimum görüntü alma tekniğinin belirlenebilmesi için farklı görüntü alma protokolleri oluşturulmuştur. Bu protokoller sayesinde de karşılaştırma yapmak kolaylaştırılmıştır.

Bu protokoller

- ışık şiddeti ve rengi,
- alan tarama örüntüsü,
- kamera uzaklığı (yüksekliği),
- kamera çözünürlüğü,
- kamera hareket adımı

olmaktadır.


Bu OOİ cihazına ait mekanik, donanım ve yazılım çalışmaları ayrıntılı olarak anlatılacaktır. OOİ cihazının mekanik, donanımsal ve yazılımsal tasarımlarında da tez kapsamında belirlenmiş isterler baz alınmış ve bu isterlerin üzerine proje geliştirmesi için gerekli eklemeler yapılmıştır.

Şekil 2.1’de cihazın dış kaplaması yapılmış halde ve denetim için kullanılan bilgisayarı ile kullanımına hazır halde görülmektedir. Şekil 2.2’ de ise cihazın iç görüntüsü ve tarama için yerleştirilmiş BDK görülmektedir.





Şekil 2.1 Cihaz ve bilgisayar görüntüsü



Şekil 2.2 Cihaz içi ve BDK

## 2.1. Mekaniksel Çalışmalar

Tez isterlerinde mekanik tasarımın maksimum boyutları belirlenmiştir. Bu boyutlar aynı zamanda büyük bagaj boyutları olmaktadır. Bu boyutların seçilmesinde ana sebep cihazın portatif olarak kullanılabilmesidir. Aynı zamanda bir diğer ister olan cihazın içine yerleştirilecek maksimum ve minimum BDK boyutları da yine tez isterleri kapsamında belirlenmiştir. Cihazın mekanik tasarımında bu isterler baz alınmış olsa da ana iskeletin boyutları istendiği takdirde büyütülebilir veya belli bir limit dahilinde de daha küçük boyutlarda tasarlanabilmektedir.

Cihazın sahip olması gereken bu iki boyut isteri şu şekildedir:

- Cihazın için yerleşmesi gereken maksimum BDK boyutları: 360mm x 260mm x 70mm


- Cihazın sahip olabileceği maksimum boyut ölçüleri: 582mm x 467mm x 380mm

Cihaz için tasarım sürecinde mümkün olan maksimum boyutlar tercih edilmiştir. Bunun sebepleri ise şöyle özetlenebilir. Cihazın üretim amacı prototip ve Ar-Ge olması sebebiyle cihazda bulunan her elemanın kolay değiştirilebilir olması gerekmektedir. Her eleman mümkün olabildiğince birbirinden bağımsız modüler yapıya sahip olmalıdır. Bu da her elemanın ayrı olarak montajlanabilir olmasını gerektireceğinden ihtiyaç duyacağı hacimsel alan artmaktadır. Bu sebeple de cihazın iç hacmi ne kadar geniş olursa her bir eleman için yerleşim kolaylığı artacaktır.

### **2.1.1. Ana iskelet**

Sistemin mekanik yapıtaşı olan ana iskelet için kalınlığı 20 mm olan alüminyum sigma yapılar kullanılmaktadır. Sigmalarının kalınlığını belirleyen ana unsurlar dayanması gereken yük ve dış ortamdan gelecek olası hasarlara karşı direnç olarak sıralanabilir. Uygulama alanı alüminyum sigmaların darbelere ve yüksek ağırlığa dayanıma sahip oldukları deneysel çalışmalar ve piyasa araştırmaları sonucunda tespit edilmiştir. Bu malzemenin sağlam yapısı, korozyon dayanımı ve hafifliğinin yanı sıra CNC, torna ve hareketli makine parçaları başta olmak üzere birçok üründe kendini kanıtlaması temel tercih sebepleri arasında gösterilebilir. Ayrıca, proje kapsamında hedeflenen kolay üretim anlayışı doğrultusunda tedariki oldukça kolay bir malzemedir. Mekanik yapı ve malzeme bileşenlerinin oldukça basit sistemlerden oluşması, üretim sırasında ve bakım-onarım çalışmalarında kolaylık sağlayabilecektir. Alüminyum sigmaların montajı Hacettepe Üniversitesi laboratuvarlarında gerçekleştirilmiştir. Alüminyum yerine kullanılacak diğer malzemeler değerlendirildiğinde karbon fiber ve çelik üzerinde durulmuştur. Ancak karbon fiber çok hafif olduğundan, sistemin durağan olamama olasılığı ön plana çıkmıştır. Bununla beraber çelik kullanıldığında malzemenin ağırlığı ve dolayısıyla durağanlığının artacak olmasına rağmen, cihazın portatif olma özelliği olmayacaktır. Çünkü cihazın ağırlığı, portatif olarak kullanımını zorlaştıracaktır. Ayrıca çelik kullanıldığı takdirde malzemenin

işlenme zorluğunun artması ve dolayısıyla üretim ve bakım masraflarının artması söz konusu olacaktır. Şekil 2.3'te cihazın ana iskelet yapısı ve çizimi görülmektedir.



Şekil 2.3 Ana iskelet teknik ve 3D çizimi

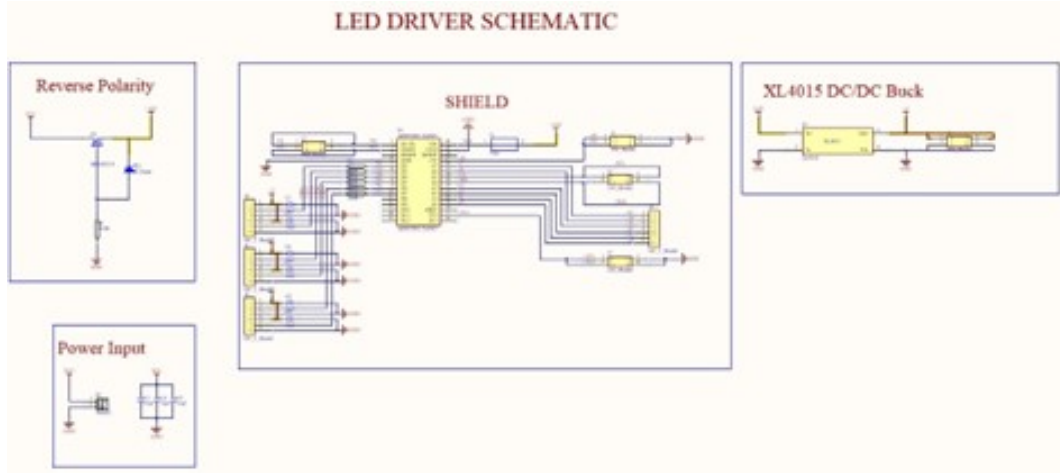
### 2.1.2. Kamera Hareketi

Cihaz tasarımında görüntüleme için kullanılacak kameranın XYZ eksenlerinde hareket edebilmesi gerekmektedir. Bu hareketin sağlanabilmesi için 3D yazıcılarına benzer bir tasarımdan esinlenilmiştir. XYZ eksenlerinde hareketin sağlanması için step motorlar ve doğrusal step motor kullanılmıştır. XY eksenleri hareketi birlikte çalışan iki step motor ile, Z eksenine ise bir doğrusal motor ile sağlanmaktadır. Ana motor konfigürasyonu step motorlar üzerindedir. Bunun sebebi step motorların adım sayısı üzerine hassas bir hareket seçeneği sunmasıdır. Cihazda kullanılan step motorlar tam bir 360 derecelik turu 400 adımda almaktadır. Yani hareketlerinde 0.9 derecelik bir hassaslığa sahiptir.


Yapılan teknik çalışmalar sonrasında maksimum boyutlardaki kartın görüntülenmesi için gerekli olan zaman tespit edilmiştir. Kamera seyahat süresinin belirlenmesinde kart boyutlarının yanı sıra kameranın görüntüleme hızı (İng. Frame Per Second - FPS), kullanılacak step motorların adım aralıkları ve sistemin mekanik salınımları değerlendirmeye alınmıştır. Bu değerlendirmeler kamera yazılım geliştirmesi başlığı altında bahsedilecektir.

### 2.1.3. LED Kart Devresi


Işıklandırma devresinin tasarımı Şekil 2.4 ve 2.5 olarak verilmektedir. Tasarımda, ters bağlanma durumuna önlem olarak bir koruma devresi çizilmiş ve kullanılan köle mikro denetleyici için ayrıca 250 mA sigorta bağlantısı yapılmıştır. Ters bağlama koruması için P-kanal MOSFET, 12 V Zener diyot, 100 kOhm direnç kullanılmıştır. Şematik tasarım yapıldıktan sonra baskı devre aşamasına geçmeden THT elemanlar ile delikli pertinaks üzerine prototip üretilmiş ve gerekli akım değerleri için testleri yapılmıştır (Şekil 2.6).



Şekil 2.4 LED kartı Şeması



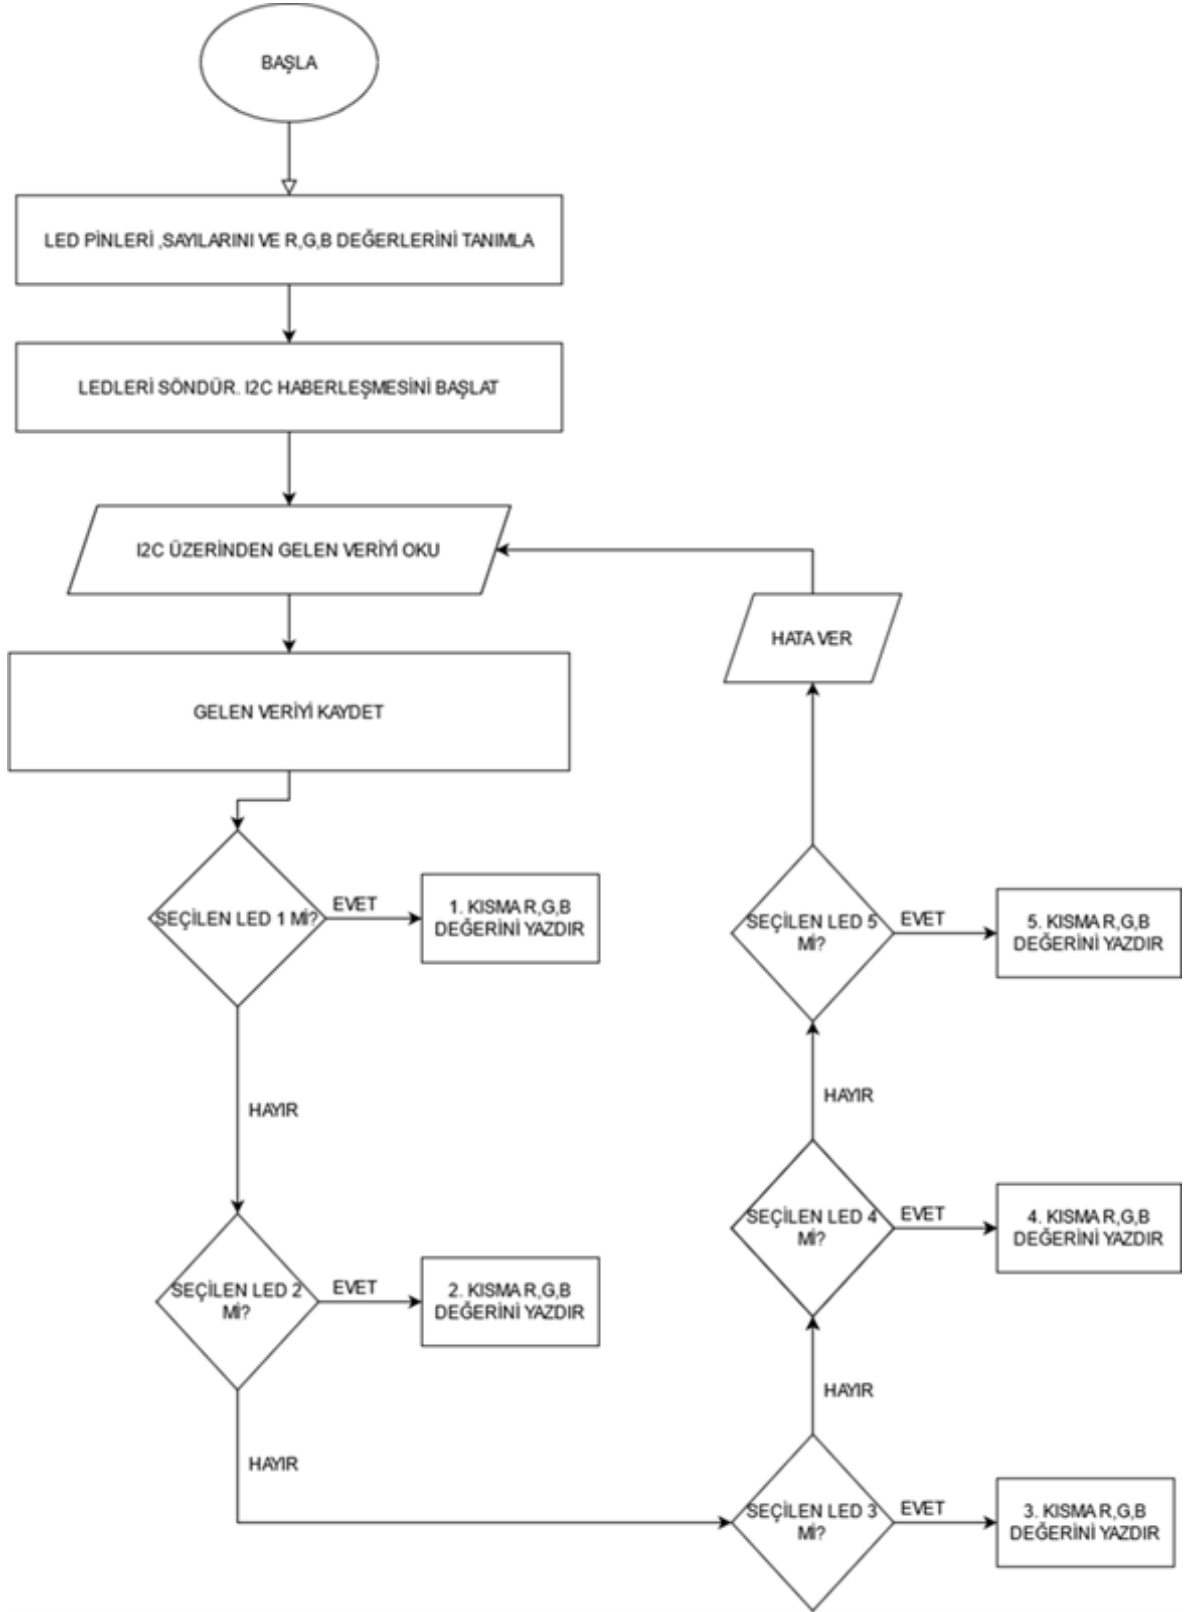
Şekil 2.5 LED kartı BDK tasarımı



Şekil 2.6 LED kartı pertinaks üzerinde tasarım

Ters bağlama korumasından sonra ışıklandırma sistemini sürebilmek için kullanılan SMPS üzerinden gelen 12 V gerilimi DC/DC Buck converter kullanarak 5 V değerine potansiyometre yardımıyla indirgenmiştir. Kullanılan Buck converter modülü 8 - 36 V arasında değer alabilirken çıkışında 1.25 V ile 32 V arasında gerilim verebilmektedir. XL4015 modülünün içinde kısa devre koruması olduğundan, tasarımda ayrıca bir kısa devre korumasına ihtiyaç görülmemiştir. Kullanılan WS2812b modelinde bir pin veri için kullanılmaktadır ve kullanılan veri pini 200 Ohm direnç ile mikro denetleyicinin pinlerine bağlanmıştır. Bu bağlantının sebebi veri pinlerinde oluşan yanlış bilgi aktarımının önüne geçmektir.

Şekil 2.7'de LED kartı devresinin kontrol algoritması görülmektedir. Algoritmada ilk adım olarak LED pinleri ve RGB değerleri tanımlanır. İlk olarak LED kapalı hale getirilir ve I2C ile ana kontrol kartı ile haberleşme için beklemede kalır. Ana kontrol kartından gelen her bir komut ayrı bir LED için sırayla gelmektedir. Gelen her bir komut ile seçili LED için RGB ayarlanır ve aktif edilir. Bir hata durumunda, veri kaybı veya kaymasında komutlar iptal edilir ve hata durumuan geçilir. Tüm komutların baştan gönderilmesi beklenir.




Şekil 2.7 LED kartı gömülü yazılım akış diyagramı



#### 2.1.4. Cihaz Hareketi


Altı eksende hareket etme kabiliyetine sahip cihazın doğrusal tahrik sistemi için XY eksenini için triger kayışları (Ing. timing belt) ve step motorlar, Z ekseninde doğrusal step motor (Şekil 2.8) kullanılmaktadır. Tüm sistemde kullanılan step motor 42.3 x 42.3 x 48mm (NEMA 17) boyutlarında, 0.9° step açısı, 1.7A çalışma akımı, 4.8 kg-cm tutunma torkuna sahiptir.



Şekil 2.8 Doğrusal step motor

Cihazda Z ekseninde hareketli kısım kamera olmaktadır. BDK'nın yerleştirildiği kısım sabit kalmaktadır. Tasarımın bu şekilde olmasının iki ana sebebi vardır. Birinci sebep, cihaz görüntü alırken kendi içinde yaptığı veya dışarıdan gelen bir etkiden dolayı titreşimler oluşabilmektedir. Bu da görüntünün kalitesini düşürebilir. Bu görece daha ağır olan BDK yerleştirme kısmının sabit kalması ve görece daha hafif kamera kısmının hareket etmesi titreşimin görüntüye olan etkisini azaltacaktır. Bu çıkarımın asıl dayanağı ise 3D yazıcılarda farklı mekanik tasarımların sunduğu getiri ve götürülerin incelenmesi sonucunda tespit edilmiştir. 3D yazıcılarda baskının olduğu tabla kısmının sabit olması

baskı kalitesini Z ekseninde daha hassas olmasını sağlamaktadır. Bu getiri tabii farklı mekanik geliřtirmeler ile farklı sonuçlar da ortaya çıkarabilir ama esinlenilmiř olan 3D yazıcı modelinin mekanik tasarımının getiri ve götürüleri incelenmiř ve bu tasarımda sabit olmasının sağladıđı getiri bu řekilde belirlenmiřtir. İkinci sebep ise, görece daha ağır olan BDK yerleřtirme kısmını hareket ettirmek ve durdurmak görece daha hafif olan kamera kısmına göre daha fazla tork istemektedir. Daha ağır bir parça için hareketler daha keskin ve sert olacaktır ve step motorlar için gerekli akım deđeri artacak dolayısıyla da motorların ısınması da artacaktır. Isınan motorlar cihazın tasarımında kullanılan PLA+ malzemesinin sünmesine neden olmaktadır. Bu sorun ileriki bařlıklarda detaylandırılacaktır. řekil 2.9’da dođrusal step motor ile görüntü alımı görölmektedir.



řekil 2.9 Dođrusal step motor görüntü alımı

### 2.1.5. Diđer Tasarım Birimleri

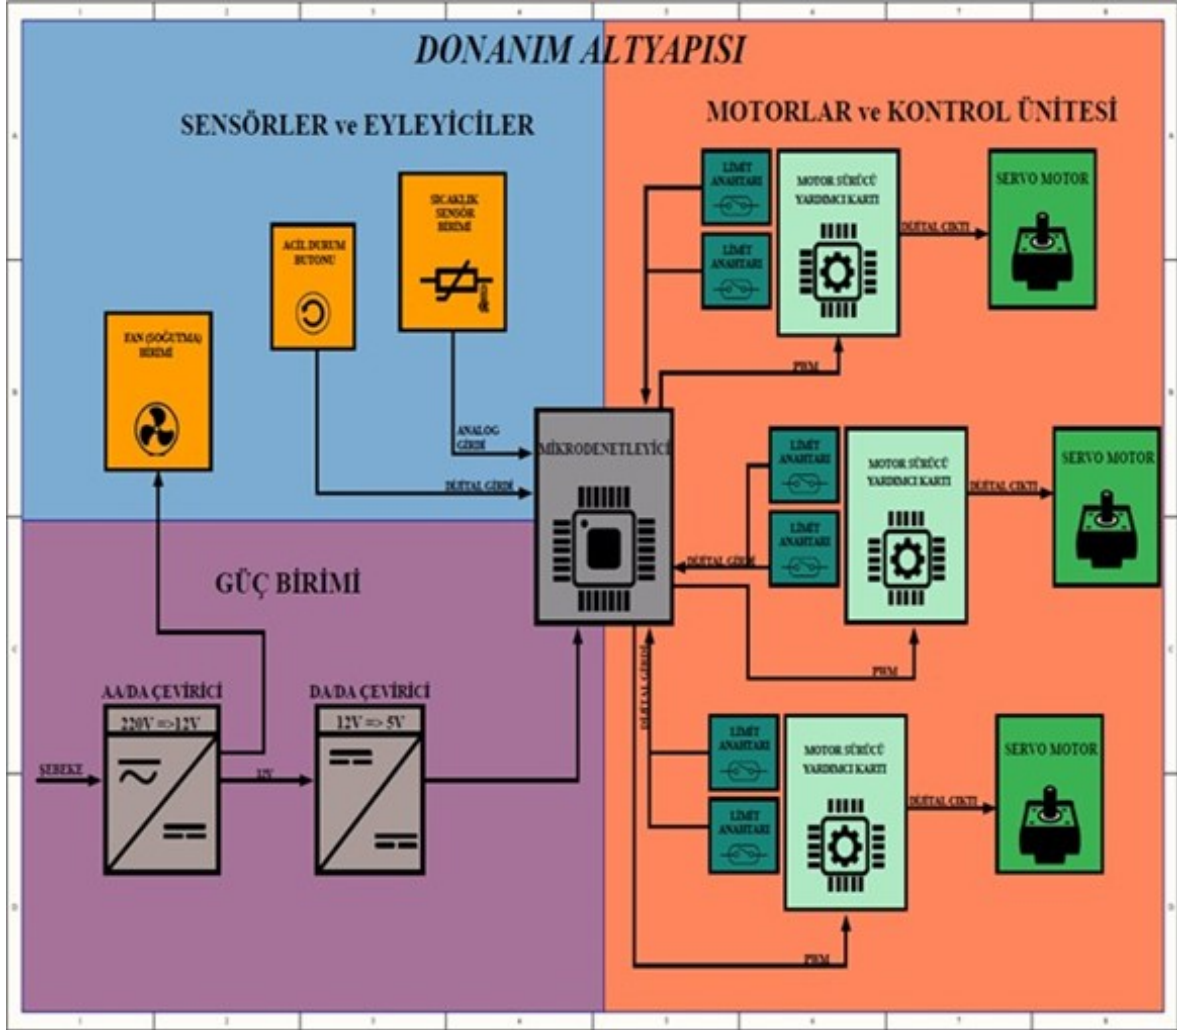
Cihazın ana iskelet ve motor tercihlerinin yapılmasının ardından montaj için gerekli parçaların üretimi için teknik seçilmesi gerekmiřtir. Kullanılan iki teknik arasında



karşılaştırma yapılmıştır. Bunlar, ısıya daha dayanıklı ve sert olan alüminyum üretim ile daha ucuz ve esnek bir tasarım olasılığı sunan 3D baskı teknikleridir. Alüminyum üretim tekniğinde üretilen parçalar ısıya karşı daha dayanıklıdır yani daha 3D baskı tekniğine göre yüksek ısılarda da şekil bütünlüğünü korumaktadır. Aynı zamanda bükülme, esneme ve kırılmaya karşı da daha dayanıklıdır. Üretilen parçaların çözünürlüğü de 3D baskı tekniğine göre daha yüksektir. Ama üretim maliyeti yüksektir ve laboratuvarında bir CNC makinası bulunmadığından anlık üretim yapma şansı yoktur. Üretim için tasarımlar hazırlanmalı ve sipariş verilmelidir. Bu da uzun zaman alan bir süreçtir. 3D baskı tekniğinde ise 3D yazıcı makinası CNC makinasına göre daha ucuz bir teknolojidir. Üretim maliyeti çok daha düşük olduğundan her parça için daha fazla test, geliştirme ve yeniden üretme imkânı sunmaktadır. Laboratuvar ortamında da 3D yazıcı bulunduğu için anlık olarak tasarımlar üretime verilebilmektedir. Bu da üretim ve test aşamasını hızlandırmıştır. 3D baskı tekniğinde kullanılan malzeme PLA+ olmaktadır. Bu malzeme baskı esnasında 205-220 dereceye kadar ısıtılır ve baskı yapılır. Malzeme temelinde polimer plastiktir. Dayanıklılık olarak üretim aşamasında kullanılan malzeme miktarına ve tasarıma göre değişkenlik gösterebilmektedir. Baskıda üretilen parçanın iç hacminin doluluk oranı, baskının yönü ve konumu dayanımını etkilemektedir. Gerekli dayanıklılık da bu parametreler ile sağlanabilmektedir. Herhangi bir parça için yapılacak güncelleme ve geliştirme de daha düşük maliyette ve kısa bir sürede olabilmektedir. Ama PLA+ özellikle ısıya karşı 120-150 derece üstünde dayanıklılığını büyük ölçüde kaybetmeye ve şekil bütünlüğünü koruyamamaya başlamaktadır. Genelde 100 derece ve üstünde özellikle sünme ve esneme oluşmaktadır. Cihazda step motorlar uzun süreli kullanımlarda veya yüksek tork gerektiren hareketlerde ısınmaktadır. Bu da motorların montajı için PLA+ ile üretilen parçalar için sorun oluşturabilmektedir. Bu durumda motorların ısınmasını engellemek için de motorlara mini fanlar takılabilmektedir. Çalışma süresine bağlı olarak ısınma artmaktadır. Fanlar ise uzun kullanım süreleri oluşturduğunu sisteme entegre edilmesi planlanmıştır.

