

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANA BİLİM DALI

DOKTORA TEZİ

GÖRÜNTÜ İŞLEME VE YAPAY SİNİR AĞLARI
KULLANILARAK ARAÇ KAROSERİSİ SAC YÜZEYİNDEKİ
ELEKTRİKSEL DİRENÇ NOKTA KAYNAKLARININ KALİTE
SEVİYELERİNİN TESPİTİ

HİKMET OTMANBÖLÜK

KOCAELİ 2024

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI

DOKTORA TEZİ

GÖRÜNTÜ İŞLEME VE YAPAY SİNİR AĞLARI
KULLANILARAK ARAÇ KAROSERİSİ SAC YÜZEYİNDEKİ
ELEKTRİKSEL DİRENÇ NOKTA KAYNAKLARININ KALİTE
SEVİYELERİNİN TESPİTİ

HİKMET OTMANBÖLÜK

Prof. Dr. Sarp ERTÜRK

Danışman, Kocaeli Üniversitesi

.....

Prof. Dr. Mehmet Melih İNAL

Jüri Üyesi, Kocaeli Üniversitesi

.....

Doç. Dr. Serhat YILMAZ

Jüri Üyesi, Kocaeli Üniversitesi

.....

Doç. Dr. Erchan APTOULA

Jüri Üyesi, Sabancı Üniversitesi

.....

Dr. Yakup GENÇ

Jüri Üyesi, Gebze Teknik Üniversitesi

.....

Tezin Savunulduğu Tarih: 17.07.2024

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ

Kocaeli Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez/proje çalışmada,

- Bu tezin/projenin bana ait, özgün bir çalışma olduğunu,
- Çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı,
- Bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi,
- Bu çalışmanın Kocaeli Üniversitesi'nin abone olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü'nün belirlemiş olduğu ölçütlere uygun olduğunu,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Tezin/Projenin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez/proje çalışması olarak sunmadığımı,

beyan ederim.

☒ Bu tez/proje çalışmasının herhangi bir aşaması hiçbir kurum/kuruluş tarafından maddi/alt yapı desteği ile desteklenmemiştir.

☐ Bu tez/proje çalışması kapsamında üretilen veri ve bilgiler tarafından no'lu proje kapsamında maddi/alt yapı desteği alınarak gerçekleştirilmiştir.

Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Hikmet OTMANBÖLÜK

YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI

Fen Bilimleri Enstitüsü tarafından onaylanan lisansüstü tezimin/projemin tamamını veya herhangi bir kısmını, basılı ve elektronik formatta arşivleme ve aşağıda belirtilen koşullarla kullanıma açma izninin Kocaeli Üniversitesi'ne verdiğimi beyan ederim. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet hakları bende kalacak, tezimin/projemin tamamının ya da bir bölümünün gelecekteki makale, kitap, tebliğ, lisans, patent gibi çalışmalarda kullanımı, danışmanımın isim hakkı saklı kalmak koşuluyla ve her iki tarafın bilgisi dâhilinde bana ait olacaktır.

Tezin/projenin kendi özgün çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin/projenin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim kurulu tarafından yayınlanan “*Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge*” kapsamında tezim aşağıda belirtilen koşullar haricinde YÖK Ulusal Tez Merkezi/ Kocaeli Üniversitesi Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

- ☐ Enstitü yönetim kurulu kararı ile tezimin/projemin erişime açılması mezuniyet tarihinden itibaren 2 yıl ertelenmiştir.
- ☐ Enstitü yönetim kurulu gerekçeli kararı ile tezimin/projemin erişime açılması mezuniyet tarihinden itibaren 6 ay ertelenmiştir.
- ☒ Tezim/projem ile ilgili gizlilik kararı verilmemiştir.

Hikmet OTMANBÖLÜK

ÖNSÖZ VE TEŞEKKÜR

Endüstriyel üretimin birçok alanında, metal parçaların birleştirilmesinde cıvatalı bağlantılar ve perçin bağlantıları kullanılmaktadır. Ancak özellikle otomotiv sektöründe, bu iki yöntemden daha fazla oranda, punta kaynağı olarak da bilinen elektriksel direnç nokta kaynaklı birleştirme yönteminden yararlanılmaktadır. Otomotiv sektöründe, özellikle araç karoseri sac parçalarının birleştirilmesi amacıyla, karoseri yüzeyinde sayıları binleri bulan elektriksel direnç nokta kaynakları kullanılmaktadır. Bu kaynaklar, kaynak makinelerinin çalışan tarafından el ile kullanımı yanında, robotik uygulamalarla yapılıyor olsa da çeşitli nedenlerle uygun olmayan punta kaynaklar ortaya çıkmaktadır.