## 2.2. Donanımsal Çalışmalar

Cihazın donanımsal yapısı dört ana bileşenden oluşmaktadır. Denetim ünitesi, duyargalar, motorlar ve güç ünitesi. Bu birimler ayrıntılı olarak anlatılacaktır. Şekil 2.10'da donanım blok diyagramı gösterilmiştir.



Şekil 2.10 Donanım blok diyagramı

### 2.2.1. Mikrodenetleyici ve Denetim Ünitesi

Mikrodenetleyicinin temel görevi bütün ana bileşenlerin birbirleriyle senkronize çalışmasını sağlamak olup, sistemin ana denetim algoritmasının yönetimi de mikrodenetleyici üzerinden

sağlanacaktır. Cihazda ATMEL, PIC, TI (MSP) vb. düşük maliyetli ve kendini farklı sistemlerde kanıtlamış bir çipin kullanımı önem arz etmektedir. Öncül tasarımda ATMEL firmasının Atmega 2560 ürünün kullanımına yer verilmiştir. Mikrodenetleyicilerde ve sistemde yer alan diğer devre elemanlarında kullanımı önem arz eden sıcaklık sensörlerinin donanımın belirli bölgelerinde kullanımı planlanmıştır. Cihazın bilgisayar ile bağlantısı denetim ünitesi üzerinden USB 2.0 ve USB 3.0 aracılığıyla gerçekleşmektedir.

### **2.2.2. Güç Birimi**

Cihazın 220 VAC şebekeden besleneceği düşünülerek tasarım yapılmıştır. Ana güç kaynağı 12 VDC gerilim ve 30 A akımda çalışmaya uygun olacaktır. 220 VAC'den 12 VDC elde etmek için AA/DA Çevirici kullanılmıştır. Ayrıca sistem farklı modüller için gerekli olacak 5 VDC için DA/DA Çevirici kullanılmıştır. Güç kaynaklarında motorlara ve diğer devrelere kurulan hatlarda ısıya dayanımı yüksek ve esnek kablolar kullanılmıştır. Güç kaynağında bir adet cam sigorta kullanılmış olup, yüksek akımlarda sistemin arızaya neden olmadan kendini güvene alması hedeflenmiştir. Güç kaynağında kendi içindeki ısı duyargasından alınan ölçümlere göre aktif olan bir fan yardımıyla çalışma sırasında soğutulabilecektir.

### **2.2.3. Step Motorlar**

Cihazın 6 eksenli hareketi için dört adet step motor kullanılmıştır. Nema17 olarak sınıflandırılan ve 1.7 A çalışma akımı bulunan bipolar step motorlar tercih edilmiştir. Sistemin hareket kabiliyetinin ana elemanı olan motorlarda bipolar tutunma torku 48 N.cm ve tetik torku 2.2 N.cm'dir. 0.9 derece adım açısında 400 adım/devir yapma kabiliyetine sahip Nema17 step motorların maliyet, ağırlık (280g) ve çalışma dayanımları değerlendirildiğinde sistem isterlerini sağlayacağı anlaşılmıştır.

#### **2.2.4. Motor Sürücü Devreleri**

Her bir motorun sürülmesi için ayrı bir sürücü entegresi veya devresinin kullanılması gerekmektedir. Sıcaklık kaynaklı bir sorun olmadığı için ve çoklu sürücüye sahip kart tasarımı portatif olduğundan ayrı sürücü devreleri tercih edilmiştir. Sürücülerin yüksek akımda çalıştıkları düşünüldüğünde entegre edilmesi gereken soğutucu sistemlere de tasarımda yer verilmiştir. Soğutucu ünitesi fan ve soğutucu yüzeyden oluşmaktadır. Sürücü devreleri denetim birimine zırh (shield) olarak takılmaktadır ve denetim ünitesinde ortak soğutma sistemi olmaktadır.

#### **2.2.5. Duyarga ve Eyleyiciler**


Cihazda sıcaklık duyargaları, hareket bitiş durakları, soğutucu fanlar ve acil durum butonu gerekli yerlerde kullanılmaktadır. Sistem motordan kaynaklı anlık bir arıza durumunda oluşabilecek yüksek akım bütün elektronik donanıma hasar verebileceğinden akım koruma önlemi ana güç kaynağının çıkışına eklenmiştir. Soğutucu fanlar denetim ünitesinde motor sürücüler için kullanılmıştır ve tercihe bağlı olarak kamera ısınma sorunu yaşamaması durumunda soğutulması için kameraya da eklenebilmektedir. Bu durum kamera başlığında ayrıntılı anlatılacaktır.

#### **2.2.6. Kamera ve Elektronik Elemanlar**

Kamera seçiminde dikkat edilmesi gereken temel özellikler çözünürlük, minimum odak mesafesi, otomatik odaklama ve görüş açısı FOV (Field Of View) olmak üzere dört başlıkta incelenmiştir. Çözünürlük kameranın üzerinde bulunan görüntüleme duyargalarının üzerindeki renk algılayıcıların miktarıdır. Aynı görüş açısına sahip, farklı çözünürlüklere sahip iki kamera ile görüntüleme yapıldığında, çözünürlüğü yüksek olan kameradan elde edilen görüntü daha ayrıntılı ve nettir. Çözünürlük arttıkça görüntüdeki ayrıntılar belirginleşir. Buna karşı olarak, ayrıntı miktarı artan görüntünün sayısal ortamda kapladığı alan da artar. Çözünürlük arttıkça, ihtiyaç duyulan sayısal depolama alanı ve görüntü

üzerinde işlem yapabilmek için gerekli olan işlem gücü artar. Minimum odak mesafesi, kamera ile görüntülenecek cisim arasında olabilecek minimum mesafedir. Kamera minimum odak mesafesinden daha yakın olan cisimleri net bir şekilde görüntüleyemez. Taşınabilir bir görüntüleme sisteminde minimum odak mesafesinin olabildiğince küçük seçilmesi gerekmektedir. Çünkü odak mesafesinin artması cihaz için Z ekseninde yüksekliğin yani boyutun artması anlamına gelmektedir.

Kamera görüntüsünde balık gözü (fisheye) lenslerde sık rastlanan fiçı yaklaşımı bozulması veya varil distorsiyonu olarak adlandırılan bu bozulma şekline bulunmaktadır. Bu sebeple görüntüde merkezden kenarlara gidildikçe bozulmalar oluşmaktadır. Bu bozulmalar yaklaştırma efekti uygulanmışçasına nesnelere merkeze doğru yaklaştıkça büyürken kenarlara doğru küçülürler.



Şekil 2.11 Kamera görüş alanı

Kameranın odak mesafesinde bulunan bir cismin görüntüsü net ve ayrıntılı olarak alınabilir. Cisim odak mesafesinden uzaklaştıkça, cismin görüntüdeki netliği azalır. Otomatik odaklama yeteneğine sahip olan kameralar, odak mesafesini dinamik olarak değiştirerek, görüntülemenin net bir şekilde yapılmasını sağlarlar.


Görüş açısı kameranın merceğinden itibaren taradığı alanın kaç derecelik açı ile ilerlediğini ifade eder. Kısaca FOV olarak nitelendirilen görüş açısı arttıkça kamera daha geniş bir alanı görüntüleyebilirken, görüntülenen alanda bulunan cisimlerin detay miktarı azalır.

FOV azaldıkça görüntü üzerindeki cisimlerin detay miktarı artar. FOV değeri düştükçe görüntülenen alan da azalacağı için alanın tamamını daha fazla görüntü ile ifade etmek gerekir.

Bu özellikler dikkate alınarak, dört adet kamera seçilmiştir. Bu kameraların karşılaştırması Tablo 2.1’de gösterilmektedir. Seçilen kameralar arasında yer alan AF205 ve AM73915MZTL model numaralı kameralar, dijital mikroskop kamerası olarak üretici tarafından önerilmektedir. Mikroskop kameralarının görüş açıları 10-20 derece gibi değerlere kadar düşürülerek detaylı görüntüler elde edilebilmektedir. Öte yandan kameralar oldukça dar bir alanı görüntülemektedirler. Birbirlerine muadil sayılabilecek SEE3CAM130 ve UC130MPA kameraları ile yaklaşık 6x4.5 cm’lik bir alanı 13 MP çözünürlükle görüntülenebilmektedir. SEE3CAM130 ve UC130MPA üstte belirtilen kriterler ve tez gereksinimleri göz önünde bulundurularak incelenmiş ve tezde kullanılmaya uygun görülmüştür. Daha dar bir görüş açısına sahip olan UC130MPA öncelikli tercih olarak belirlenmiştir. Cihaz üzerinde kullanılan UC130MPA kamera modeli (Şekil 2.12) ile yaklaşık 6x4.5 cm’lik bir alan 13 MP çözünürlükle görüntülenebilmektedir.

Table 2.1 Üzerinde Çalışılan Kamera Model ve Özellikleri

<b>MODEL</b>	<b>ÇÖZÜNÜRLÜK</b>	<b>GÖRÜŞ AÇISI</b>	<b>MİNİMUM ODAK MESAFESİ</b>	<b>OTOMATİK ODAKLAMA</b>
SEE3CAM130	4208x3120	74	100	VAR
AF205	1920x1080, 5MP	Değişken	50	VAR
AM73915MZTL	2560x1920	Değişken	30	VAR
UC130MPA	4196x3104	60	50	VAR



Şekil 2.12 Tercih edilmiş kamera: UC130MPA

Seçilmiş olan kamera uzun süreli kullanımlarda ısınma sorunu göstermektedir. Ulaştığı ısı seviyeleri kamera kartının optimum sınırlarının üzerine çıkmakta ve görüntüde hatalara veya görüntü kaybına sebep olmaktadır. Bu durum kameradan uzun kullanım sürelerinde ve yüksek çözünürlükte görüntü alınırken gerçekleşmektedir. Hatanın sebebi OOİ cihazı kaynaklı değildir çünkü kamera gücü ve iletişimi bilgisayar üzerinden sağlamaktadır. Bu durumda da kamerada üretim hatası olabilme veya sınırlarının üzerinde bir kullanım durumunda kaldığı düşünülmüştür. Bu durumun ortaya çıkması sebebiyle de kameraya gerekli olduğunda soğutucu bir sistem takılma tercihi de opsiyonel olarak tasarıma eklenmiştir.

### 2.3. Görüntü Alma Teknikleri

Arayüz üzerinden kamera istenilen koordinata götürülebilmektedir ve kamera üzerinden anlık görüntü alınabilmektedir. Sabit tarama ve konum bazlı tarama olmak üzere iki yaklaşım bulunmaktadır. Görüntü alınırken kullanılabilen bu iki yöntem Şekil 2.13.a ve Şekil 2.13.b'de verilmektedir.





## 3. SİSTEM YAZILIM TASARIMI

Bu bölümde OOİ cihazına ait kullanıcının rahatlıkla operasyonları takip edebileceği ve görüntüleri inceleyebileceği, kullanıcı dostu arayüz ve alt yazılımlar ayrıntılı olarak anlatılmıştır.

### 3.1. Arayüz Tasarımı

#### 3.1.1. Ana Ekran

Arayüz programı ilk açıldığında Şekil 3.1’de verilen ana menü penceresi gelmektedir.



Şekil 3.1 Ana menü ekranı

Bu ekrandan kart tarama yapabilmek için “Görüntü Al” ekranına, LED renkleri ve düzenlemeleri ayarlamak için “LED Düzenlemeleri” ekranına, bazı sistem testlerini elle denetlemek için “Sistem Testleri” ekranına, sisteme ait tüm ayarlara ulaşmak için “Ayarlar” ekranına, eğitim işlerini kontrol etmek ve düzenlemek için “Eğitim İşlemleri” ekranına ve kayıtlı tüm verileri görmek için “Veri Tabanı” ekranına geçilebilir. Bu ekranda sistemin

içinde bulunduğu sürecin anlık bilgilerini alabileceğimiz uyarı ve ikaz durumları için bildiriler de gösterilmektedir.

### **3.1.2. Görüntü Alma Ekranları**

Görüntü alma ekranında kart taraması için gerekli ayarlar yapılmaktadır. Bu aşamada gerekli ayarlar yapıldıktan sonra tarama başlatılabilir. Bu ayarlar Şekil 3.2’de gösterildiği gibi tarama alanı, LED renk ve parlaklık, kamera yüksekliği, adım sayısı, karta dair özel bilgiler ve bazı hareket ayarları olmaktadır. Bu bilgiler kullanıcı tarafından girilmek zorundadır ve her farklı kart için ayrı girilmelidir. Görüntü alma ekranları “Test”, “Konum” ve “Görüntü Al” olmak üzere üçe ayrılır.

Görüntüleme cihazı içine yerleştirilen kartın taranması için konum bulmaya yardımcı olması amacıyla canlı görüntü ve yön tuşları ile kameranın XYZ ekseninde hareketi sağlanmıştır. Şekil 3.2’de görüldüğü gibi tarama yapılması istenen alanın başlangıç ve bitiş noktalarını belirleme işlemi daha hızlı ve kolay olabilmektedir. Ayrıca tarama işlemi boyunca canlı görüntü gösterilmekte, herhangi bir aksilik veya hata durumu anlık olarak görülebilmektedir. Kart tarama sonrası, eğer var ise, kartın arka yüzünün görüntüsü de tek buton ile gerçekleştirilebilmektedir. Her işlem için de işlemin tamamlanması için ilerleme süreci yüzde hesabı olarak kullanıcıya gösterilmektedir. Bu sayede işlemin süreci tahmin edilebilir olmaktadır.

Kart taramalarında görseller kameranın adım hareketleri sonucunda alınır. Bu hareketlerin mm cinsinden değeri tarama öncesinde seçilebilmektedir. Belirlenen her adımda bir görüntü alınır. Sonuçta adım sayısına ve tarama alanına göre farklı sayılarda parça görüntüleri elde edilecektir. Bu görüntüler veri tabanına konum bilgisi ile kaydolur. Bu sayede hem parça görüntü hem de konum kaydedilmiş olur. Bu görüntüler aynı görüntü açısını paylaşıyor olmak zorunda değildir. Bu adım sayısında ne girildiğine bağlıdır. Bu sebeple kamera yüksekliğine yani Z ekseninin yüksekliğine göre adım sayısının değeri değişebilir. Bu sebeple tercihen tavsiye edilmiş adım sayısına bağlı varsayılan olarak kayıtlı

Z eksenini yükseklik deęerleri kullanılır veya kullanıcı tarafından belirlenmiř yeni deęerler kullanılabilir.

řekil 3.2 Görüntü alma - Test ekranı

řekil 3.2’de verilen “Test” ekranında kullanıcı tarafından istenen alanın koordinatlarını belirler. Bunu yaparken ekranın saę tarafında canlı kamera görüntüsü bulunmaktadır. Bu koordinatların görüntü ile eşleřtirilmesi kolaylıęı sağlamaktadır. Koordinatları ayarlarken yön tuřları ile konumlar denenebilir ve anlık koordinat da sürekli olarak otomatik olarak güncellenir. İstenen konum belirlendięinde “maksimum ve minimum koordinatlar” girilir ve kaydedilir. Eęer deęiřiklik yapılması istenirse yeni deęerler yazılıp “Anlık Koordinatları Kaydet” butonuna basılmalıdır. Gerekli bilgiler girildięinde “İleri” butonu ile “Konum” ekranına devam edilebilir.

Görüntü Alma

—————  —————

Minimum Koordinatlar		Maksimum Koordinatlar		Yükseklik ve Step	
X	<input type="text"/>	X	<input type="text"/>	Z	<input type="text" value="0"/>
Y	<input type="text"/>	Y	<input type="text"/>	Step	<input type="text"/>

Hareket Ayarları

Focus Time  Wait

LED Seçenekleri

Kayıtlı RGB Renk Kodları		Tarama için Kullanılacak Renkler	
White	255,255,255	RGB Renk İsmi	RGB Kodu
h1	93,122,174	1 h1	93,122,174
yu	192,221,255		
lila	206,40,245		
kırmızı	206,40,40		

Kart Bilgisi

Card ID

Seri No

UDK

PN

Şekil 3.3 Görüntü alma - Konum ekranı

“Konum” ekranında tarama alanının konumları belirlenmiş olur ve değiştirilmek istenirse “Test” butonuna basılarak bir önceki ekrana geçiş yapılabilir. “Konum” ekranında kamera yüksekliği yani “Z” değeri ve “Step” yani adım sayısı girilir. Bu değerler tarama için gereklidir. “Focus Time”, “Timeout” ve “Wait” isteğe bağlı olarak seçilebilir ve girilmesi zorunlu değildir. İstendiğinde tamamen kaldırılabilir özelliklerdir. Şekil 3.3’te verilen “LED Seçenekleri” altında taramada kullanılacak LED rengi seçilir. Burada bilgiler renk kodu ve renk koduna ait rengin görselleştirilmiş halidir. İstenilen ölçekte renk seçilebilir veya eklenen renkler çıkarılabilir. “Kart Bilgisi” altındaki kısımda karta dair özel bilgiler yer almaktadır. Doldurulması zorunlu olmamaktadır ancak doldurulmazsa “none-boş” olarak veri tabanına kaydedilecektir. Tüm bu bilgiler girildikten sonra “İleri” butonu ile taramanın başlayacağı “Görüntü Al” ekranına geçilir (Şekil 3.4).



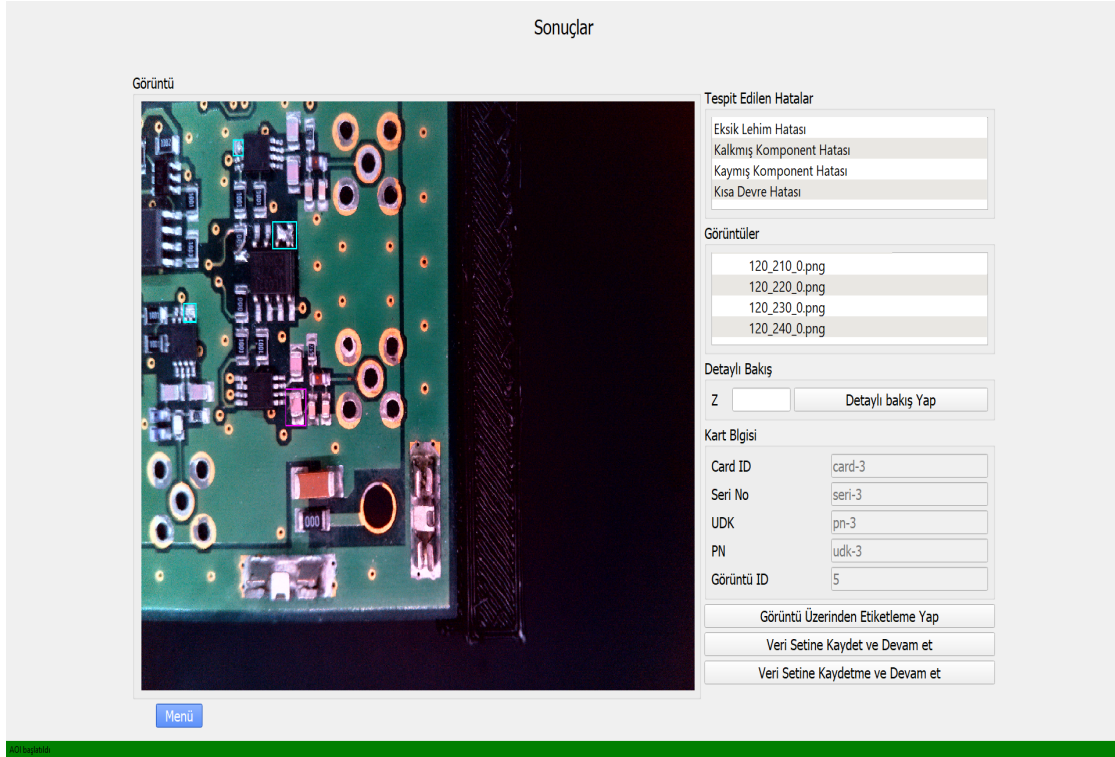
Şekil 3.4 Görüntü alma - Görüntü Alma ekranı

“Görüntü Al” ekranında canlı kamera görüntüsü ve taramanın ilerleyişini gösteren işlem çubuğu bulunmaktadır. İşlem çubuğu yüzde yüze ulaştığında tarama bitmiş olur. Sonrasında istenirse aynı kartın arka yüzü taramak istenirse hiçbir ek ayarlama yapmaya gerek olmadan önceki ayarların aynısı ile tarama yapılabilir. Bunun için de “Arka Yüz için Başlat” butonuna basılması yeterlidir. Tüm tarama işlemi bittiğinde paralelinde hata tespit algoritması da çalışmış olup hataların konumları belirlenmiş olur. Bu çıkan sonuçları görmek için “Sonuçlar” butonuna veya işlemi direk olarak bitirip ana menüye dönmek veya yeni bir tarama başlatmak için “Bitir” butonuna basılabilir.

### 3.1.3. Sonuçlar Ekranı

Sonuçlar penceresinde tarama yapılmış görüntüler listelenir. İstenildiğinde çift tıklanarak herhangi bir görüntü açılabilir. Sonrasında görüntülenmek istenen hata türü veya “Tüm Hatalar” seçilerek tüm hatalar aynı anda görüntülenebilir. Burada sistem için önemli bir geliştirme ise görüntü üzerinde tespit edilmiş hatalarda bir düzenleme yapılmak istenmesi durumunda “Görüntü Üzerinde Etiketleme Yap” butonu ile etiketleme çalışması yapılabilir.

Bu noktada gerekli görülmeyen kart taramalarını hem depolama alanını doldurmaması hem de eğitim modellerinin geliştirilmesinde fayda sağlamayacak olduğu düşünülürse “Veri Setine Kaydetme ve Devam et” butonu seçilerek taramaya ait görüntüler kalıcı olarak silinir. “Veri Setine Kaydet ve Devam et” butonu ile görüntü seti kaydedilir ve ekrandan çıkarılır.



Şekil 3.5 Sonuç ekranı

Kart tarama sonucunda elde edilmiş görüntüler, kart tarama işlem dizininden çıkılmadan bakılıyorsa ayrıntılı bakış veya tekrar bakış özelliği kullanılabilir. Görüntülerde kamera yüksekliğini değiştirip daha uzaktan veya yakından bakılmak istenebilir. Bunun için “Detaylı bakış” altında Z yani kamera yüksekliği girilip “Detaylı bakış yap” butonunun işletilmesi gerekir. Bu noktada görüntüleme cihazı tekrar seçili görüntünü koordinatlarına gidecek ve Z değerine göre tekrar görüntü alacaktır. Eski görüntü yerine artık bu yeni görüntü olacak ve hata tespit algoritması da çalışacak ve yeni görüntü yeni çıktılar ile gösterilecektir. Eğer belli bir alanda detay istenirse bu yöntem tercih edilebilir. Bu noktada alınan ayrıntılı görüntüler önceki görüntünün yerine veri tabanına kaydolmaktadır ama bu kullanıcı tercihi göre bir ekleme ile değiştirilebilir.

### 3.1.4. Veri Tabanı Ekranı

Veri tabanı tüm kaydedilmiş görüntülerin listelendiği bölümdür. Bu kısımda veriler “Windows” dosyalama sistemi düzeninde saklanmaktadır. Bu sayede kullanıcı verilere arayüz olmadan ya da kod bilgisi gerektirmeden dosya yolu üzerinden de ulaşabilir, ancak yorumlaması ve incelemesi görüntüler ve görüntü bilgileri ayrı olarak kaydedildiği için zor olacaktır. Veri tabanının tutulduğu konum kullanıcı tarafından belirlenebilir veya sonrasında değiştirilebilir. Ama değiştirildiği takdirde eski veriler yeni konuma taşınmayacaktır. Sadece o an belirlenmiş konumda bulunan veriler veri tabanını oluşturacaktır. Eğer bir değiştirme durumu yapılırsa veriler yeni konuma kullanıcı tarafından taşınmalıdır. Şekil 3.6 ile verilen arayüz içinde her taramaya ait veriler ayrı dosyalar içinde saklanır ve dosya isimleri kart ile ilgili girilen bilgiler ve arayüz işlem numarası kullanılarak oluşturulur.

Number	Card ID	Seri No	UDK	PN	Hatalar
0	0	0	0	0	
36	AELSAN	21-2323	123	00	
37	AELSAN	21-2323	123	00	- Eksik Lehim ...
45	none	none	none	none	- Kalkmış ...
48	none	none	none	none	
57	none	none	none	none	- Eksik Lehim ...
59	none	none	none	none	- Eksik Lehim ...
60	id	none	none	none	- Kalkmış ...
61	id	none	none	none	- Kalkmış ...
62	id	none	none	none	
63	id	none	none	none	- Kalkmış ...

Şekil 3.6 Veri tabanı ekranı

İstenildiğinde arayüz olmadan da veriler bulunabilir veya kopyalanabilir, ancak arayüz ekranı kullanıcı kolaylığı sağlar. Arayüz içinde her taramaya ait veriler ayrı dosyalar içinde saklanır ve dosya isimleri kart ile ilgili girilen bilgiler ve arayüz işlem numarası

kullanılarak oluşturulur. Bu şekilde istenildiğinde arayüz olmadan da veriler bulunabilir veya kopyalanabilir, ancak arayüz penceresi kullanıcı kolaylığı sağlar.

Arayüzde veri tabanı sayfasında tüm kayıtlı veriler görülebilmektedir. İstedildiğinde harf veya kelime olarak veya hata türüne göre arama ve filtreleme yapılabilir. Bu da gerekli olduğunda istenen veriye ulaşılmasını kolaylaştıracaktır. Ayrıca tüm veriler tekrar kullanılabilir, üzerinde istendiğinde yeniden etiketleme veya hata tespit algoritması tekrar çalıştırılabilir.

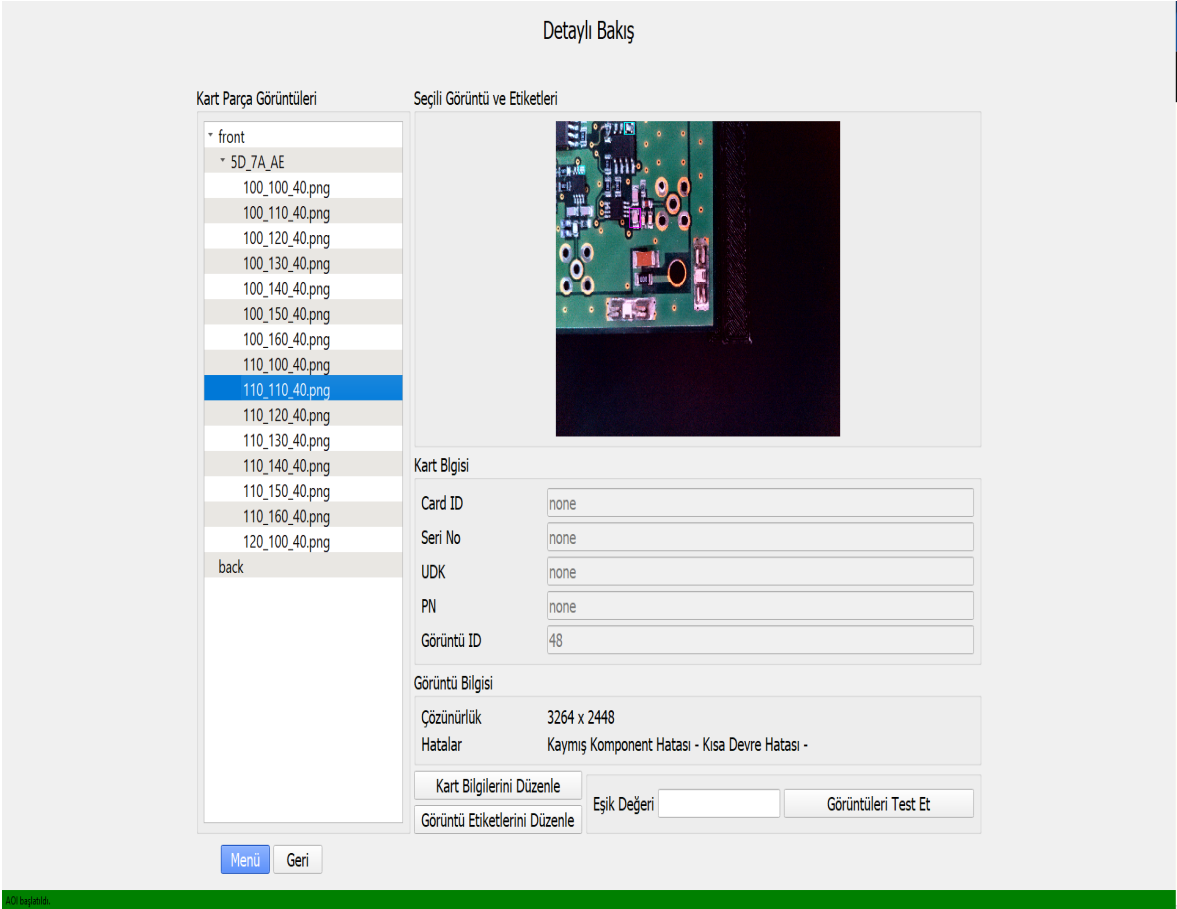
Veri tabanı ekranında sistemde kayıtlı tüm görüntü setleri kart bilgileri ve özel atanmış numaraları ile görülebilmektedir (Şekil 3.6). Bu görüntü setleri içinde barındırdığı hata çeşitleri "Hatalar" sütunu altında görülebilmektedir. Aynı zamanda sağ taraftaki "Listelenenler" kısmından da hata türleri filtrelenebilir. Bir anahtar kelime veya harfe göre de arama yapılabilir. Bu sayede istenen veriye ulaşım kolaylaşmış olmaktadır. Kayıtlı görüntü setlerinden biri seçilip "Kaldır" butonu ile silinebilir veya "Çıktı Al" butonu ile seçili yere kopyalanabilir.

Kayıtlı verilerden biri seçilerek "Detaylı Gösterim" butonuna basılarak görüntü seti içindeki tüm görüntüler ve görüntüler üzerinden tespit edilmiş hata ve türleri detaylı olarak görülebilir.

### **3.1.5. Detaylı Bakış Ekranı**

Detaylı gösterim ekranında belirli bir görüntü setine ait arka ve ön yüz taramaları, farklı LED renklerinde alınan görüntüler, alınan görüntülerin çözünürlükleri ve varsa seçili görüntü üzerindeki hatalar belirtilmektedir. Şekil 3.7'de gösterilen bu pencerede "Kart Bilgilerini Düzenle" butonuna basılarak kart bilgisi altındaki bilgiler düzenlenebilir. "Görüntü Etiketlerine Düzenle" butonu ile seçili görüntü üzerindeki tespit edilmiş hataların etiketleri düzenlenebilir. "Görüntüyü Test Et" butonu ile eğer görüntü üzerinde daha önceden hata tespit algoritması çalıştırılmadıysa veya tekrar çalıştırılmak isteniyorsa tekrardan hata tespiti yapılabilir.

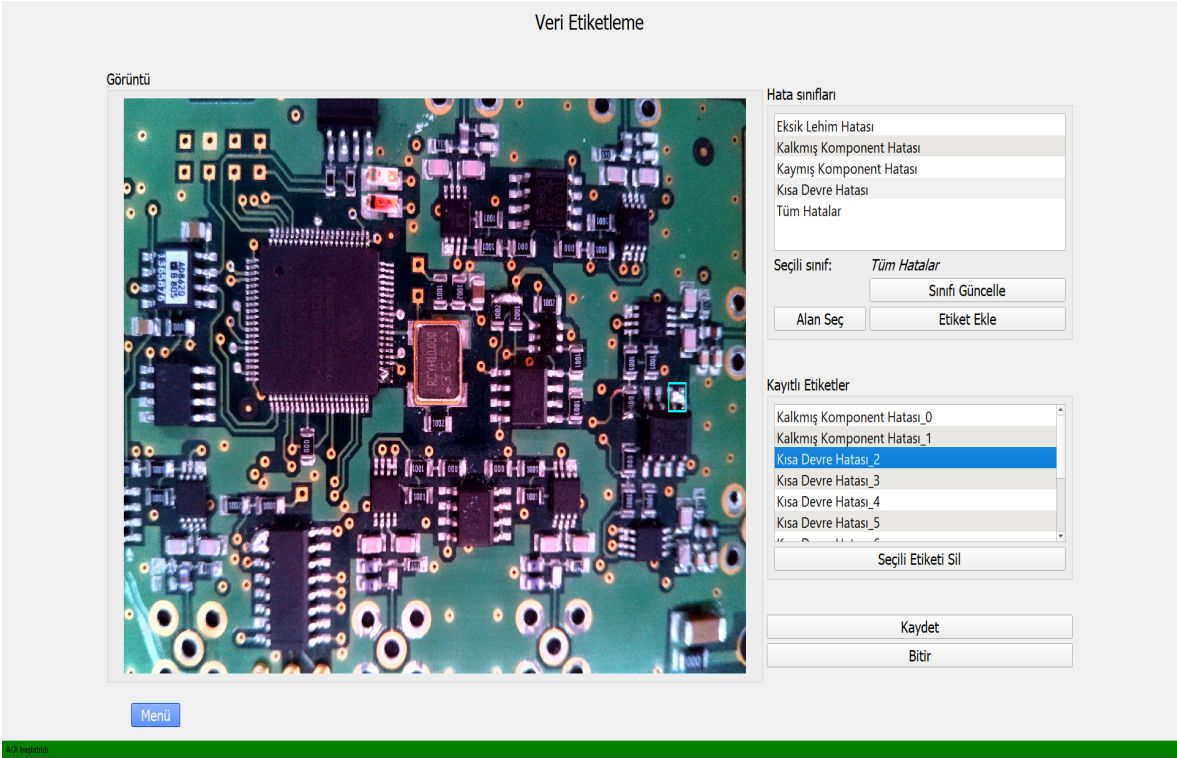




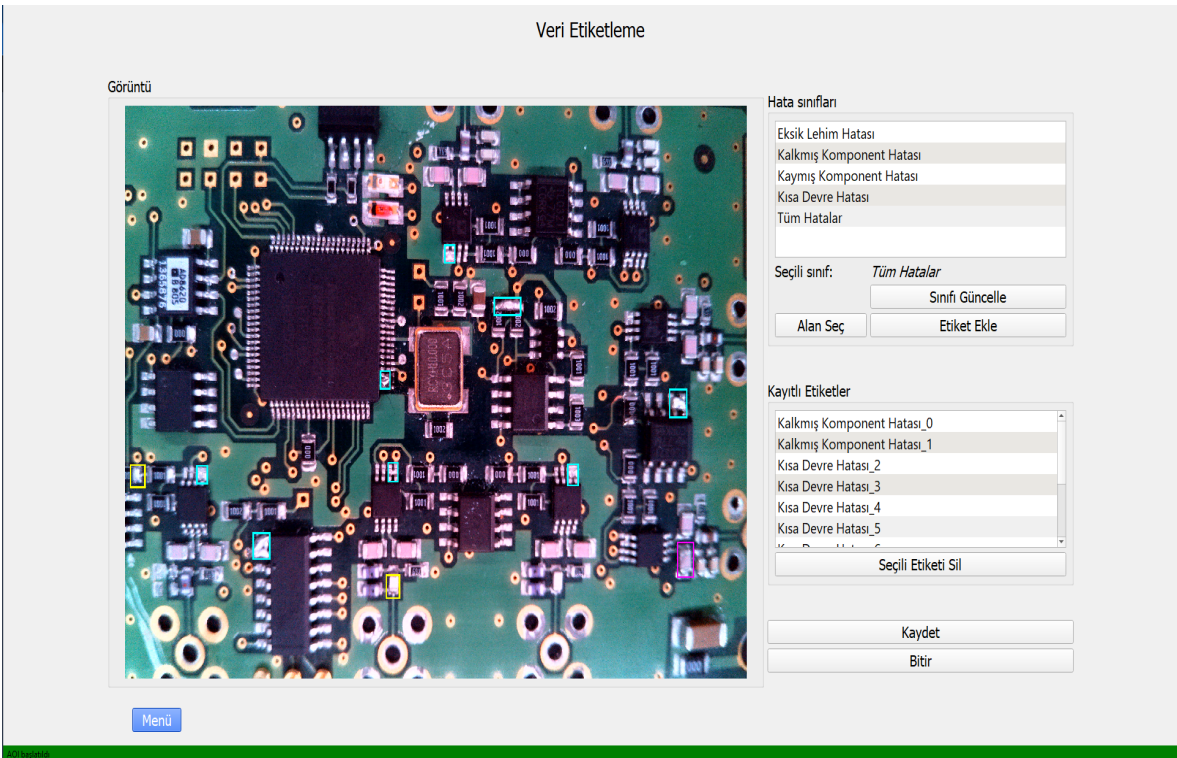
Şekil 3.7 Detaylı bakış ekranı

### 3.1.6. Veri Etiketleme Ekranı

Veri etiketleme eğitim için önemli ve zorunlu bir evredir. Şekil 3.8 ve 3.9'da örnekleri sunulan biçimi ile etiketleme özellikleri arayüze uyumlandırılmış olup istendiğinde veriler üzerinden etiket ekleme ve düzenleme işlemi yapılabilmektedir. Hata tespit algoritmasının çıktıları da hataların konumlarını etiketlenmesi aşamasında yararlı bir destek bilgisi sunmaktadır. Kullanıcı isteğine bağlı olarak bu çıktılar da anlık olarak düzenlenebilmektedir.



Şekil 3.8 Görüntü etiketleme ekranı 1



Şekil 3.9 Görüntü etiketleme ekranı 2

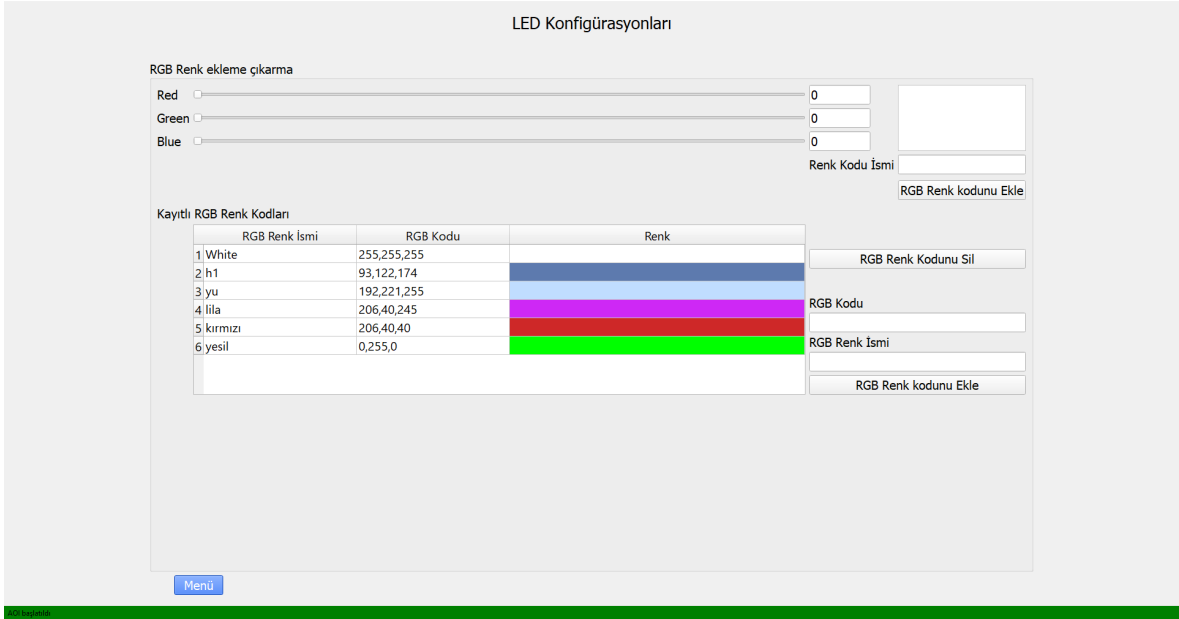
Bu etiketler projenin bu evresi için dört temel kart hatası üzerinden yapılmaktadır. Ama eğer kullanıcı yeni bir hata türünü de öğretmek isterse bu hata da sisteme eklenebilecek bir yapıdadır ve etiketlemelerin eklenen yeni hatalar üzerinden de yapılabileceği açıktır.

Etiketleme işlemi hata sınıfının seçilmesi ve sonrasında hatanın olduğu bölgenin dikdörtgensel alan içine alınması ile gerçekleştirilmektedir. Etiketler ayrı ayrı görülebileceği gibi sadece belli hata sınıfına ait hataların görülebilmesi de sağlanabilir.

Veri etiketleme ekranında daha önceden var olan etiketler ayrı ayrı veya sadece belli bir hata sınıfına ait olanlar ya da tüm etiketler aynı anda görülebilir. Bu sayede detaylı olarak hata ve konum bilgisine ulaşılabilir. Etiket ekleme işlemi için bir hata sınıfı seçilir ve “Sınıfı Güncelle” butonuna basılır. Bu buton aynı zamanda o hata sınıfına ait tüm hataların da görüntü üzerinde görülmesini sağlayacaktır. Hata sınıfı seçildikten sonra “Alan Seç” butonuna basılarak görüntü üzerinde işaretleme etkin hale gelir. Görüntü üzerinde basılı tutularak dikdörtgensel bir alan belirlenir. Tarama işlemi tamamlandıktan sonra “Etiket Ekle” butonu ile seçili etiket kayıtlı etiketlere eklenir. İstendiğinde ”Kayıtlı Etiketler” altında tüm var olan etiketler görülebilir. Bu pencere içinde çift tıklama ile etiketler ayrı olarak görüntülenebilir ve istendiğinde etiket seçilip silinebilir. Veri etiketleme ekranında yapılan tüm işlemlerin kaydedilmesi için “Kaydet” butonuna basılmalıdır. Aksi halde en son kaydedilen sürüm var olmaya devam edecektir.