Bu çalışmada, uygun olmayan kaynakların bir araç karoseri yüzeyi üzerinde, bir çalışanın göz kontrolü ile tespit etmesine göre hızlı ve daha stabil çalışan, görüntü işleme ve yapay sinir ağı uygulamalarına dayanan bir yöntem geliştirilmiştir. Çalışmamın, disiplinler arası düzeyde kaynak tekniği, görüntü işleme ve yapay sinir ağları alanlarında çalışan araştırmacılara yararlı olmasını dilerim.

Görüntü işleme ve yapay sinir ağları alanlarında bu çalışmanın tamamlanmasında çok değerli katkılarıyla yol gösteren ve beni destekleyen hocam Prof. Dr. Sarp ERTÜRK'e, farklı bakış açısı ve getirdikleri yaklaşımlar ile çalışmalarına katkıda bulunan ve çok değerli destekler veren hocalarım Prof. Dr. Melih İNAL'a ve Doç Dr. Serhat YILMAZ'a teşekkürlerimi sunarım. Ayrıca, kaynak tekniği alanındaki incelemelerimde bana çok değerli katkılar sağlayan ve tüm çalışmalarımda destek olan babam Prof. Dr. Ing. A. Naci OTMANBÖLÜK'e minnet duygularımı sunarım.

Temmuz – 2024

Hikmet OTMANBÖLÜK

İÇİNDEKİLER

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ.....	i
YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI	ii
ÖNSÖZ VE TEŞEKKÜR.....	iii
İÇİNDEKİLER.....	iv
ŞEKİLLER DİZİNİ.....	vi
TABLolar DİZİNİ.....	x
SİMGELER VE KISALTMALAR DİZİNİ	xi
ÖZET	xii
ABSTRACT	xiii
1. GİRİŞ	1
2. GENEL BİLGİLER	2
2.1. Elektriksel Direnç Nokta Kaynağı.....	2
2.2. Punta Kaynakların Değerlendirilmesi Amacıyla Yapılan Çalışmalar	4
2.3. Önerilen Durum ve Hipotez.....	7
3. ELEKTRİKSEL DİRENÇ NOKTA KAYNAKLARININ GÖRÜNTÜ ÜZERİNDE TESPİTİ VE SINIFLANDIRILMASI.....	9
3.1. Karoseri Görüntüsünün Alınması Amacıyla Kullanılan Kamera ve Kamera Kalibrasyonu	9
3.2. Karoseri Görüntüsü Üzerinde Elektriksel Direnç Nokta Kaynakların Tespiti	12
3.3. Punta Kaynak Görüntülerinin Analizi ve Sınıflandırılması.....	20
3.3.1. Analiz ve Sınıflandırma İçin Temel Özniteliklerin Kullanılması.....	21
3.3.2. Analiz ve Sınıflandırma İçin HOGs Verilerinin Kullanılması.....	24
3.3.3. Görüntü Sınıflandırmada SIFT ve SURF Yöntemlerinin Uygulanması	27
3.3.4. Robotik Punta Kaynak Görüntülerinin Yapay Sinir Ağı Kullanılarak Sınıflandırılması	31
3.3.5. Manuel Punta Kaynak Görüntülerinin Yapay Sinir Ağı Kullanılarak Sınıflandırılması	36
3.3.6. Bölgesel Seçilen Manuel Punta Kaynak Görüntülerinin Yapay Sinir Ağı Kullanılarak Sınıflandırılması.....	38
3.3.7. Punta Kaynakların Sınıflandırılmasında Kullanılan Diğer Görüntü Öznitelikleri.....	40
3.3.8. Harris Köşeleri Sayısının Değişimi Ve Punta Kaynak Görüntüsünde Tanımlayıcı Özellik Olarak Kullanılması	43
3.3.9. Punta Kaynak Görüntüsünde En Küçük Özdeğerler Algoritması İle Bulunan Köşe Sayısı Değişiminin Tanımlayıcı Özellik Olarak Kullanılması.....	49
3.3.10. Verilerin Birleştirilmesi	50
3.3.11. Algoritmaların Tümü İçin Geliştirilen Yazılım	51
3.3.12. Sistemin Nihai Kararı Oluşturması.....	53
4. BULGULAR VE TARTIŞMA	58
4.1. Algoritmanın Kabin Arka Duvar Bölgesinde Denenmesi ve Elde Edilen Sonuçlar	59
4.2. Algoritmanın Kabin A Direği Altındaki Punta Kaynak Bölgesinde Denenmesi ve Elde Edilen Sonuçlar.....	63