### **3.1.7. LED Düzenleme Ekranı**

LED düzenleme ekranında LED için renk kodları ve isimleri belirlenir. Şekil 3.10’da gösterildiği gibi renkler için ekleme çıkarma veya RGB kodları üzerinden renk denemeleri yapılabilir. Renk kodu doğrudan girilebileceği gibi el ile de kaydırma çubukları kullanılarak değiştirilebilir.



Şekil 3.10 LED düzenleme ekranı

LED düzenleme ekranında LED için renk kodları ve isimleri belirlenir. Renkler için ekleme çıkarma veya RGB kodları üzerinden renk denemeleri yapılabilir. Renk kodu direk olarak girilebileceği gibi el ile de kaydırma çubukları kullanılarak değiştirilebilir.

### 3.1.8. Ayarlar Ekranı

Ayarlar ekranında “Hareket Ayarları” (Şekil 3.11), “Hareket Ayarları” (Şekil 3.12), ve “Kayıt” (Şekil 3.12) sekmeleri bulunmaktadır. Kamera ayarları sekmesinde kameranın çözünürlük ve odaklama parametreleri seçilebilmektedir. Hareket ayarları sekmesinde görüntüleme cihazının motor denetimi için parametreler ayarlanabilmektedir. Kayıt sekmesinde ise veri tabanının kayıt konumu dosya yolu olarak girilebilmektedir.

Görüntüleme cihazı, kamera ve arayüz için ayarlar elle değiştirilebilir hale getirilmiştir. Bu ayar özel olarak ayarlanmış olsa da kullanıcı tarafından gerekli görüldüğünde farklı ayarlar denenebilir. Kamera için odaklanma ve çözünürlük ayarları değiştirilebilir. Görüntüleme cihazı için motor ayarları değiştirilebilir. Arayüz için ise veri tabanının kayıt konumu değiştirilebilir.

Ayarlar

Kamera Ayarları Hareket Ayarları Kayıt

Odak Aralık Değeri 400 Odak Adım Değeri 8

Kamera Çözünürlüğü 4192x3104 Canlı Görüntü

Kaydet

Menü

Şekil 3.11 Ayarlar ekranı - Hareket Ayarları

Ayarlar

Kamera Ayarları Hareket Ayarları Kayıt

Max Feed Rate (mm/s)

X

Y

Z

JerK (mm/s)

X

Y

Z

Axis Steps Per Unit (steps/mm)

X

Y

Z

Max Acceleration (change/s) change = mm/s

X

Y

Z

Adım (mm)

Adım başı mm

Acceleration (change/s) change = mm/s

Acceleration

Minimum Noktaları (mm)

X Min

Y Min

Z Min

Maksimum Noktaları (mm)

X Max

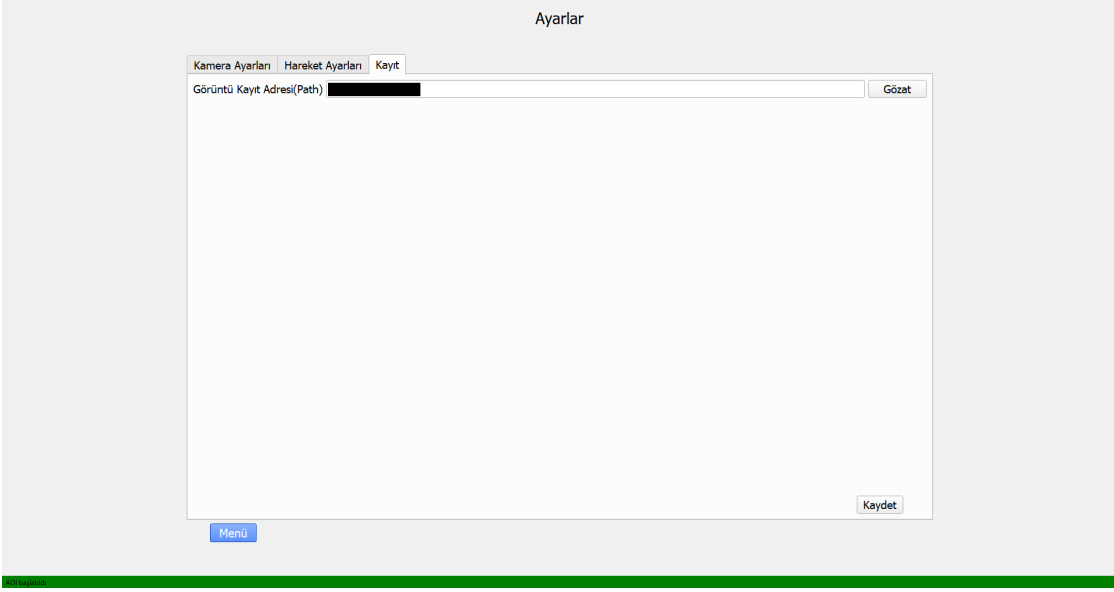
Y Max

Z Max

Kaydet

Menü

Şekil 3.12 Ayarlar ekranı - Hareket Ayarları



Şekil 3.13 Ayarlar ekran - Kayıt

## 3.2. Yazılım Tasarımı

Proje kapsamında OOİ cihazı için üç alt yazılım oluşturulmuştur. Bu yazılımlar için Python ve C/C++ dilleri kullanılmıştır.

### 3.2.1. Cihaz Denetim ve Haberleşme

Cihazın yazılımsal olarak temel özellikleri kameranın XYZ ekseninde konumlanmasını sağlamak, cihaz içerisindeki aydınlatmayı sağlamak ve bilgisayar tarafında bulunan arayüz programı ile iletişimini sağlamak olmaktadır.

G-kodu, başta CNC makineleri olmak üzere birçok farklı cihazda kullanılan bir programlama dilidir. G kodu “Geometrik Kod” anlamına gelmektedir. Sistem için bu dil, cihaza bilgisayar tarafından yapılması istenen hareketleri ve hareket özelliklerini, aydınlatma için RGB kodlarını ve acil durumda kullanılması için durdurma veya iptal komutlarını iletmek ve geri dönüş almak için kullanılmaktadır. G-kod evrensel olarak geçerli bir seri komutlara sahiptir bu sayede cihaz kontrolü için gerektiğinde farklı programlar veya cihazlar da kullanılabilir. Özel bir komut seti bilgisi gerekmez.

Cihaz içinde aydınlatma için ayrı bir LED kontrol kartı tasarlanmış ve kullanılmaktadır. Ana kontrol kartı ile haberleşme içindedir. Bu haberleşme için UART haberleşmesi kullanılmaktadır. Bu haberleşmedeki komut setleri karta özel olarak oluşturulmuştur. Bu komutlar sadece LED kontrol kartı ve ana kontrol kartı arasında geçerlidir. Bilgisayar tarafından aydınlatma ile ilgili gelen G-kod ana kontrol kartında yorumlanır ve UART üzerinden sadece veri olarak aktarılır. Her bir aktarım RGB koduna ait bilgi içerir. LED kontrol kartında bu veriler toplanır ve yorumlanır. İşlem sonucunda istenen aydınlatma sağlanır. Bu iletişim tek yönlü olup sadece ana kontrol kartından LED kontrol kartına olacak şekildedir.

### **3.2.2. Kamera Yazılımı**

Kamera yazılımı için iki seçenek ön plana çıkmıştır. Bu iki seçenektan bahsetmeden önce kullanılan kameranın önemli bir özelliğinden bahsedilmesi gerekir. Kameranın görüntü üzerinde odaklanabilmesi için ilk seçenekte kamera kartının yazılımında bulunan otomatik odaklama algoritmasının odaklamayı sağlamasıdır. Bu noktada kamera, odaklamayı görüntülenmekte olan BDK'nın kameraya uzaklığına göre otonom olarak ayarlamaktadır. Ama bu odaklanma süresi BDK'nın kameraya uzaklığı, ışık şiddeti, kartın rengi veya şekline bağlı olarak farklılık göstermektedir. Bu odaklanma işleminin tamamlandığını da tespit etmek için anlık görüntü işlenmeli ve odaklanmanın sağlandığının tespit edilmesi gerekmektedir. Ayrıca da odaklanma başarısız olursa tekrar başlatılmalıdır. Ya da kamera yazılımı ile iletişim kurulmalı ve odaklama süreci ile ilgili dönüt alınmalıdır. Odaklamamanın tamamlandığı tespit edilebilse bile odaklanma süreci değişkenlik göstermekte ve 10 saniyeye kadar çıkabilmektedir. Bu işlem görüntüleme esnasında her kamera adımı yapılmakta ve bu görüntüleme süresini oldukça arttırmaktadır. Bir örnek verilirse 200x200 mm boyutlarında bir BDK için kameranın her adım hareketi 10 mm olduğunu varsayalım. Bu durumda toplamda 400 adet görüntü alınacak demektir ve her görüntünün odaklanması için ortalama 5 saniye beklendiğinde 2000 saniyenin yani 30 dakikadan fazla sürenin sadece odaklanmaya ayrılması gerekmektedir. Bu istenen bir görüntüleme süresi değildir. Süreyi kısaltmak için ikinci seçenek daha getirili olacaktır.

İkinci seçenekte kamera yazılımında bulunan otomatik odaklanma işlemi devre dışı bırakılır ve kameranın BDK uzaklığına göre otomatik odak ayarı yapılır. Kameranın yazılımı ile anlık olarak iletişim kurulabilmekte ve odaklanma için gerekli değerler güncellenebilmektedir. Kameranın görüntüleme esnasında BDK ile arasındaki yükseklik anlık olarak bilinmektedir. Çünkü tarama başlamadan önce bu bilgiler ayarlanmış, kart ve kamera arasındaki uzaklık ve doğrusal step motorun anlık yüksekliği bilinmektedir. Bu yükseklik değerine bağlı olarak kamera yazılımındaki odak değeri de her yüksekliğe yani kameranın BDK'ya olan uzaklığına göre güncellenecektir. Yüksekliğe bağlı olan odak değerleri yapılan testler ile belirlenmiştir ve matematiksel algoritma ile bilgisayar tarafındaki arayüze eklenmiştir. Arayüzün içinden de oda değerlerinin katsayısı istendiğinde değiştirilebilmektedir. Bu kullanım ile kamera odağı sabit kalacak ve değişmeyecektir. Vermiş olduğumuz örnekteki her kamera adımında odaklanma için 10 ile 5 saniye arasında değişen süreler gerekecektir. 200x200 mm boyutlarında olan kart için görüntüleme süresi kamera adımın hızına bağlı olacaktır. Her adım 1 saniyede tamamlandığında toplam görüntüleme 400 saniye yani 6-7 dk civarında olacaktır. Bu işlem adım hızı artırılarak hızlandırılabilir ama kamera odağı sabit olsa dahi hareket sonrası net görüntü oluşması için 0.5 ile 1 saniye arasında bekleme süresi gerekebilir. Bu da süreyi limitlemektedir. İki seçenek arasında görüntüleme süresini oldukça kısaltabildiği için ikinci seçenek tercih edilmiştir.

### **3.2.3. Veri Depolama ve Analizi**

BDK'nın görüntüleri alınırken veriler dört farklı kategoride etiketlenmektedir ve hiyerarşik olarak da ilk üç kategori dosyaların ve son kategori ise de görüntünün dosya ismi olmaktadır. İlk kategori özel isimlendirilmiştir. Bu aşamada tez isterleri kapsamında görüntü alınan karta ait bazı bilgiler girilebilir (Şekil 3.14). İkinci kategoride her bir BDK için ön ve arka yüz olacağı öngörülmüş olup bu sebeple "front" ve "back" olarak etiketlenmektedir (Şekil 3.15). Görüntü alım aşaması sonrasında arka yüz için tarama yapılması seçildiğinde "back" olarak, ilk alınan her görüntü ise "front" olarak etiketlenmektedir. Üçüncü kategori ise aydınlatma için kullanılan RGB kodu olmaktadır. "R\_G\_B" olarak dosya ismi verilmektedir (Şekil 3.16). Dördüncü kategori de kameranın görüntü aldığı XYZ konumu bilgisi isim olarak verilir ve



”X\_Y\_Z.png” olarak görüntü kaydedilir. Yanında da eğer görüntü üzerinde bir hata tespit edilmiş ise ”X\_Y\_Z.txt” dosyası bulunur ve hata tespit verilerini içerir (Şekil 3.17).

Ad	Tür	Boyut
65_ID5_PWR_TST_56	Dosya klasörü	

Şekil 3.14 Dosya düzeni - Kart bilgisi

Ad	Tür	Boyut
back	Dosya klasörü	
front	Dosya klasörü	

Şekil 3.15 Dosya düzeni - Kart yüzü

Ad	Tür	Boyut
0_FF_0	Dosya klasörü	

Şekil 3.16 Dosya düzeni - LED renkleri

Ad	Değiştirme tarihi	Tür	Boyut
120_210_0.png	26.05.2022 19:40	PNG Dosyası	15,449 KB
120_210_0.txt	23.04.2024 21:43	Metin Belgesi	1 KB
120_220_0.png	26.05.2022 19:40	PNG Dosyası	14,715 KB
120_220_0.txt	23.04.2024 21:47	Metin Belgesi	1 KB
120_230_0.png	26.05.2022 19:40	PNG Dosyası	14,207 KB
120_230_0.txt	23.04.2024 21:48	Metin Belgesi	1 KB


Şekil 3.17 Dosya düzeni - Görüntüler

Arayüz üzerinden kamera kapasitesine bağlı olarak görüntüler için çözünürlük seçilebilmektedir. Her alınan görüntü de bu çözünürlüğe göre kaydedilmektedir. Ama hata tespiti ve eğitim için görüntü kullanılırken aslında belirli bir çözünürlük ayarlıdır. Görüntü bu çözünürlükte de kaydedilebilir Ama eğitim için ayarlanmış bu çözünürlük, sistemde bulunan kameranın çözünürlük kapasitelerinden daha düşüktür ve kullanıcı deneyimi için iyi olmayacaktır. Ama yine de yüksek çözünürlükte kaydetmek kullanıcı deneyimi göz önüne alınarak tercihe bırakılmıştır. Veri bankasına kaydedilen görüntüler orijinal hali ile saklanarak ilerde tekrar üzerinden farklı bir işlem yapılabilme veya daha ayrıntılı bir görüntü elde etmek istenebilir düşüncesi ile kullanıcı kararına bırakılmıştır. Görüntülerin depolama olarak kapladığı alana göre kullanıcı bu duruma karar verebilir.


Görüntülerin kapladığı alan fazla olabilmektedir. Bu durum donanıma bağlı olarak kullanım devam ettikçe depolama alanı yetmezliğinden dolayı sorun çıkarabilir. Bu durum için alınan her görüntü seti sonrasında veri bankasına kaydedilme durumu kullanıcıya bırakılır. Aynı görüntü çeşidinden yani seçili sınıfa ait benzer hataların bulunduğu görsellerin saklanması tavsiye edilmez. Çünkü benzer görüntülerin artması eğitime büyük anlam ifade eden bir katkı sağlamamaktadır. Benzer veya aynı veri eğitim sonucunda zaten öncesinde öğrenilmiş olacağı için yenisi de bu bilgi ile zaten bulunabilir. Ayrıca aynı bilginin tekrarı bilgiye daha çok bağlanması anlamına gelir ve yeni olası görüntüler için fayda sağlamaz. Bu noktada sadece depolama alanı işgal ediyor olabilir. Ama görüntüdeki benzer bu durumun tespitinin başarısı düşük görülüyorsa veya tespitinde süreklilik görülüyorsa benzer veriyi arttırmak bahsedildiği gibi bilgiye bağlanmasını ve eğitimde başarı oranına daha çok etki etmesini sağlar. Eklenen veriler hata tespitine pozitif yönde bir etki yapacaktır. Bu kararları kullanıcı operasyon sırasında alacaktır ve yanlış alınan karara ait veya geliştirme sağlamadığı düşünülen bir görüntü setini veri bankasından silebilir ve önceki eğitilmiş modele de geçilebilir. Bu durumdan daha ayrıntılı olarak model eğitimi kısmında bahsedilecektir.

#### **3.2.4. Görüntü Etiketleme**

Devre kartları üzerinde lehimlerin konumları CAD verisi olmadan bilinemediğinden bu lehimlerin tespiti ve bölütlenmesi (segmentation) gereklidir. Lehimleri tespit edebilmek için yeteri kadar eğitim verisine ihtiyaç vardır. Bu verilerden öznitelikler çıkararak bir sınıflandırıcı eğitilip kart görüntüleri üzerinde lehim konumları otomatik olarak bulunabilir. Bu sayede kamera her bir lehim bölgesine denetim için yönlendirilebilir. Lehim özniteliklerini çıkarabilmek için öncelikle lehimin etiketlenmesi gerekir. Bu amaçla ilk verilerin oluşturulması için Python tabanlı etiketleme aracı olan labelImg.exe kullanılmış olup sonrasında geliştirilmiş olan arayüz üzerinden bu işleme devam edilerek birçok kart görüntüsü üzerinde lehimler ve diğer hata sınıfları Şekil 3.18 ve 3.19'da olduğu gibi etiketlenir. Etiketlenen görüntüler içerisinde etiketlenmiş alana ait bilgiler (hata sınıfı, merkez x koordinatı, merkez y koordinatı, genişlik, uzunluk) yer alınır.



Şekil 3.18 Örnek görüntü etiketleme 1



Şekil 3.19 Örnek görüntü etiketleme 2

## 4. ÖNERİLEN YÖNTEM ALTYAPISI VE TASARIMI

### 4.1. Derin Öğrenme

Derin öğrenme, insanlara doğal gelen örnek ile öğrenmeyi öğreten bir makine öğrenimi yöntemidir. Derin öğrenme, örnekler arasında sürücüsüz arabaların dur işaretini tanımasını ya da bir lamba direği gözleminden yayayı ayırt etmesini sağlayan ana teknolojidir. Ayrıca telefon, tablet, televizyon gibi tüketici elektroniği cihazlarındaki ses denetimlerinin olduğu örneklerin önemli veri işleme yaklaşımıdır. Derin öğrenme, daha önce erişilmesi imkânsız olan sonuçlara eriştiği için son günlerde oldukça dikkat çekmektedir. Bilgisayar modeli, derin öğrenmede sınıflandırma yapmak için doğrudan görüntülerden, yazıdan veya sestən öğrenir. Derin öğrenme modelleri bazen insanüstü başarımlar göstererek yüksek doğruluk oranına erişebilmektedir. Modeller çok sayıda etiketlenmiş veri ve birçok katman içeren sinir ağları kullanılarak eğitilmektedir. 1980’lerde kuram geliştirilmiş olan derin öğrenmenin ancak günümüzde popüler bir hale gelebilmesine iki sorunun çözülmesi sebep gösterilebilir.


- Derin öğrenme çok sayıda etiketli veri gerektirir. Örneğin, sürücüsüz araç gelişimi milyonlarca görüntü ve yüzlerce saatlik video gerektirir.
- Derin öğrenme önemli ölçüde işlem gücü gerektirir. Derin öğrenme için verimli olan paralel mimariye sahip yüksek başarılı GPU’lar bir derin öğrenme ağının eğitim süresini haftalardan saatlere düşürebilir.

#### 4.1.1. Derin Öğrenme Yapısı

Derin öğrenme yöntemleri sinir ağları mimarisini kullanır. ”Derin” genellikle sinir ağındaki gizli katman sayısını ifade eder. Geleneksel sinir ağları Şekil 4.1’deki gibi yalnızca 2-3 gizli katmana sahip iken derin ağlar 150 kadar katmana sahip olabilirler.

Derin öğrenme modelleri veriden kendi kendine öznitelikleri öğrenirken kullanıcının öznitelik çıkarımına ihtiyaç duymazlar. İlgili öznitelikler, ağ bir grup görüntü üzerinde

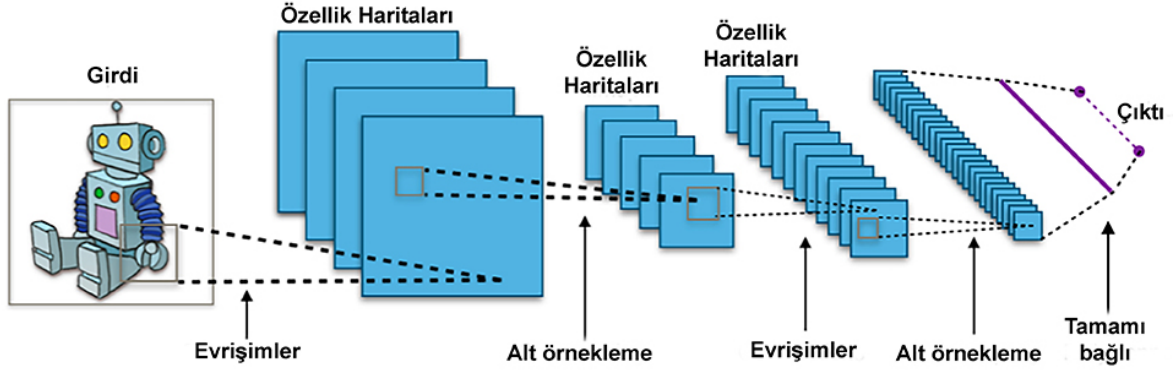
eđitilirken öğrenilir. Bu otomatik öznitelik çıkarımı nesne sınıflandırma gibi bilgisayarlı görü görevleri için yüksek doğruluk sağlar.



Şekil 4.1 Sinir ađları [1]

CNN yapıları (Convolutional Neural Networks) onlar veya yüzlerce gizli katmanı kullanarak görüntünün farklı özniteliklerini tespit etmek için öğrenir. Her bir gizli katman öğrenilen görüntünün özniteliklerinin karmaşıklığını artırır. Örneğin ilk katman köşelerin nasıl tespit edileceğini öğrenebilirken son katman saptamak istediğimiz objeye özgü daha karmaşık şekilleri nasıl bulacağını öğrenebilir.

Şekil 4.2’de CNN’deki katmanlar genel sıraları ile verilmiştir. CNN yapısında ilk katman her zaman Evrişim katmanıdır. Bu katmanda giriş görüntüsünde genelde 3x3 veya 5x5 boyutunda bir filtre gezdirilir. Bu işlem sırasında filtre ağırlıkları görüntünükiler ile çarpılır ve bu değerler toplanır. Bu işlem tüm görüntü üzerinde yapıldıktan sonra bir öznitelik haritası elde edilir. Daha sonra aktifleştirme fonksiyonu olan ReLU katmanında evrişim katmanını çıktıları eşiklenir. Bir diđer katman olan Pooling katmanı ise çıktı üzerinde alt-örnekleme (downsampling) yaparak gereksiz özniteliklerin atılmasını sağlar. Ađın en sonunda ise Fully Connected katmanı önceki Evrişim / Pooling katmanının çıktısına bakarak görüntüyü en iyi tanımlayan etiketi tahmin eder.



Şekil 4.2 Birçok evrişimsel katmanlı bir ağ örneği [2]

#### 4.1.2. Sadece Bir Kere Bak (You Only Look Once (YOLO)) Algoritması

YOLO'dan bahsetmeden önce, YOLO için hazırlanan veri kümelerinden bahsetmek gerekmektedir. Donanım ile çekilen BDK fotoğrafları projenin veri kümesini oluşturmaktadır. Oluşturulan veri kümelerinin zenginleştirilmesi ve derin öğrenmenin başarımının yükselmesi için de oldukça fazla sayıda hatalı BDK'ya ihtiyaç bulunmaktadır. Fotoğrafi çekilen hasarlı kartlar veri kümesini zenginleştirir. Yani fotoğraflar bütünü bir veri kümesi oluşturur. Ancak not etmek gerekir ki, bazı durumlarda kullanılan veri kümelerinde düzenlemeler yapılmıştır. Örneğin fotoğrafın parlama veya sönük çıkması sonucu piksel farklılıkları oluştuysa elde edilen görüntüleri çok daha hızlı ve sisteme uygun bir şekilde kullanmak için yeniden boyutlandırma işlemi yapılmıştır. Evrişimsel sinir ağları ile danışmanlı öğrenme modelinde yapay zekâ eğitimi yapmak için oldukça fazla sayıda etiketli veriye ihtiyaç vardır. Yüksek miktarda veriye ihtiyaç duyulduğu için veri artırma işlemleri gerçekleştirilmiştir. Bu işlemler "Python" programlama dili ve "OpenCV" kütüphanesi ile yapılmıştır. Bu tekniğin her veri kümesi için kullanılmadığını belirtmekle birlikte şunu da eklemek gerekir ki veri artırma yöntemlerinden döndürme, beyazlatma vb. yöntemler kullanılmıştır.

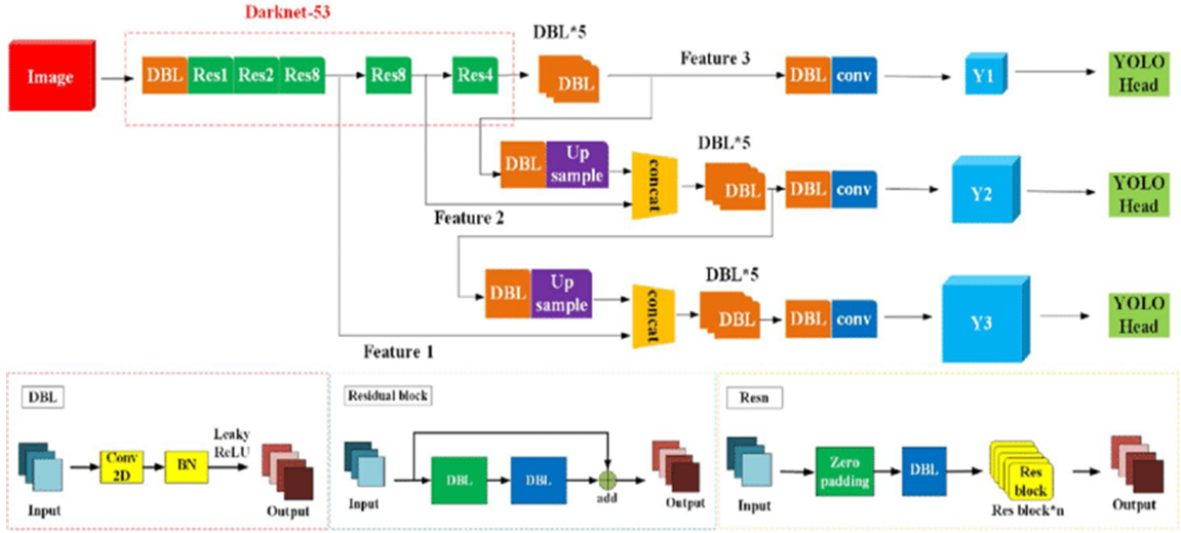
Burada dikkat edilmesi gereken nokta, Python programlama dili ile veri artırımı yapılan kümelere kendini yineleyen verilerin olup olmamasıdır. Projede kendini yineleyen veri kümeleri tespit edilip eğitime dahil edilmemiştir. Kendini yineleyen veri kümelerinin



olmamasına özen gösterilmiştir. Bunun nedeni ise, kendini yineleyen veri kümelerinin yapay sinir ağlarında “overfitting” olayına neden olmasıdır. “Overfitting” yapay zekanın veri kümesini ezberlemesi ve veri kümesine dâhil olmayan verilerde ise tespit yapamama durumudur.


Veri kümesi olarak elde edilen veriler yapay zeka eğitimi için bir sonraki adım olarak etiketlenme işlemine tabi tutulur. Bu işlem yapay sinir ağlarındaki en kritik işlemlerden biridir. Etiketleme işlemini gerçekleştirmek için ilk başlarda Windows “Labelimg” programı sonra ise geliştirilen arayüz kullanılmıştır. Bu program üzerinden veri kümesindeki hatalar etiketlenmiş ve her hata türü için Class Index çıkartılmıştır. Bu “Class index”ler YOLOv3 programının çıktıları ve Darknet-53’ün girdileri olacaktır. Bu ardışık düzenin tamamı, Şekil 4.3’te gösterildiği gibi temel olarak omurga ağı yoluyla öznitelik çıkarımı ve birleşimini içerir. Veri kümeleri anlatıldığına göre şimdi ise YOLO ve derin öğrenme ilişkisi anlatılacaktır.

YOLO [24] ve YOLOv2 [25] ağlarının yenilenmesi ve güncellenmesi ile YOLOv3 [26] ağı geliştirilmiştir. Bilindiği üzere R-CNN [27] yönteminde nesne tespiti nesnenin bulunabileceği olası alanlara ihtiyaç duymaktadır. YOLO ise R-CNN yönteminin aksine bu olası alanlara ihtiyaç duymayıp nesne tespiti regresyona dönüştürmektedir. Regresyon ile görüntüde bulunan sınıflar için sınırlayıcı kutu koordinatları ile olasılıkları aynı anda oluşturulur. Bunu yaparken ise YOLO’nun tüm sınıflar için ayrı ayrı işlem yapmasına gerek yoktur. Görüntüye bir kez bakılması tüm sınıflar için sınırlayıcı kutu koordinatları ve olasılıklarının oluşturulması için yeterlidir. Görüntüde bulunmak istenen nesnenin tespiti yapılırken tüm sınıflar için ayrı ayrı işlem yapılmadığı için bu işlemler çok hızlı gerçekleştirilmektedir. Yani tespit süresi konusunda ciddi verim almak için YOLO programının kullanılması çok uygundur. Görüntüye bir kez bakıldığında tüm sınıflar için sınırlayıcı kutu koordinatlarının tespiti YOLO’yu öne çıkaran bir özelliktir. Yani YOLO nesnenin bulunabileceği olası alanlara ihtiyaç duymayıp nesne tespiti regresyona dönüştürmektedir.



Şekil 4.3 YOLO sistem mimarisi [3]

Şekil 4.4 verilen YOLO sistem modeli görüntüyü  $S \times S$ 'lik kareler düzenine (grid) böler ve her bir kare için güven skorları (confidence) ile birlikte sınırlayan kutu tahmini ve sınıf olasılığı tahmini yapar.



Şekil 4.4 YOLO tespit şeması [4]



### 4.1.3. Hata Tespit Algoritması

Hata tespit algoritması iki farklı aşamada çalışmaktadır. İlk olarak görüntü alma işlemi sonrasında ve ikinci olarak ise veri bankasında herhangi bir görüntü seti için özel olarak başlatılabilir. Yazılımda hata tespiti için kullanıcı tarafından iki giriş bilgisi gerekmektedir. Diğer gerekli bilgiler yazılımda kullanıcının değişiklik yapmasına izin vermeyecek şekilde kayıtlıdır. Kullanıcı tarafından beklenen girişler; görüntü setinin ve hata tespiti için eşik değerinin seçilmesi olmaktadır. Varsayılan olarak eşik değeri 0.4 olmakta ve azaltılarak hassasiyet arttırılabilmekte veya tersi şeklinde azaltılabilmektedir. Veri bankasına son hata tespitinin yapıldığı son eşik değerine ait veriler kayıtlı tutulur. Veri alanından tasarruf etmek amacıyla tüm hata tespit eşik değerlerine ait sonuçlar tutulmamaktadır. Bu işlemin süresi veri setindeki görüntü sayısına bağlı olarak değişmekte olsa da ortalama görüntü başına 0.05 saniye olmaktadır.

Her hata tespiti sonucunda her bir görüntü için dosya yolu olarak görüntüye ait dosya konumunun olduğu yerde görüntü dosyası ile aynı isimde bir txt dosyası oluşturulur. Bu dosya içinde her bir tespit işlemi ayrı satır olarak kaydedilir. Her bir satır bilgisinde sınıfa ait id, görüntü üzerinde merkez x koordinatı, merkez y koordinatı konumları ve tespit edilmiş alanın 2 boyutlu olarak genişlik ve yükseklik bilgileri yer alır (Şekil 4.5). Konum ve alan bilgisi normalize edilmiştir ve 0-1 aralığındadır. Sınıf bilgisi ise eğitime katılırken her bir sınıf için belirlenmiş id numarasıdır.

```
0 0.31587 0.538603 0.011642 0.023284  
3 0.259191 0.746324 0.011642 0.028595
```

Şekil 4.5 TXT dosyası

### 4.1.4. Model Eğitimi

Model eğitimi her bir sınıf için ayrı olarak ya da tüm sınıflar birleşik olarak yapılmaktadır. Eğitim başlamadan önce veri seti içerisinde rastgele olarak veriler yüzde 10 ve 90 olarak ayrılır. Yüzde 90 olan kısım model eğitim seti ve geri kalan yüzde 10 ise eğitimdeki modelin

başarısını ölçmek için test seti olarak kullanılacaktır. Eğer önceden bu eğitim işlemi için oluşturulmuş yani aynı sınıf için geçerli bir model var ise başlangıç modeli olarak alınır. Eğer ilk eğitim süreci ise herhangi bir eğitim modeli tercih edilebilir.

Eğitim sürecinin yarıda kesilmesi ya da bir sorun sonucu sonuçlanamaması sistemin çalışmasında bir sorun yaratmayacaktır. Eğitim süreci öncesinde geçerli olan modeller kullanılmaya devam edecektir. Ama model kendini geliştirememiş olacak ve bu süreci tekrarlamak isteyecektir. Bu öğrenen yapı süreç döngüsünde ayrıntılı bahsedilecektir.

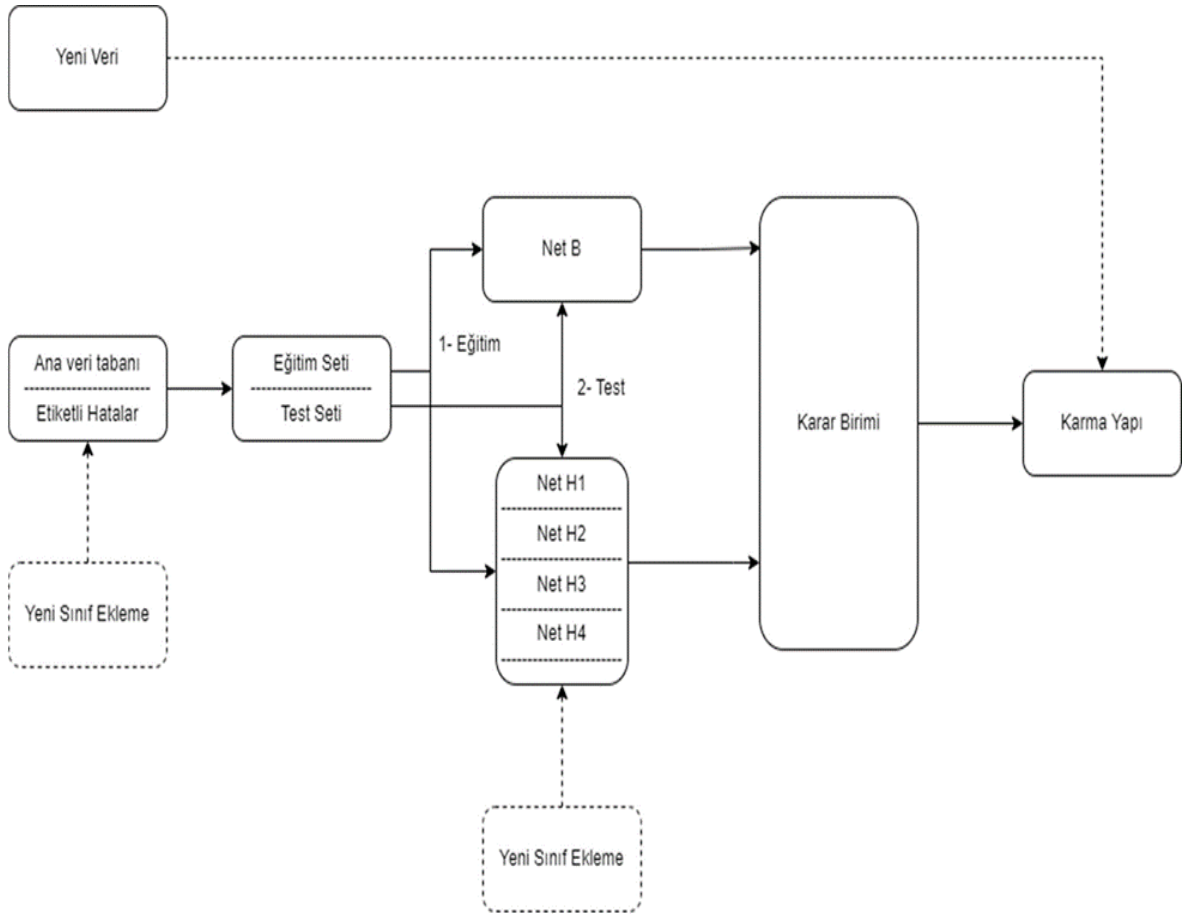
## **4.2. Öğrenen Sistem Tasarımı**

Öğrenen yapı sistemi için iki önemli adım bulunmaktadır. Hata tespitinde kullanılan modellerin eğitime süreklilik içinde devam etmesi ve kullanıcı tarafından alınan geri dönütlerin eğitime dahil edilmesidir. Aynı zamanda hata tespitinin iyileştirilmesi, sınıflar arasındaki veri sayısı farklılığından veya veri benzerliğinden dolayı oluşabilecek sorunlara önlem almak amacıyla ayrık ve bileşik modeller kullanılmaktadır. İlk olarak bu modeller hakkında bilgi verilecek, devamında eğitim süreci ve sürece kullanıcının dahil edilmesi anlatılacaktır.

### **4.2.1. Ayrık ve Bileşik Modeller ile Hata Tespit İyileştirmesi**

Hata tespitinde her bir sınıfın tespiti için iki farklı modelden faydalanılmaktadır. Bunlar; sadece o sınıfa ait veri seti ile eğitilmiş ayrık model ve sistemde bulunan tüm veri seti ve tüm sınıfların birlikte kullanılarak eğitildiği bileşik model olmaktadır. Şekil 4.6'da Net B bileşik modeli ve Net H1,2,3,4 ise ayrık modelleri temsil etmektedir. Hata tespitinde bu model dosyalarında hangisinin kullanılacağına karar verilmesi için modellerin eğitim sonrasında aynı test seti üzerindeki başarı oranı değerlerine bakılır ve karar biriminde yüksek başarı oranına sahip olan seçilir. Seçilen ayrık veya bileşik model karma yapının seçili hata sınıfı için geçerli modeli olur hata sınıfının hata tespiti için kullanılır. Bu seçme işlemi her hata tespit işlemi başında kontrol edilir. Çünkü her modelin eğitim işlemi sonucunda model ve

test seti deđiřecek, başarı oranları güncellenecektir. Ek olarak, eđer daha öncesinde hata tespiti yapılmıř bir görüntü setinde tekrar bir hata tespiti yapılacak olursa ve eřik deęeri aynı olarak sečilmiř olsa bile eđer bu iki hata tespitinin yapılma zamanları arasında bir model eđitimi gerçekleřmiř ise yeni hata tespitinde farklı model kullanılabilir. Bu da sonuçların deęiřmesine sebep olabilir. Ama daha güncel ve de yeni eklenmiř daha fazla doęru bilgilerin de dahil edildięi veriler ile eđitilmiř bir model kullanılacaęı için sonuçların iyileřmiř olması beklenmektedir. Sonuçların kötüye gitme durumunun sebebi ise son eklenmiř verilerdeki hatalı veriler olabilir veya yeni eklenmiř veriler model için çok farklı bilgiler içermekte olabilir ve zamanla eski verilere olan başarısını etkileyebilir. Bu durumda eski eđitilmiř modele dönülebilir, son veriler yeniden etiketlenebilir veya silinebilir ya da o sınıfa ait yeni ve daha fazla doęru veri eklenebilir.



řekil 4.6 Bileřik ve ayrıık aę yapısında eđitim ve karma sistem

#### 4.2.2. Model Eğitimi

Sistemi diğer benzer sistemlerden ayıran en önemli farklarından biri eğitimin sürekli bir döngü içinde ve kullanıcıdan bağımsız gerçekleşiyor olmasıdır. Bu sayede sistemde eğitim sonucunda oluşan ve hata tespit için de kullanılan modeller son bilgilere ve kullanıcı dönütlerine göre en güncel halde kalması sağlanır. Bu da sistemin kullanıcının beklentilerine daha iyi cevap vermesini sağlar.

Eğitim sonucunda oluşan eğitilmiş model her zaman eğitim işlemine girdi olarak kullanılmış tüm veri setine göre oluşacaktır. Bu sayede modeller her zaman veritabanındaki tüm verilerdeki bilgilerin toplamıdır. Sistemde başlangıçta var olan modeller ise ana veri seti yani geliştirme sürecinde toplanan veriler ile eğitilmiş modellerdir. Bu modellerin önceden geçerli sınıf için eğitilmiş olması her bir eğitim için gereken eğitim süresini azaltmaktadır. Çünkü son eğitime girdi olarak verilen bu önceden eğitilmiş modeller zaten belli bir başarı oranına sahiptir ve aslında bu eğitim süreçleri ile güncellenmektedir. Rastgele bir model ile yapılan eğitim 8 saate kadar sürebilirken önceden aynı sınıfa ait bir önceki eğitilmiş model ile yapılan eğitimde süre ortalama olarak 1 saate kadar inebilmektedir. Bu eğitim süresi tek bir sınıfın eğitimine ait süreçtir. Örneğin sistemde başlangıçta dört adet hata sınıfı var ise her bir sınıfın ayrı olarak dört ve tüm sınıfların birlikte eğitimi ile de bir adet eğitim süreci olacağı düşünüldüğünde yani toplamda beş adet eğitim süreci gerçekleşecektir. Eğitime başlangıç sırasında da önceden aynı sınıfa ait bir eğitim modeli kullanmak da bu süreyi kısaltarak bunu mümkün kılmaktadır. Eğitim süreci arka planda devam ederken kullanıcı sistemi kullanabilir. Bu da mümkün olan bir işlem olsa da sistemin kullanıldığı donanıma bağlı olarak sorunlar ortaya çıkabilmekte ve hata tespit işleminde veya eğitim işleminde işlemin yarıda bırakılmasına sebep olmaktadır.

Kullanıcı sistemi kullanırken eğitim süreci gerçekleşmesinden dolayı ortaya çıkabilecek sorunun temel sebebi donanımın bellek kapasitesinden kaynaklıdır. Proje kapsamında farklı bilgisayarlarda eğitim ve hata tespiti aynı anda paralel olarak gerçekleştirildiğinde veya sadece eğitim süreci tek başına çalışırken donanımın bellek kapasitesinin yeterli olmaması sebebiyle eğitim veya hata tespiti tamamlanamamıştır. Eğitim yapılmadığı takdirde düşük

bellekli donanımlarda hata tespiti için sorun çıkma olasılığı düşük olsa da eğitim sürecinde sorun olabilmektedir. Bu durumun da aslında bir eşik değeri veya limit, veri setine bağlı olarak değişebileceğinden bir kapasite tanımlamak tam olarak doğru olmayacaktır. Çünkü sisteme kayıtlı veriler, sınıf sayısı, anlık yapılan hata tespitine ait veri seti dahil birçok etken anlık bellek kapasitesinin kullanımına etki edecektir ve aşılmasına sebep olabilir. Bu duruma önlem olarak da eğitim sürecinin kullanıcının donanımı aktif olarak kullanmadığı saatlerde yapılması daha güvenli olmaktadır.

Tüm eğitimlerde de belirli koşullar sağlanmalı ve sonrasında da aynı döngü gerçekleşmelidir. Her bir eğitimin başlaması için veya herhangi bir hata sınıfının eğitime dahil edilebilmesi için veri bankasında o sınıfa ait yeterli sayıda veri bulunmalıdır. Yetersiz sayıda veri bulunması eğitimde yeterli öğrenme imkânı sunmayacaktır. Çünkü hem başarı oranı hesabı çok kısıtlı bir veri seti içinden yapılacak olup hem de eğitim için gerekli bilgilerin ayrışması yeterli olamayacaktır. Bu durumun önüne geçmek için sınıfa ait etiketli görüntü sayısı 100'ün üzerinde olmayan sınıflar hem sisteme sınıf olarak dahil edilmez hem de ayrı olarak veya bileşik olarak eğitime giremez. Bileşik eğitimde dahi veri olarak alınmaz. Yeterli veriye sahip olmayan sınıf sisteme dahil edilmese de veri bankasında kayıtlı kalır ve her eğitim süreci öncesinde yeterliliği kontrol edilir. Yeterli veriye sahip olmayan sınıf için de eğitilmiş bir model olmayacağından bir hata tespiti de gerçekleşmez. Eğer önceden var olan bir sınıf yeterliliğini kaybetmiş ise sistemde ayrı model olarak son model korunur ama bileşik model eğitime dahil edilmez. Bu sebeple bu sınıfa ait yine hata tespiti yapılmaz. Koşullar sağlandıktan sonra sınıfa ait önceki model var ise üzerinden eğitim başlar. Yok ise varsayılan olarak kayıtlı eğitim modeli üzerinden eğitim başlatılır.