4.3. Sistemin Kabin Ön Cam Alt Flanş Bölgesinde Denenmesi ve Elde Edilen Sonuçlar.....	68
4.4 Geliştirilen Sistemin YOLO Nesne Tanıma Modeli İle Karşılaştırılması	72
4.4.1 Cam Alt Flanş Bölgesinde YOLOv5 Uygulaması.....	73
4.4.2 Arka Duvar Alt Bölgede YOLOv5 Uygulaması	76
4.4.3 A Sütunu Alt Bölgesinde YOLOv5 Uygulaması.....	80
4.5. Geliştirilen Sistemin Faster R-CNN Modeli İle Karşılaştırılması	82
4.5.1. Cam Alt Flanş Bölgesinde Faster R-CNN Uygulaması	84
4.5.2. Arka Duvar Alt Bölgede Faster R-CNN Uygulaması	85
4.5.3. A Sütunu Alt Bölgede Faster R-CNN Uygulaması	86
4.6. Punta Kaynak Görüntülerinin Sayısal Verilerinin Yapay Sinir Ağı Haricindeki Yöntemler Kullanılarak Sınıflandırılması.....	87
4.6.1 Verilerin Destek Vektör Makinesi Kullanılarak Sınıflandırılması	87
4.7. Şimdiye Kadar Yapılan Çalışmaların Işığında Bulguların Değerlendirilmesi ve Tartışma.....	91
5. SONUÇLAR VE ÖNERİLER.....	102
KAYNAKLAR.....	107
KİŞİSEL YAYIN VE ESERLER.....	112
ÖZGEÇMİŞ.....	113

ŞEKİLLER DİZİNİ

Şekil 2.1.	Elektrik direnç nokta kaynağı şematik gösterimi	3
Şekil 2.2.	Kamyon kabin karoserisi üzerinde elektriksel direnç nokta kaynakları	4
Şekil 3.1.	Kamera kalibrasyonu için dama tahtası görüntü örnekleri.....	9
Şekil 3.2.	Uzak kalibrasyon işleminde kamera-görüntü konumları	10
Şekil 3.3.	Uzak kalibrasyonda her bir görüntüye ait piksel hatası	10
Şekil 3.4.	Yakın kalibrasyon işleminde kamera-görüntü konumları.....	11
Şekil 3.5.	Yakın kalibrasyonda her bir görüntüye ait piksel hatası	11
Şekil 3.6.	Karoseri yüzeyi görüntüsü ve punta kaynaklar	12
Şekil 3.7.	Korelasyon için ana görüntü olarak seçilen karoseri görüntüsü üzerinde punta kaynaklar ve saplamalar	13
Şekil 3.8.	Örnek olarak seçilen punta kaynak görüntüsü	13
Şekil 3.9.	Karoseri yüzey görüntüsü ile punta kaynak görüntüsü korelasyon sonucunun 3 boyutlu görünümü	14
Şekil 3.10.	Ana görüntüden punta kaynakların elde edilmesi için uygulanan algoritma.....	14
Şekil 3.11.	Karoserinin ön cam alt flanş bölgesinden alınan örnek görüntü	15
Şekil 3.12.	Gri ölçekli görüntüye dönüştürülen ana görüntü.....	15
Şekil 3.13.	Gauss filtresi ile bulanıklaştırılan ana görüntü.....	16
Şekil 3.14.	Sobel filtre uygulama sonrasında elde edilen görüntü	16
Şekil 3.15.	Dairesel Hough dönüşümü sonrasında elde edilen çemberler	17
Şekil 3.16.	Ana görüntü üzerinde tespit edilen punta kaynaklar	18
Şekil 3.17.	Kameranın konumu ve yanlardaki görüntülerin deformasyonu.....	18
Şekil 3.18.	Tespit edilen bir saplama örneği	20
Şekil 3.19.	Tespit edilen bir delik örneği	20
Şekil 3.20.	Punta kaynak görüntüsünün bölgelere ayrılması	21
Şekil 3.21.	İlk analiz kapsamında oluşturulan yapay sinir ağı modeli	22
Şekil 3.22.	Eğitim sonunda elde edilen hata histogramı	22
Şekil 3.23.	Doğru ve hatalı tespitlerin dağılımı.....	23
Şekil 3.24.	Uygun bir punta kaynak görüntüsünde tanımlanan kaynak bölgeleri.....	24
Şekil 3.25.	Kaynak dış bölge piksel yeğlilik değerlerinin değiştirilmesi	25
Şekil 3.26.	HOGs işleminin uygulanması sonrasında elde edilen matris.....	25
Şekil 3.27.	HOGs verileri ile eğitilen yapay sinir ağı.....	26
Şekil 3.28.	HOGs verileri ile eğitilen yapay sinir ağının hata histogramı.....	26
Şekil 3.29.	HOGs verileri ile yapılan eğitime ait hata matrisi.....	26
Şekil 3.30.	SIFT uygulaması için örnek yol tabelası görüntüsü.....	28
Şekil 3.31.	Yol tabelası görüntüsünde tespit edilen ve eşleştirilen anahtar noktalar.....	28
Şekil 3.32.	(a) Ve (b) robotik punta kaynak makinesi ile üretilen punta kaynak görüntülerine SIFT yönteminin uygulanması	29
Şekil 3.33.	SIFT yönteminin uygulanması sonucunda eşleşme elde edilememesi.....	29
Şekil 3.34.	SURF yönteminin trafik işareti görüntüsüne uygulanması ve elde edilen eşleşmeler	30
Şekil 3.35.	(a) Ve (b) robotik punta kaynak makinesi ile üretilen punta kaynak	