### **Eğitim Düzeni**

Eğitim döngüsünde ilk eğitim bileşik eğitimidir ve arkasında her bir sınıf için ayrı eğitimler gelir. Bunun sebebi her ayrı eğitim sonucunda hesaplanan başarı oranı o sınıfın bileşik eğitim sonucundaki başarı oranı ile kıyaslanacak ve hata tespitinde hangi modelin kullanılacağına karar verilecektir. Başarı oranı yüksek olan tercih edilecektir. Eğitim sürecine girmiş her bir sınıf ve bileşik model için sadece bir önceki versiyonuna ait modelleri tutulur. Yapılan eğitim sonucunda da var olan önceki model silinir, güncel model önceki

model olarak kaydedilir ve eğitim sonucu oluşan yeni model ise güncel model olarak kaydedilir. Bu aşamada eğitim sonucu oluşan model hata tespiti için seçili model olur. Önceki model ile başarı oranı kıyası yapılmaz. Kullanıcı "Eğitim İşleri" ekranında önceki ve güncel iki modele ait de başarı oranlarını görebilir ve isterse bir önceki modeli seçili model olarak kaydedebilir. Kullanıcı bunu istediği zaman da değiştirebilir, istediği görüntü setlerinde hata tespiti yaparak test de edebilir. Çünkü modeller için hesaplanan başarı oranı rastgele seçilen bir test görüntü seti üzerinden yapılmaktadır ve görüntü sayısı arttıkça iken güvenilirliği artacaktır.

### Özel Toplanmış Veri ile Eğitim

Eğitim yaklaşımlarından ilki özel olarak toplanmış veri ile eğitimidir. Bu işlem sistem kullanıcıya sunulmadan önce geliştirme sürecinde yapılır. Önceden toplanmış veriler bileşik ve ayrıık olarak eğitilir. Bu ilk eğitim kabul edilebilir başarı oranları isterleri sağlayana kadar devam eder. Gerektiğinde veriler değiştirilir veya yenileri eklenir veya bazıları çıkarılır. Bu ilk eğitim sürecinde kullanılan en son veriler de veri bankasına eklenir ki yeni eğitim süreçleri yapıldığında bu verilerin sağladığı bilgiler kaybolmasın. Bu verilerin silinmemesi önemlidir. Çünkü isterleri sağlayan başarı oranlarının garantisi bu verilerdir. Bu veri seti veri bankasında ilk sırada yer alır (Şekil 4.7).

Veri Bankası							
Anahtar Kelime						Ara	Tamamı
Number	Card ID	Seri No	UDK	PN	Hatalar	Detaylı Gösterim	
0	0	0	0	0		Kaldır	
36	AELSAN	21-2323	123	00			
37	AELSAN	21-2323	123	00	- Eksik Lehim ...		
45	none	none	none	none	- Kalkmış ...		
48	none	none	none	none			
57	none	none	none	none	- Eksik Lehim ...		
59	none	none	none	none	- Eksik Lehim ...		
60	id	none	none	none	- Kalkmış ...		
61	id	none	none	none	- Kalkmış ...		
62	id	none	none	none			
63	id	none	none	none	- Kalkmış ...		
65	ID5	PWR	TST	56	- Eksik Lehim ...		

Listelenenler

- Eksik Lehim Hatası
- Kalkmış Komponent Hatası
- Kaymış Komponent Hatası
- Kısa Devre Hatası
- Tüm Hatalar

Güncelle

Şekil 4.7 Önceden toplanmış veri seti

### **Planlı Eğitimler**

Diğer bir eğitim yaklaşımı ise sistem tarafından yapılan planlı eğitimlerdir. Bu eğitimler kullanıcı kontrolü dışında gerçekleşir ve eğitime girme koşulunu sağlayan sınıflar için başlatılır. Her bir görüntü seti kaydedildiğinde herhangi bir sınıfın eğitim koşullarını sağlayıp sağlamadığı kontrol edilir ve eğitim yapılmasına karar verilirse kullanıcıya bildirim olarak görünür. Bu noktada kullanıcıdan donanımı belirlenmiş saatler içinde aktif bırakması ve kullanmaması istenir. Tahmini eğitim süresi de bildirilir. Bu eğitim süresi önceki eğitimlere göre ortalama bir tahmin olacaktır. Planlı eğitimde tüm sınıflar aynı anda eğitime girmek zorunda değildir. Önceden bahsedildiği sınıfın eğitime girebilmesi yeterli veri sayısına sahip olması gerekirken yeniden eğitime girebilmesi içinse ayrıca da veri sayısında yeterli artışın sağlanmış olması gerekir. Bunun için var olan tüm veri bankası taranır. Görüntü setlerinden toplanan sınıf verilerinin toplamda önceki duruma göre yüzde 10 oranında bir artış sağlamış olması gerekir. Yeterli bilgi toplandığına emin olunması gerekir. Koşulları sağlamış her sınıf için eğitim süreci başlar. İlk olarak tüm veriler ile bileşik eğitim başlar ve sonrasında yeterlilik sağlayan sınıflar eğitilir. Önceden bahsedildiği gibi başarı oranları hesaplanır ve kıyaslanır. Sınıf eğitime girmemiş olsa bile bileşik model eğitime girmiş ise başarı kıyaslamasına girer ve duruma göre bileşik model ve sınıfın ayrık modeli arasında seçim yapılır. Planlı eğitimler öğrenen yapının temelini oluşturmaktadır ve süreklilik içinde olmalıdır.

### **Anlık Eğitimler**

Son eğitim yaklaşımı ise sistemde kullanıcı kontrollü olarak anlık eğitim başlatılmasıdır. Kullanıcı istediği zamanda arayüz üzerinden anlık eğitim başlatabilir ve bu eğitim istendiğinde sadece tek bir sınıf için veya tüm sınıflar için olabilir. Bu eğitim için de koşul olan yeterli sayıda verinin bulunma durumu geçerlidir. Bu koşul sağlanması sonrasında eğitim seçili sınıfa ait ayrık ve bileşik model için başlar. Planlı eğitimde bahsedildiği üzere bileşik eğitim gerçekleşme durumunda tüm sınıflar için bileşik ve ayrık modeller arasında başarı kıyaslaması tekrar yapılır. Anlık eğitim metodu istediği her an yapılabildiğinden veri artışı koşulu aranmaz. Bu işlem için dikkat edilmesi gereken durum her eğitim sonucunda sadece bir önceki model ve yeni model tutulmaktadır.

### **Model Başarı Oranı Hesabı**

Eğitimler yapıldıktan sonra hesaplanan başarı oranı test seti olarak eğitim öncesinde ayrılmış etiketli veri seti üzerindeki hata tespit sonuçlarının doğruluğunun oranıdır. Bu karşılaştırmada test veri setinin etiketlerini koordinatları ve yeni eğitilmiş model ile yapılan hata tespiti sonucundaki etiketlerin koordinatları karşılaştırılır. Koordinatlar karşılaştırılırken bir miktar hata payına kadar doğru kabul edilir. Test veri seti tamamen rastgele oluşmaktadır ve eğitim veri setine dahil edilmemektedir. Bu durum başarı oranının daha genele göre hesaplanmasını sağlamaktadır.

### **Görülen Durumlar ve Dikkat Edilmesi Gereken Hususlar**

- Modeller için hesaplanan başarı oranı veri tabanından rastgele seçilen görüntü setleri üzerinden yapılmaktadır. Bu seçili sınıf için toplam verilerin onda biridir. Veri sayısının azlığı hem her eğitim sonrası eğitim verisi aynı olsa bile başarı oranında fazla oynamalara hem de başarı oranın genele değil de o anlık test veri setinde bulunan verilere göre olmasına sebep olabilir. Bu sebeple veri sayısı arttıkça başarı oranındaki oynamalar azalacaktır. Veri sayısının artması başarı oranını artıracaktır ama buradaki oynama ile anlatılmak istenen aynı ya da çok benzer veri seti ile girilen eğitimlerdeki başarı oranındaki değişimdir. Kullanıcının aynı veri seti ile tekrar eğitim başlatıp yüksek başarı oranı görmeye çalışmasının çok anlamlı olmadığı anlatılmak istenmiştir.
- Anlık eğitimler eğer yeterli değişim sağlanmadan yapılırsa eğitim öncesinde var olan önceki model kaybedilecektir. Bu eğitim yaklaşımının sisteme veri bankasında bulunan verilere yeni ve farklı veriler eklendiğinde veya hatalı verilerden sistemden çıkarıldığında yapılması tavsiye edilir. Dikkat edilmesi gereken bir diğer husus ise anlık eğitimler her yapıldığında eğitim ve test veri seti var olan veri bankasında rastgele olarak oluşturulduğundan art arda yapılan eğitimler arasında başarı oranlarında değişimler gözlenebilir. Bu değişim veri sayısının az olması durumunda daha fazla olacaktır. Eğer bu anlık eğitimler öncesinde yeterli sayıda yeni veri sağlanmadıysa yeni eğitilmiş bu modellere daha başarılı veya başarısız demek doğru olmaz. Buradaki başarı oranlarındaki değişikliğin bir sebebi eğer sınıfa ait toplam veri sayısı az ise test



setindeki deęişkenlik olabilir. Ya da yeterli yeni veri eklenmemişse sadece test ve eğitim seti arasındaki anlık deęişkenliklerden kaynaklı küçük oynamalar olabilir.

- Bir sınıfa ait yeterli çeşitlilik yok ise yani veri sayısı yeterli olsa dahi verilerde benzerlięi yüksek hatta aynı sayılabilecek oran fazla ise test setinin başarısı yanıltıcı olabilmektedir. Çünkü bu durumda aynı sayılabilecek veriler hem eğitim setine hem de test veri setinde yer almış olabilir. Bu durumda aslında model o sınıfın tespitinde başarılı olsaydı o sınıfın belirli verileri üzerinde ezberleme yapmış olabilir. Bu sebeple veri setinde özellikle aynı sayılabilecek görüntülerin bulundurulması tavsiye edilmez. Bu duruma geliştirme sürecinde veri sayısı az olduęu durumda denk gelinmiştir. Ama veri sayısı arttıkça bu durum gözlemlenmemiştir. Güncel kullanılan sistemde bu durum için olumsuz bir dönüş olmamıştır. Ama aynı verilerin sürekli kaydedilmeye başlanması bu soruna sebep olabilir. Eğer gerekli olursa sisteme eklemek için bir çözüm düşünülmüş ama uygulanmamıştır. Çözüm her görüntü seti alındığında verileri sınıflara ait olarak etiketlemenin yanında sınıf içinde tip etiketlemesi yapmak olacaktır. Örneğin kullanıcı benzer olarak düşündüğü hataları aynı tip ile etiketleyebilir. Yeni hatalar için yeni tipler tanımlayabilir. Ve de eğitim aşamasında veriler eğitim ve test veri seti olarak ayrılırken toplam veri seti içinde rastgele ayrılması yerine her bir etiketin tiplerine göre de eşit dağılım sağlanacak ve sonrasında rastgele yüzde 90 ve 10 olarak ayrılacaktır.

#### **4.2.3. Öğrenen Yapı ile Hata Tespit İyileştirilmesi**

Sistemin temeli eğitimin süreklilięinin sağlanmasına dayanmaktadır. Bu sayede yeni veriler ile öğrenen yapı kurulmuş olur. Her bir görüntü seti sisteme bilgi sağlar. Bilgiler ise eğitim sonucu oluşan modellerin geliştirilmesi için kullanılır. Her yeni görüntü setinin de veri bankasına kaydedilmesi kullanıcı kararıdır. Sistemin kendini eğitebilmesi ve öğrenen yapının süreklilięi için görüntü seti kaydetmek önemlidir. Özellikle var olan görüntü setlerinden farklı yeni görüntü setleri eklemek sisteme daha çok fayda sağlayacaktır. Sisteme yeni eklenen görüntü setleri sistemde bulunan güncel modeller kullanılarak etiketlenir. Bu

etiketleme işleminde sistemde bulunan güncel modeller ile hata tespit algoritması kullanılır. Bu etiketleme sonucunda yüzde yüz doğruluk yoktur. Bunun sebebi modeller ne kadar çok ve de doğru veri ile eğitilse de bir hata payı her zaman olacaktır. Dolayısıyla hata tespiti sonucu etiketlemeler güncel modelin başarısına bağlı olarak değişebilir. Çıkan sonuçta eksik veya hatalı tespitler bulunabilir. Bu eksik veya hatalı verilerin bilgisinin sisteme bildirilmesi gerekir ve bu noktada da çevrime kullanıcı dahil edilir.

### **Yanlış veya Eksik Etiketlerin Düzenlenmesi**

“Veri Etiketleme Ekranı” sayfasında hata tespiti sonucunda eksik veya yanlış oluşmuş etiketlerin silinmesi ve eklenmesi mümkündür. Etiketli bir görüntü üzerinde etiket düzenleme yapıldıktan sonra düzenlemeler için ön izleme sunulur ve bu yapılan düzenleme ile ne yapılmak istediğine karar verilir. Seçenek olarak bu görüntü eğitim veri setine veya sadece veri bankasına eklenebilir veya işlem iptal edilebilir. Eğitim veri setine eklendiğinde ileride bu düzenleme ile eğitim modelleri oluşturulabilir ve algoritma sonraki tespitlerde daha başarılı sonuçlar verebilir.

### **Eğitimde Yeni Verilerin Etkisi**

Sistemin geliştirilme sürecindeki veri seti ne kadar genel ve kapsayıcı olması istense de tüm verileri elde etmek gerçekçi olmamaktadır. Öğrenen yapının en büyük getirisi de daha önce veri bankasında var olmayan veri setlerini sadece eskilere bağlı olarak tespit etmeye çalışmak yerine kendini veri bankasına eklenen yeni veriler ile de eğiterek öğrenmenin sürekli kılınmasıdır. Bu sayede bilinmeyen veriler zamanla bilinebilen olmaya başlayacaktır ve hala bilinmeyen verilerin tespitindeki başarı oranı artacaktır. Çünkü bu yeni eklenmiş olan görüntü setlerinde var olan bilgiler ile modellerin eğitilmesi sonucunda daha ayırt edici bilgiler kazanılacak ve hata tespitinde kullanılacaktır.

### **Çevrimde Kullanıcı**

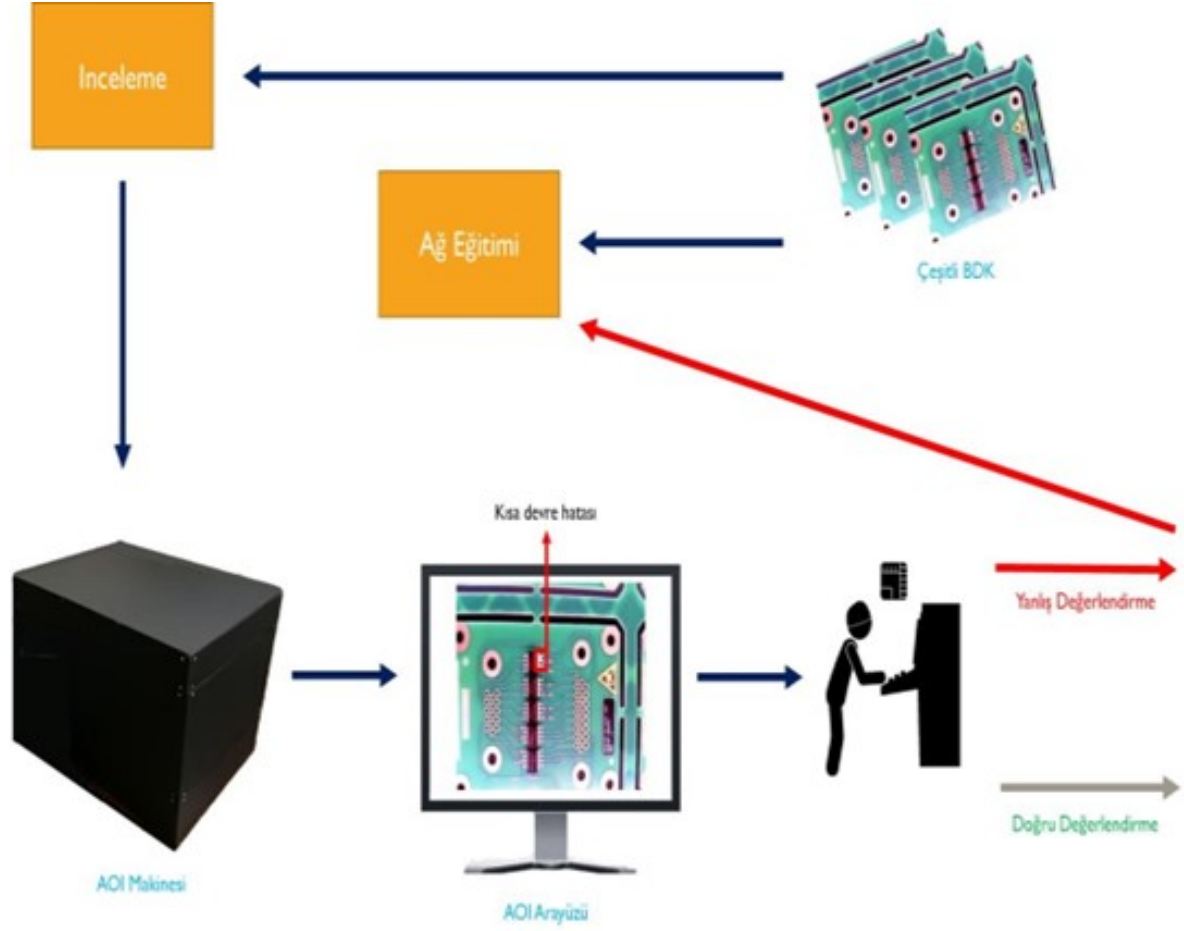
Sistemde yeni eklenen görüntü setlerinin etiketlerinin doğruluğu kesin değildir. Ama yine de bu yeni veriler aynı zamanda sistemde modellerin eğitilmesi için de kullanılması gerekmektedir. Bu sebeple öncelikle etiketlemenin doğruluğunun teyit edilmesi gerekir. Bu noktada sistem döngüsüne kullanıcı da dahil edilir. Kullanıcı her bir görüntü seti alınması

sonrasında güncel modeller ile yapılan hata tespit sonucunu inceler ve her etiketlemenin doğruluğunu onaylar. Buradaki onayda hatalı veya eksik etiketlemeleri kullanıcı düzenler. Hatalı etiketlemeleri siler veya eksik etiketleme var ise gerekli etiketlemeyi kendisi ekler. Bu da verilerin doğruluğunu ya da aslında sistemin kullanıcı isterleri doğrultusunda ilerlemesini sağlar. Sistem ne kadar geliştirilme aşamasında oluşturulan veri setine bağlı olarak başlamış olacağına da kullanıcının bu görüntü setlerini sisteme eklemeye devam etmesi ile zamanla daha çok kullanıcının dönütlerine daha bağımlı olacaktır. Zamanla da hata tespit sonuçları kullanıcı isterlerine daha çok yaklaşacak ve etiketlemeler üzerindeki düzenleme ihtiyacı azalacaktır veya hiç olmayacaktır. Hata tespiti için başta sağlanmış olan modellerin başarısının yüzde 77.77'nin üzerindedir. Yani zaten sonuçlar belirli veri seti üzerinde isterler doğrultusunda doğruluk sunmaktadır. Buradaki temel amaç özellikle veri bankasında bulunmayan görüntüler için başarı oranını arttırmaktır. Geliştirmeler ile var olan görüntüler için de başarı oranı artacaktır.


Öğrenen yapı döngüsü sürekli olarak her görüntü seti veri bankasına kaydedildiğinde gerçekleşecektir. Öğrenen yapı döngüsü sistem sürekli olarak devam edecektir. Bu durumun kullanıcı tarafından durdurulması mümkün değildir. Sistem kullanıldığı süre boyunca yeni veri kaydedilmez ise yeni bilgiler sağlanmadığı için eğitim süreci devam etmeyecek ve hata tespiti sonucu etiketlemeleri değişmeyecektir.

Öğrenen yapı cihazın sonuçlarını değerlendiren kullanıcının görüşlerini de eğitim sisteminin içine alacak şekilde kurgulanmıştır. Şekil 4.8 alınan bir görüntünün hata tespitine sokulması gösterilmektedir. Sonuçlarda var olması gereken bir hatanın etiketinin eksik olduğu kullanıcı tarafından fark edilir ve eksik etiketleme kullanıcı tarafından eklenir (Şekil 4.9). Yeni veri veri bankasına kaydedilir ve sonraki model eğitiminde kullanılır. Şekil 4.10'da ise kullanıcı tarafından kaydedilmiş veri ile eğitilmiş yeni model bu sefer önceden tespit edemediği hatayı bulabilir hale gelmiştir. Model yeni bilgiler ile kendini geliştirmiş ve öğrenme sürekli kılınmıştır. Bütün döngünün BDK taranmasından eğitim ile yeni modeller oluşmasına kadar olan genel yapısı Şekil 4.11'de verilmektedir. Bu yapı döngü şeklinde olup sistem çalıştığı sürece devam edecektir. Sistemde yapay zekâ yordamları hata bulma üzerine sonuç

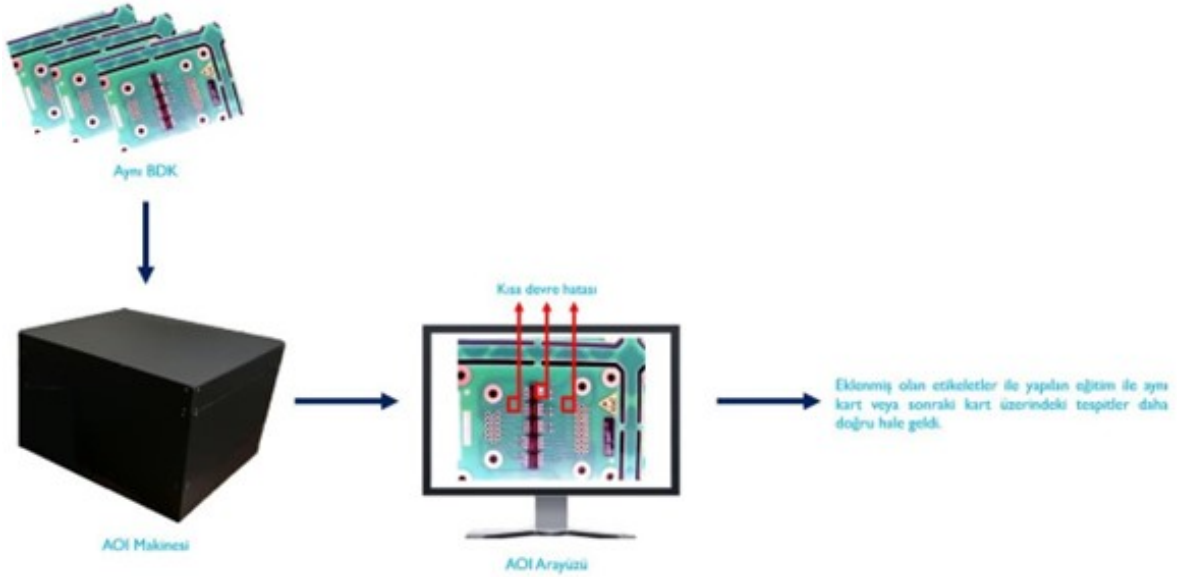
üretmekte ve uzman bu sonuçları değerlendirerek etiketleme yapabilmekte ve bunu sisteme geri besleme olarak verilmektedir.



Şekil 4.8 Öğrenen yapı içinde çevrimde kullanıcının rolü



Şekil 4.9 Çevrimde kullanıcı gösterimi



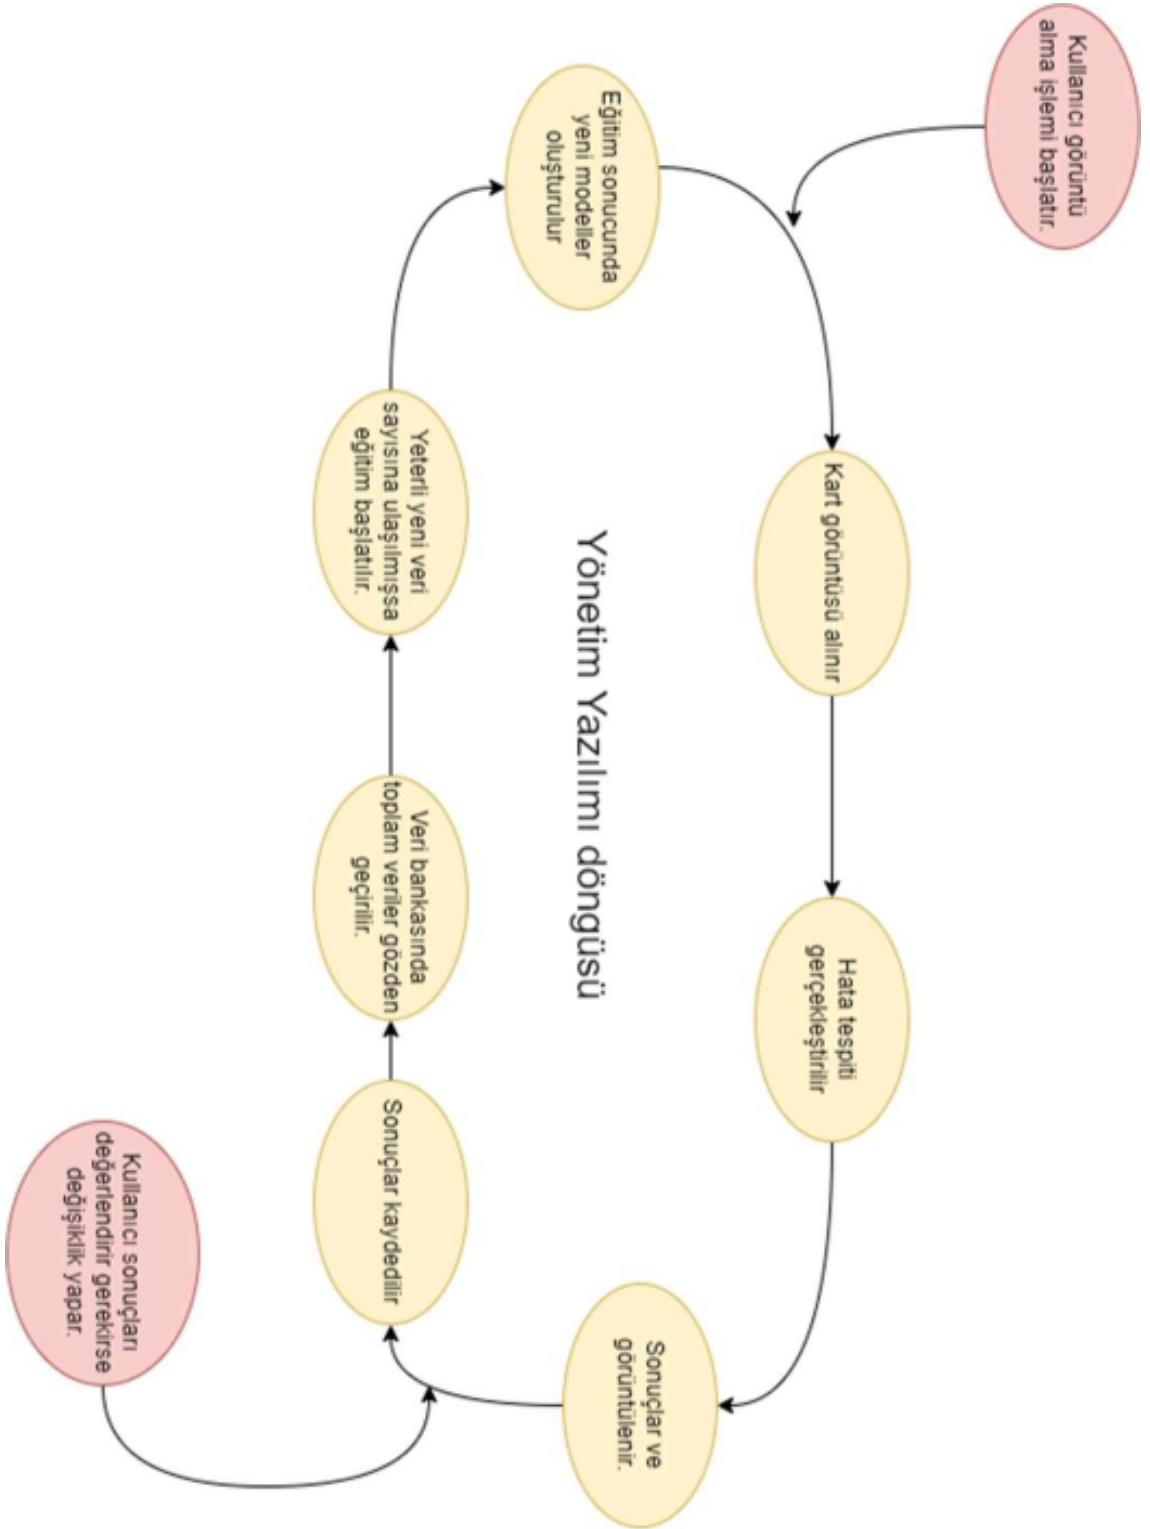
Şekil 4.10 Öğrenen yapı ile hata tespitinde iyileşme

Tüm sistem döngüsü özetlenirse kaydedilen kart görüntülerinin veri tabanında düzenlenmesi, hata tespit algoritması ile hataların tespit edilmesi, verilerin etiketlerinin düzenlenmesi ve eğitim ağlarının eğitilmesi, geliştirilmesi olmaktadır. Bu yapıda:

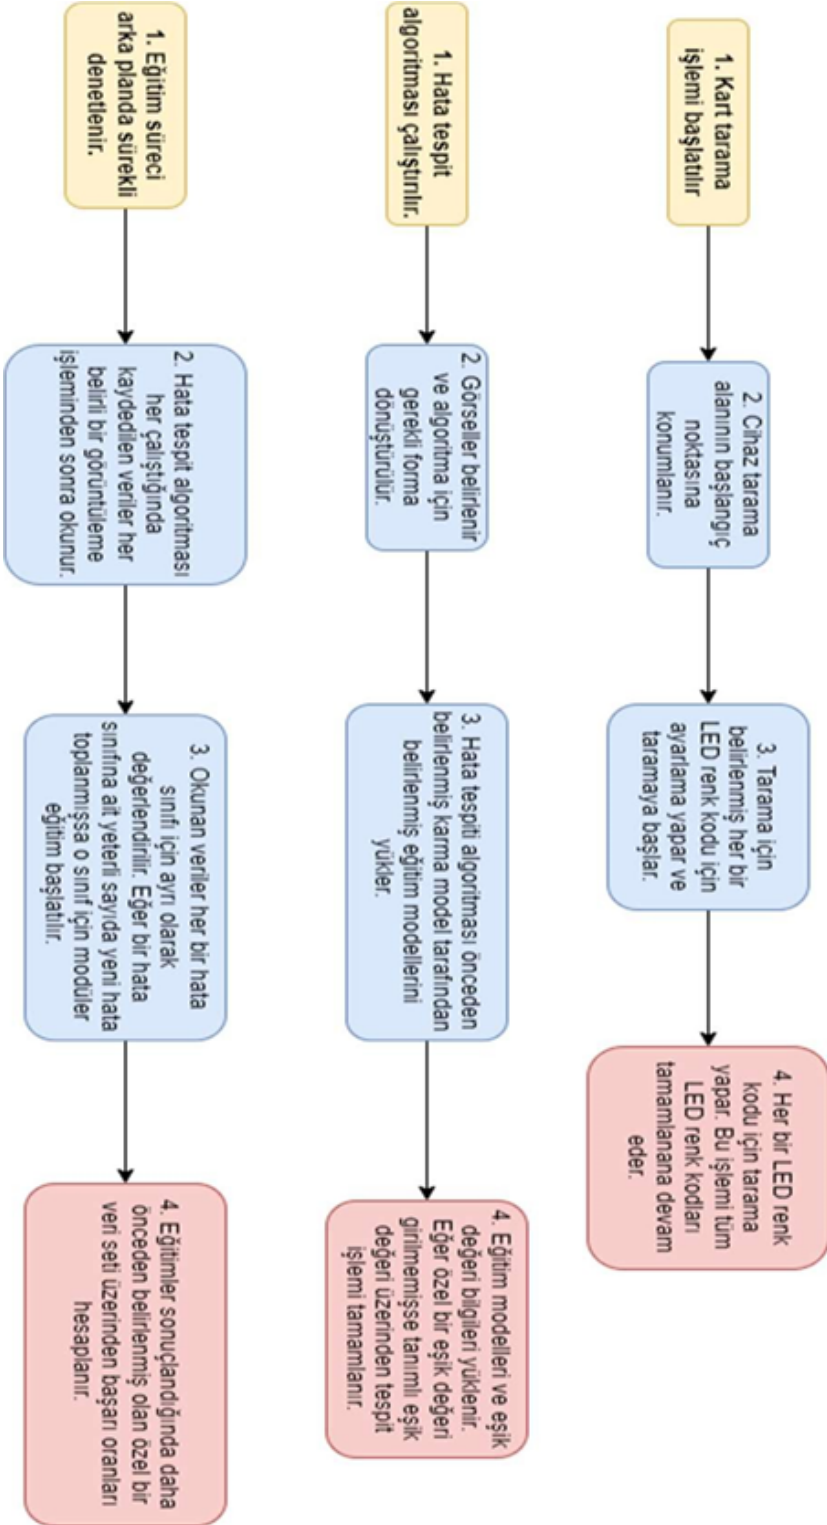
- Kart tarama sonucu kaydedilen görüntüler üzerinde hata tespiti yapılabilir.

- Veriler üzerinde etiketler oluşturulabilir, düzenlenebilir veya silinebilir.
- Veri tabanına veriler kaydedilir, görüntülenebilir ve düzenlenebilir.
- Eğitim modelleri yeni veriler ile eğitilip başarı oranı daha yüksek eğitim modelleri oluşturabilir

Sistem yazılımları gerçekleştirilirken Şekil 4.11’de gösterilen çevrim ve Şekil 4.12’de gösterilen ardışıl görevlendirme işlevlerine dikkat edilmiştir.



Şekil 4.11 Yönetim yazılım döngüsü



Şekil 4.12 Yazılımda önemli görevlerin ardışıl blokları



## 5. DENEYSEL SONUÇLAR

### 5.1. Hata Tespiti Başarı Oranları - TEST 1

Yapılacak testler için bileşik ve ayrık yöntemde eğitimler ve testler yapılmadan önce veri tabanı düzenlenmiştir. Bu bağlamda 7793 hatalı veri etiketlenmiştir. Bu hatalı verilerin 2015'i kısa devre hatası, 2827'si kaymış devre elemanı hatası, 1961'i kalkmış devre elemanı hatası ve 990 tanesi eksik lehim hatasıdır. Toplam 52 adet PCB kartının her birinde bu hata türleri birden fazla ve karışık olarak bulunabilmektedir. Bunun yanı sıra, derin öğrenme uygulamalarının bizlere sunduğu özelliklerden veri çoklama, gürültü ekleme, kaydırma, döndürme, karartma ve soldurma gibi işlemler ile veri tabanındaki veri sayısı yükseltilmektedir. Bileşik yöntemde eğitimler 7-9 saat aralığında sürmekte iken bu sayı ayrık yöntemde 3 saate inmektedir. Bu eğitimler ilk eğitim süreçleri olması sebebiyle normalden uzun sürmektedir. Eğitimde 214 katman kullanılmıştır, öğrenme hızı 0.01, momentum 0.937, batch boyutu 32, maks iterasyon sayısı 300, görüntü boyutları 416x416 piksel olmaktadır. Eşik değeri 0.1 ve 0.4 için başarı oranı (B.O), doğru pozitif (D.P) ve yanlış pozitif (Y.P) verileri Tablo 5.1 ve 5.2'de gösterilmiştir. Başarı oranları bileşik veya ayrık yöntemlerde ve farklı eşik değerlerinde yüzde 64.44 ile 97.64 arasında değişmektedir. En düşük hata tespit başarı oranı 0.4 eşik değerinde kaymış devre elemanı olsa da bileşik ve ayrık yöntem arasında hata tespiti için model tercihi yapılacağından yüzde 64.44 ile yüksek başarı oranına sahip olan ayrık yöntem tercih edilecektir.

Table 5.1 TEST 1 - Eşik Değeri 0.1 için Başarı Oranları

EŞİK DEĞER 0.1	BİLEŞİK YÖNTEM			AYRIK YÖNTEM		
	D.P	Y.P	B.O	D.P	Y.P	B.O
HATA TÜRÜ						
KISA DEVRE	83	5	%97.64	61	17	%71.76
KAYMIŞ DEVRE ELEMANI	61	13	%67.77	70	23	%77.77
KALKMIŞ DEVRE ELEMANI	142	18	%94.66	128	17	%85.33
EKSİK LEHİM	22	2	%84.61	24	2	%92.30
<b>GENEL BAŞARI ORANI</b>	308	38	%86.17	283	59	%81.79

Table 5.2 TEST 1 - Eşik Değeri 0.4 için Başarı Oranları

EŞİK DEĞER 0.4	BİLEŞİK YÖNTEM			AYRIK YÖNTEM		
	D.P	Y.P	B.O	D.P	Y.P	B.O
HATA TÜRÜ						
KISA DEVRE	60	0	%70.58	43	0	%50.58
KAYMIŞ DEVRE ELEMANI	51	1	%56.66	58	0	%64.44
KALKMIŞ DEVRE ELEMANI	106	4	%70.66	96	0	%64.00
EKSİK LEHİM	15	0	%61.53	21	0	%80.76
<b>GENEL BAŞARI ORANI</b>	232	5	%64.85	218	0	%64.94


## 5.2. Ayırık ve Bileşik Model Karşılaştırması - TEST 1

Bileşik yöntemde veri setleri güncellenmek istendiği zaman tüm veri sınıflarının da güncellenmesi gerekmektedir. Çünkü ağırlık dosyaları ve veri sınıfları ayırık yöntemde

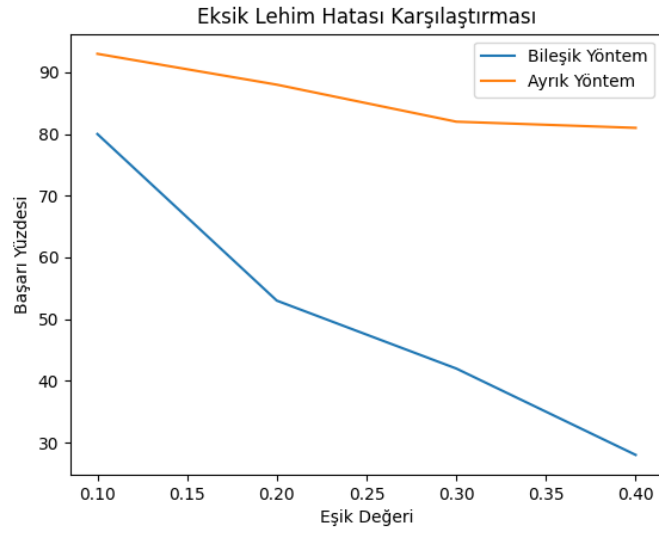
olduđu gibi ayrıştırılmamıştır. Bileşik yöntemde yeniden eğitim ve güncelleme durumları ayrıık yöntemde göre bu sebepten dolayı daha uzun sürmektedir. Ayrıık yöntemde veri sınıflarının ayrılması, hata türü kadar ağırlık dosyası oluştururken bileşik yöntemde yalnızca tek model oluşturulur. Bunun yanı sıra, ayrıık yöntemde sınıflar ayrıldığı için her bir eğitimde daha az görüntü kullanılır ve bu da görüntü başına kullanılan iterasyon sayısını artırır. Bu ise başarı oranını doğrudan etkiler.

Bir başka test veri kümesi için yapılan testte ise sonuçlar deđişmektedir. Bu veri seti de hiç eğitime sokulmamış verilerden oluşmakta olup, 30 kart görüntüsü üzerinden hazırlanmıştır ve toplam hata sayıları şu şekildedir: 85 kısa devre hata sayısı, 90 kaymış devre elemanı hata sayısı, 150 kalkmış devre elemanı sayısı, ve 26 eksik lehim sayısı. Bileşik ve ayrıık yöntem ile gerçekleştirilen eğitimler test edilmiş.

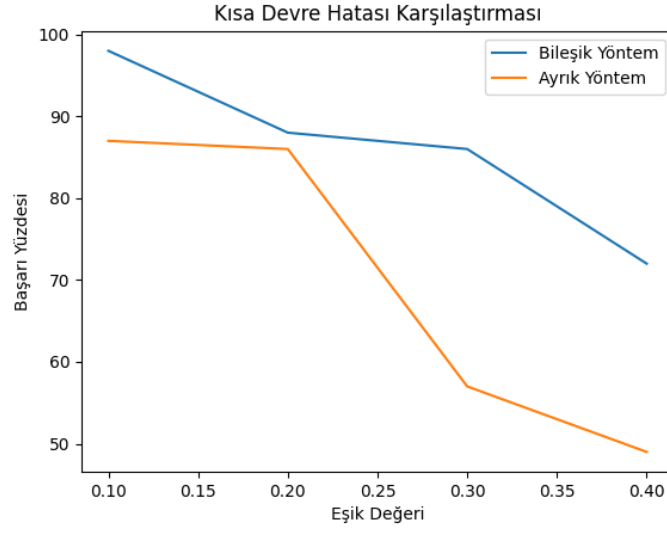
Bu tablolarda eğitim yaklaşımları 0.1 ve 0.4 eşik deđerleri üzerinden karşılaştırılmıştır (Şekil 5.1 5.2 5.3 5.4). Farklı eşik deđerlerinde bileşik ve ayrıık eğitimin başarı yüzdeleri arasındaki fark önemli deđişiklikler göstermektedir. Eşik deđerinin deđiřmesi başarı oranını doğal olarak etkilemektedir ve bu yüzden tablolar eşik deđerinin başarı yüzdesi üzerindeki etkisini de göstermektedir. Eşik deđeri yükseltildiğinde yanlış pozitif ve başarı oranları düşmektedir. Eşik deđeri düşürüldüğünde ise yanlış pozitif ve başarı oranı artmaktadır. Bu veri setinin test sonuçlarında ise başarı oranları kıyaslandığında kısa devre, kalkmış devre elemanı ve kaymış devre elemanı hatalarının ayrıık yöntemde geride kalırken, eksik lehim hatasının ayrıık yöntemde daha başarılı bir şekilde tespit edilmektedir. Sonuçlar karşılaştırıldığında, karışma olasılıkları bulunan hataların ayrıık yöntemle eğitilmesi tabanlı karma bir sistemin sınıflandırıcı kurgusuna katılmasının yararlı olduđu anlaşılmaktadır. Bu veri seti için geçerli bu gözlem veri sayısı artırıldıkça ađların farklı kombinasyonları ile daha iyi sonuçlar alınabileceđi öngörülmektedir. Deđişen veri seti bileşik ve ayrıık yöntem arasında bu sefer daha farklı sonuçlar vermiş olsa da iki modeli aynı anda kullanmanın gün sonunda başarıyı arttıracakđı görülebilmektedir.




Şekil 5.1 TEST 2 - Kalkmış devre elemanı hatası karşılaştırması



Şekil 5.2 TEST 2 - Eksik lehim hatası karşılaştırması



Şekil 5.3 TEST 2 - Kısa devre hatası karşılaştırması

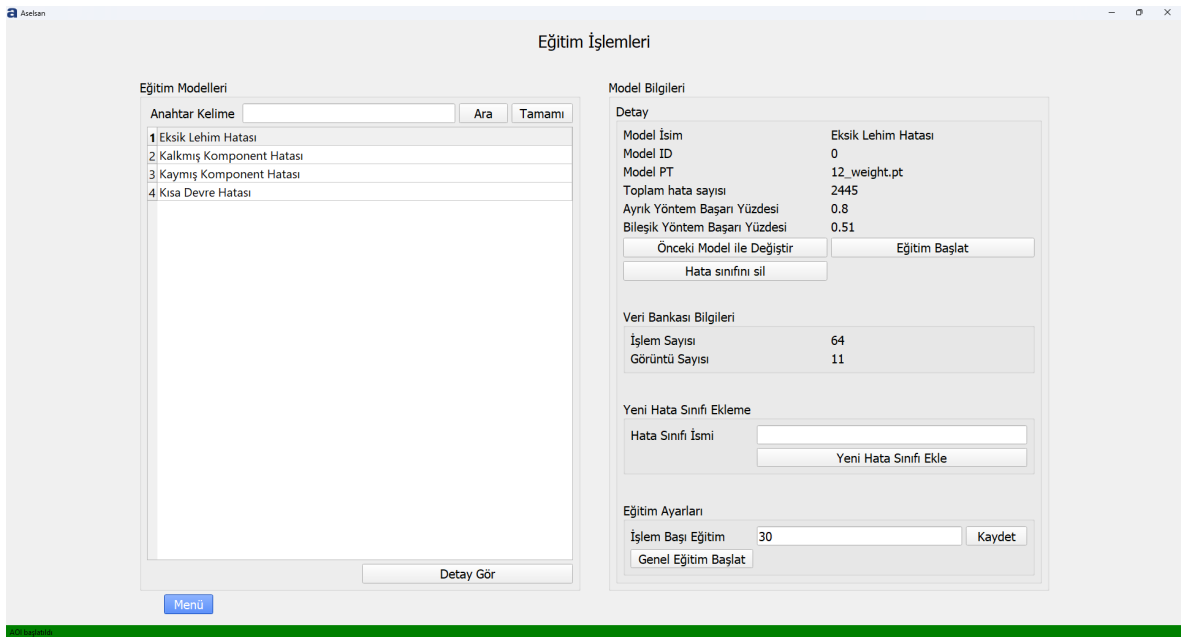


Şekil 5.4 TEST 2 - Kaymış devre elemanı hatası karşılaştırması

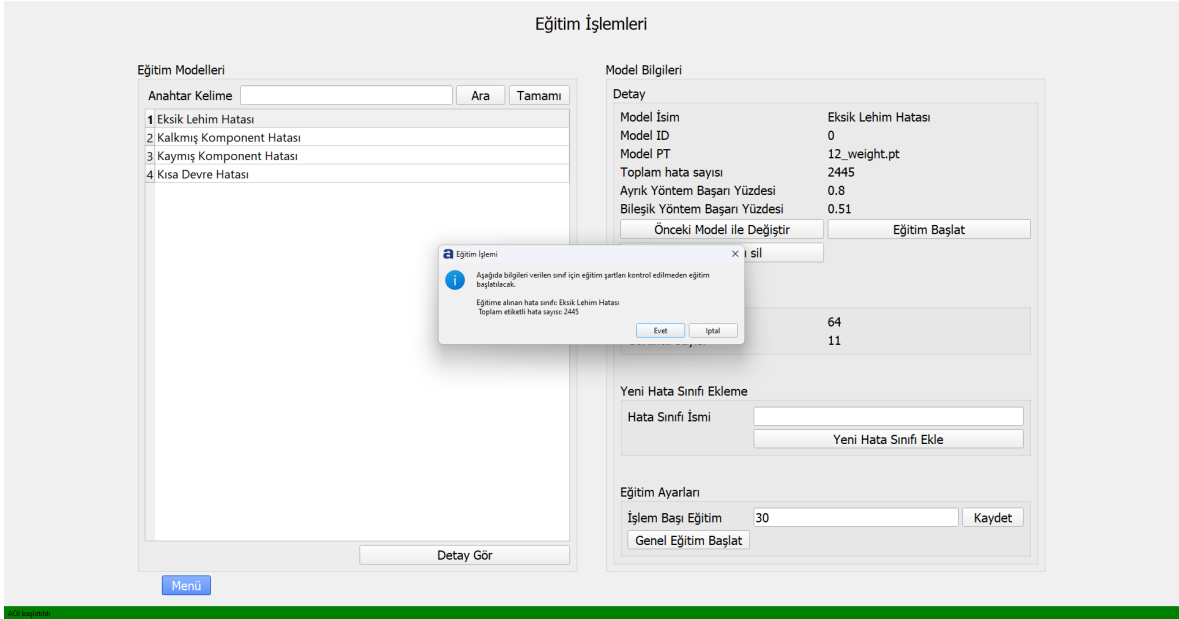
### 5.3. Eğitim İşlemi

Kullanıcı tarafından başlatılan veya planlı gerçekleşen eğitimler ile modeller güncellenmektedir. Şekil 5.5'te görülen "Eğitim işlemleri" ekranında kullanıcı tarafından bir hata sınıfı seçilip o sınıf için eğitim başlatılabilir. Şekil 5.6'da eksik lehim hata sınıfı

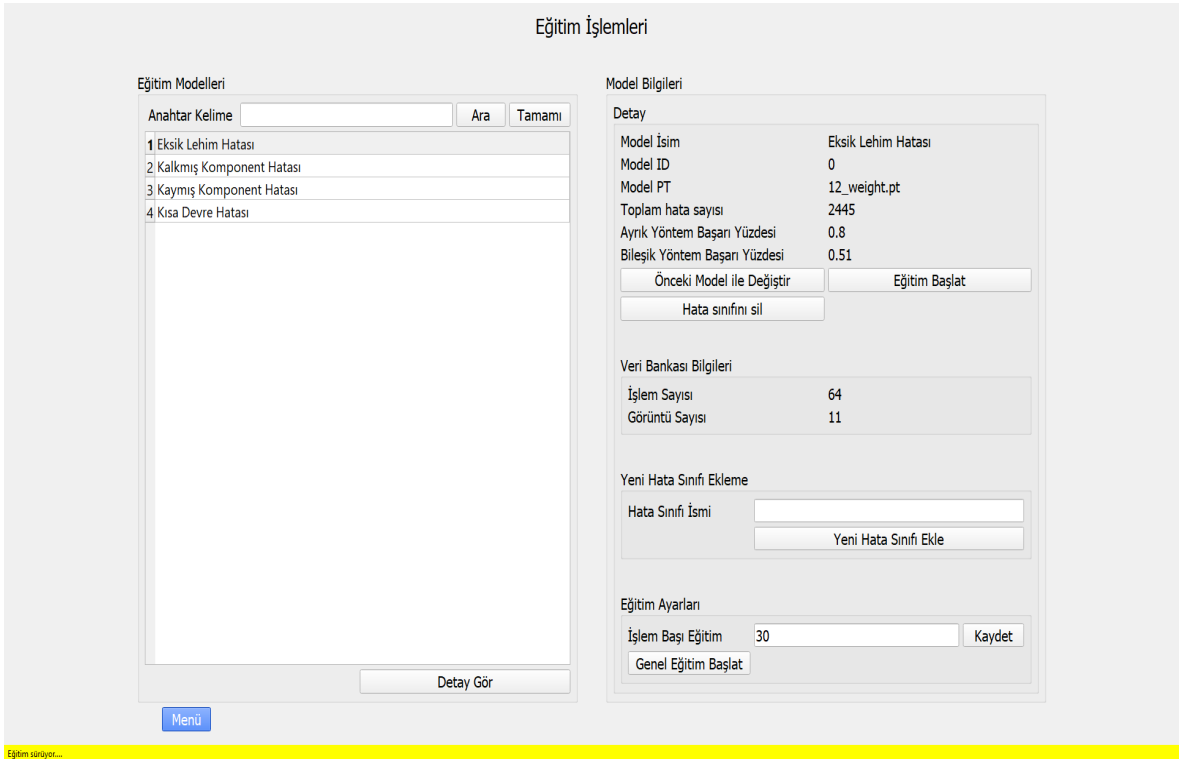
için bir eğitim başlatılmaktadır. Eğitim başlamadan önce kullanıcıya yapmak istediği işlem hakkında bilgi verilir ve onayı istenir. Sonrasında başlatılan eğitim süreci arka planda başlar ve arayüzün en altında bulunan durum çubuğunda süreç bilgisi paylaşılır. Şekil 5.7'de durum çubuğunda eğitim sürecinin sürdüğü bilgisi ve Şekil 5.8'de ise eğitim sonuçlandığını bildirilmektedir. Ayrıca Şekil 5.8'de eğitim sonrasında eksik lehim sınıfının modeli '13\_weight.pt' olarak güncellenmiştir. Başarı oranları ise ayrık modelde 0.80'den 0.85'e ve bileşik modelde 0.51'den 0.57'ye yükseldiği görülmektedir.



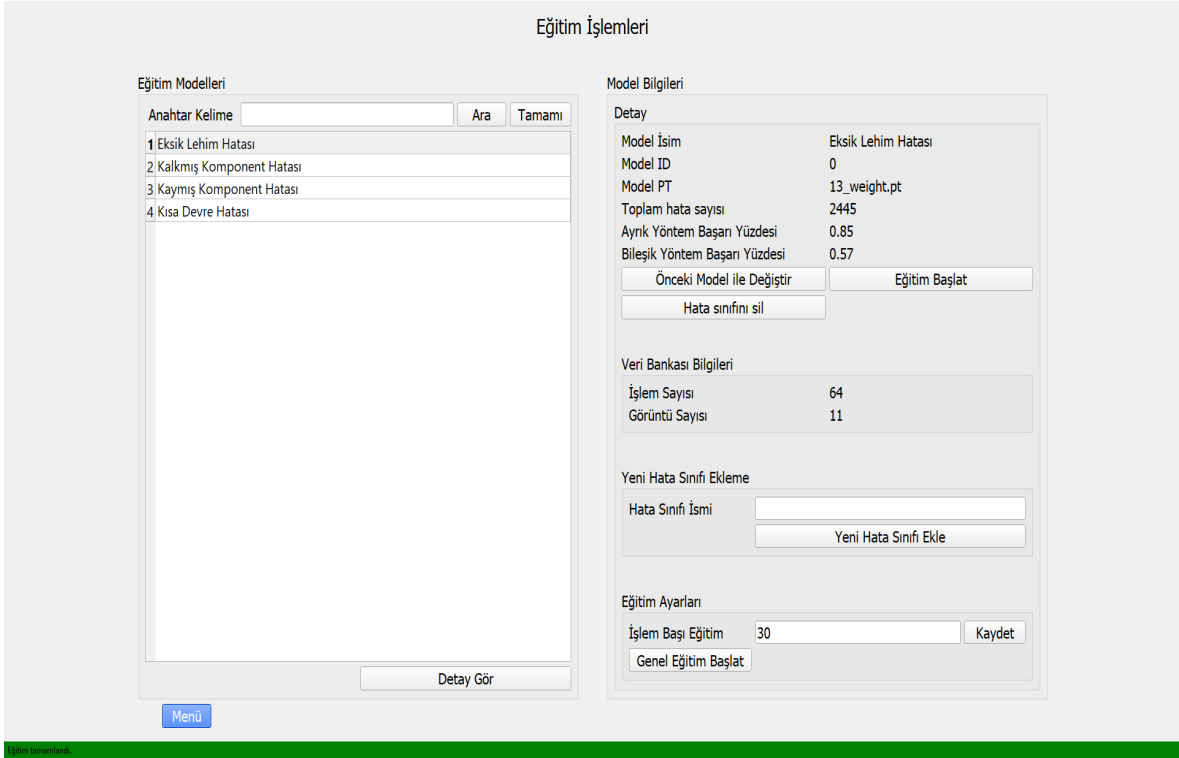
Şekil 5.5 Eğitim işlemleri ekranı



Şekil 5.6 Eğitim işlemleri - 1



Şekil 5.7 Eğitim işlemleri - 2



Şekil 5.8 Eğitim işlemleri - 3

## 6. SONUÇ

Sunulan tez çalışması dört temel başlıkta toplanabilir. Bu kapsamda i) taşınabilir OOİ cihazının mekanik ve donanım tasarımı; ii) OOİ cihazının sistem yazılım tasarımı ve arayüzü; iii) çevrimde kullanıcı içeren öğrenen yapı tasarımı ve iv) sürekli öğrenen yapı ile başarıyı artırılan hata tespit yordamları geliştirilmiştir.

OOİ cihazı ile BDK üretim hattından alınan kartların görüntüsü ve gerekli durumlarda test için kullanılan BDK'lar üzerinde hatalar oluşturularak önemli bir veri seti oluşturulmuş ve veriler etiketlenmiştir. Bu veriler YOLO algoritması kullanılarak bileşik (tüm hata sınıfları birlikte) ve ayrık (her hata sınıfı ayrı) olarak eğitilmiştir.

Taşınabilir OOİ cihazı ile yüksek çözünürlükte ve doğru aydınlatmada nitelikli ve farklı veriler toplamak mümkün olmuştur. Taşınabilir olması sayesinde üretim hatlarında veya laboratuvar ortamında veri toplanabilmiştir.



Eğitimler sonucunda oluşan modellerin aynı test veri seti üzerinde başarı oranları hesaplanmıştır. Bu başarı oranlarına göre de her bir sınıfın hata tespiti için kullanılacak olan model (bileşik veya ayrık) belirlenmektedir. Hata tespitinde ayrık ve bileşik modellerin birlikte kullanılması ile başarı oranlarında veri setine göre farklı gelişmeler kaydedilmiştir. İki modelin karşılaştırılmalı kullanımı iki farklı veri seti ile test edilmiştir. Test 1 0.1 eşik değeri sonucuna göre kısa devre yüzde 97.64 ve kalkmış devre elemanı yüzde 94.66 ile bileşik yöntemde, kaymış devre elemanı yüzde 77.77 ve eksik lehim yüzde 92.30 ile ayrık yöntemde daha başarılı olmuştur. Test 2’de ise sadece eksik lehim yüzde 93.10 ile ayrık yöntemde daha başarılı iken diğer sınıflar bileşik yöntemde daha büyük başarı sergilemiştir. İki testin sonucundan karşılaştırmalı yöntem ile herhangi bir yöntemin tek başına kullanılmasından daha avantajlı olduğunu kanıtlamıştır. Bir başka çıkarım ise veri seti değiştiğinde ayrık veya bileşik yöntemden hangisinin daha başarılı olduğunun değişebileceğidir. İki yöntemin de başarısının veri setine göre değişmesi sınıfların birbirine ne kadar benzer özellik sergilediği ile ilgili de olmaktadır. Örneğin eksik lehim ve kısa devre hatası aynı görünüme sahip olmasa da lehim bazlı bir hata olmasından ötürü benzer özellikler sergilemektedir. Veri setinde ise eksik lehim hatasına göre daha fazla kısa devre hatası olması eksik lehim hatasının bileşik eğitimden ayrık eğitimde daha başarılı olmasına neden olmuştur. Kaymış devre elemanı hatası ise testlerden birinde ayrık yöntem ile daha başarıyla diğerinde ise bileşik yöntemde daha başarılı olmuştur. Veri setinin değişmesi bu sonuçta etkilidir. Sistem de bu değişikliğe uyum sağlamaktadır.

Ayrık ve bileşik modeller hata tespitinde başarı oranını artırmıştır ama bu başarı eğitim sürecinde kullanılan verilerin bilgisi ile sınırlı olmaktadır. Yeni ve bilinmeyen veya bilinse bile farklı ışık, açı veya büyüklükte olan hataların tespiti için modellerin eğitilmesi gereklidir. Bu noktada bu eğitim döngüsüne kullanıcı görüşünü ve taranmış olan görüntülerin verilerinin de eklenmesini de sağlayarak öğrenen yapı sistemi kurulmuştur. Eğitim süreci sadece geliştirme aşamasında kalmayıp arayüz kullanılmaya devam ettikçe devam etmektedir. Kullanıcı her tarama yaptığı görüntü üzerindeki hata tespitlerinin doğruluğu ve yanlışlığı hakkında sisteme geri dönüş sağlayarak sistemin yeni doğru bilgiler elde etmesini sağlar. Bu yeni bilgiler ise belli bir miktarı geçmesiyle birlikte eğitime alınır

ve yeni bilgilere de sahip yeni bileşik ve ayırık modeller oluşur. Yeni bilgiler sayesinde hem eski veriler hem de yeni veriler üzerinde hata tespit başarı oranı artmaktadır.

Sistemde eğitim yöntemleri arasında karşılaştırma yaparak yöntemler arasındaki olumsuz etkilerden kurtulmuş ve öğrenen yapı ile de sistem yeni hatalar öğrenmeye ve eski hatalar üzerindeki başarı oranını artırmıştır. Projeye yeni hata sınıfları eklenebilmektedir. Bu hata sınıfları BDK üzerindeki hatalarının yanında tespit edilebilmesi istenen başka unsurlar ve durumlar olabilir. Arayüz olarak sunulan çözüm BDK hata sınıfları tabanlı olsa da geliştirilmiş öğrenen yapı sistemi farklı sınıflar için de kullanılabilir. Yeni hata sınıfı ekleme özelliği de sistemin bu özelliğini göstermek için eklenmiştir.

Sistemde gerçekleşen eğitimlerde bazı ön şartlar tanımlanmıştır. Bir sınıfın ilk eğitime girebilmesi için o sınıfa ait etiketli görüntü sayısı 100'ün üzerinde olmalı ve sonrasında yeniden eğitime girebilmesi içinde veri sayısında yüzde 10'luk bir değişime sahip olması gerekmektedir. Yetersiz sayıda veri bulunması eğitimde yeterli öğrenme imkânı sunmayacaktır. Ayrıca da başarı oranı hesabı veri sayısının azlığı sebebiyle güvenilir olmayacak ve aynı eğitim tekrarında bile değişkenlik gösterecektir. Bu sebeple de eğitim ön şartı bulunmaktadır. İkinci şart olan yüzde 10 şartı ise planlı eğitimlerin çalışma zamanını daha verimli olarak planlayabilmek içindir. Yeni bir model dosyasının oluşması için yeterli değişikliğin sağlandığı görülmelidir. Eğer her görüntü alma sonrası eğitim başlatılır ise donanımsal yetersizlikler ve donanımsal yavaşlıklar oluşabilir. Ayrıca donanım belleğinin fazla dolu olması da eğitim veya hata tespiti işlemlerinin tamamlanamamasına sebep olmaktadır.

## **7. TEŞEKKÜR**

Bu tez Hacettepe Üniversitesi ve Aselsan arasında Teknoloji Transfer Merkezi üzerinden yapılan bir projenin çalışmasını içermektedir. Aselsan'a bu tezin çalışması için verdiği desteğe teşekkür ederim.

## KAYNAKLAR

- [1] Matlab introduction to deep learning. <https://www.mathworks.com/discovery/deep-learning.html>. Eriřim: 2023-01-30.
- [2] Derin görsel öğrenme – görsel nöronların diđer öğrenme ađları ile iliřkisi. <https://www.kisiselgelisim.com/derin-gorsel-ogrenme-gorsel-noronlarin-diger-ogrenme-aglari-ile-iliskisi/>. Eriřim: 2022-11-30.
- [3] Dai Wei, Dayong Li, Ding Tang, Qin Jiang, Dong Wang, Huamiao Wang, and Yinghong Peng. Deep learning assisted vision inspection of resistance spot welds. *Journal of Manufacturing Processes*, 62:262–274, **2021**. doi:10.1016/j.jmapro.2020.12.015.
- [4] Abdülsamet Aktař. Derin öğrenme yöntemleri ile görüntü işleme uygulamaları, **2020**.
- [5] Markets and markets. [www.marketsandmarkets.com/MarketReports/automated-optical-inspection-system-market-179056156.html](http://www.marketsandmarkets.com/MarketReports/automated-optical-inspection-system-market-179056156.html). Eriřim: 2019-09-30.
- [6] Y. Hara, H. Doi, K. Karasaki, and T. Iida. A system for pcb automated inspection using fluorescent light. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 10(1):69–78, **1988**. doi:10.1109/34.3868.
- [7] Ismail Ibrahim, Zuwairie Ibrahim, Kamal Khalil, Musa Mohd Mokji, and SARS Abu-Bakar. An algorithm for classification of five types of defects on bare printed circuit board. *International Journal of Computer Sciences and Engineering Systems*, 5(3), **2011**.
- [8] Ajay Pal, Singh Chauhan, and Sharat Bhardwaj. Detection of bare pcb defects by image subtraction method using machine vision. *Proceedings of the World Congress on Engineering 2011, WCE 2011, 2*, **2011**.

- [9] Siti Hazurah Indera Putera, Syahrul Fahmi Dzafaruddin, and Maziah Mohamad. Matlab based defect detection and classification of printed circuit board. In *2012 Second International Conference on Digital Information and Communication Technology and it's Applications (DICTAP)*, pages 115–119. IEEE, **2012**.
- [10] Can Ma, JianXu Mao, and JianPing Mao. Research and develop on pcb defect intelligent visual inspection robot. In *2012 Symposium on Photonics and Optoelectronics*, pages 1–4. IEEE, **2012**.
- [11] Yang Hanlin and Wang Jun. Automatic detection method of circuit boards defect based on partition enhanced matching. *Information Technology Journal*, 12:2256–2260, **2013**. doi:10.3923/itj.2013.2256.2260.
- [12] Beant Kaur, Gurmeet Kaur, and Amandeep Kaur. Detection and classification of printed circuit board defects using image subtraction method. In *2014 Recent Advances in Engineering and Computational Sciences (RAECS)*, pages 1–5. IEEE, **2014**.
- [13] Prachi P Londe and S Chavan. Automatic pcb defects detection and classification using matlab. *International Journal of Current Engineering and Technology*, 4(3):2119–2123, **2014**.
- [14] Salih Göktürk, Lale Akarun, and Huriye Bozma. Automated inspection of pcb's using a novel approach. pages 180–184. **1999**.
- [15] Fabiana R Leta, Flávio F Feliciano, and Flavius PR Martins. Computer vision system for printed circuit board inspection. In *ABCM Symposium Series in Mechatronics*, volume 3, pages 623–632. **2008**.
- [16] Wen-Yen Wu, Mao-Jiun J Wang, and Chih-Ming Liu. Automated inspection of printed circuit boards through machine vision. *Computers in industry*, 28(2):103–111, **1996**.

- [17] Nang Seng Siri Mar, PKDV Yarlagadda, and Clinton Fookes. Design and development of automatic visual inspection system for pcb manufacturing. *Robotics and computer-integrated manufacturing*, 27(5):949–962, **2011**.
- [18] Csaba Benedek. Detection of soldering defects in printed circuit boards with hierarchical marked point processes. *Pattern Recognition Letters*, 32(13):1535–1543, **2011**. ISSN 0167-8655. doi:<https://doi.org/10.1016/j.patrec.2011.06.006>.
- [19] Feng Xie, Alexandra Uitdenbogerd, and Andy Song. Detecting pcb component placement defects by genetic programming. In *2013 IEEE Congress on Evolutionary Computation*, pages 1138–1145. IEEE, **2013**.
- [20] Feng Xie, Anh Hoang Dau, Alexandra L Uitdenbogerd, and Andy Song. Evolving pcb visual inspection programs using genetic programming. In *2013 28th International Conference on Image and Vision Computing New Zealand (IVCNZ 2013)*, pages 406–411. IEEE, **2013**.
- [21] Fupei Wu and Xianmin Zhang. An inspection and classification method for chip solder joints using color grads and boolean rules. *Robotics and Computer-Integrated Manufacturing*, 30(5):517–526, **2014**.
- [22] S.L. Bartlett, P.J. Besl, C.L. Cole, R. Jain, D. Mukherjee, and K.D. Skifstad. Automatic solder joint inspection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 10(1):31–43, **1988**. doi:10.1109/34.3865.
- [23] Fupei Wu and Xianmin Zhang. Feature-extraction-based inspection algorithm for ic solder joints. *IEEE Transactions on components, packaging and manufacturing technology*, 1(5):689–694, **2011**.
- [24] Joseph Redmon, Santosh Divvala, Ross Girshick, and Ali Farhadi. You only look once: Unified, real-time object detection. pages 779–788. **2016**. doi:10.1109/CVPR.2016.91.

- [25] Joseph Redmon and Ali Farhadi. Yolo9000: Better, faster, stronger. pages 6517–6525. **2017**. doi:10.1109/CVPR.2017.690.
- [26] Joseph Redmon and Ali Farhadi. Yolov3: An incremental improvement. *CoRR*, abs/1804.02767, **2018**.
- [27] Ross Girshick, Jeff Donahue, Trevor Darrell, and Jitendra Malik. Rich feature hierarchies for accurate object detection and semantic segmentation. In *2014 IEEE Conference on Computer Vision and Pattern Recognition*, pages 580–587. **2014**. doi:10.1109/CVPR.2014.81.