	görüntülerine SURF yönteminin uygulanması.....	30
Şekil 3.36.	SURF yönteminin uygulanması sonucunda tanımlayıcı ve eşleşme..... elde edilememesi	31
Şekil 3.37.	Uygun punta kaynağı örnek görüntüsü	33
Şekil 3.38.	Uygun olmayan punta kaynağı örnek görüntüsü.....	33
Şekil 3.39.	AlexNet CNN’de yapılan ilk değişiklik sonrasında yapılan eğitimin sonucu	34
Şekil 3.40.	CNN yapısında yapılan 2. değişiklik sonrasında elde edilen başarımları	34
Şekil 3.41.	Manuel punta kaynak görüntüleri ile yapılan eğitim	37
Şekil 3.42.	Yeşinlik değeri birbirine yakın olan (a) "uygun olmayan" olarak sınıflandırılan, (b) "uygun" olarak sınıflandırılan punta kaynak görüntüleri.....	38
Şekil 3.43.	Ön cam alt flanş bölgesinden alınan punta kaynak görüntülerinin eğitim sonucu	39
Şekil 3.44.	Kaynak iç bölgesi dışında kalan alanda; (a) görüntünün orijinal..... hali, (b) piksel yeşinlik değeri 100 sayısal değeri..... eşitlenmesi durumu	41
Şekil 3.45.	Punta kaynak görüntüsünün histogramı	42
Şekil 3.46.	100 Elemanlı Harris köşeleri değişimi dizisinin grafik gösterimi.....	45
Şekil 3.47.	Piksel yeşinlik değeri azaltılarak elde edilen punta kaynak görüntüleri	45
Şekil 3.48.	Yeşinlik değeri değiştirilmiş punta kaynak görüntülerine ait..... Harris köşe sayıları değişimi grafiği	46
Şekil 3.49.	(a) Kontrastı değiştirilmemiş görüntü, (b) ve (c) kontrastı sırasıyla %20 ve %40 değiştirilmiş görüntüler	47
Şekil 3.50.	Kontrastı değiştirilmiş görüntülerin Harris köşe sayısı değişimleri.....	48
Şekil 3.51.	(a) "uygun" sınıfına, (b) "uygun olmayan" sınıfına ait punta..... kaynak görüntüleri.....	48
Şekil 3.52.	"Uygun" ve "uygun olmayan" punta kaynak görüntülerinin Harris..... köşe sayısı değişimleri	48
Şekil 3.53.	En küçük özdeğer yöntemi ile elde edilmiş köşe sayılarının eşik..... değeri ile değişimi	50
Şekil 3.54.	Yazılımda karoseri yüzeyi üzerinde yeni bölge tanımlama bölümü.....	51
Şekil 3.55.	Karoseri yüzeyinden görüntülerin alınması aşaması.....	52
Şekil 3.56.	Tespit edilen punta kaynak görüntülerinin eğitimler öncesinde sınıflandırılması.....	53
Şekil 3.57.	Geliştirilen sistemin seri üretim şartlarında kullanımı sırasında..... ekran görüntüsü	54
Şekil 3.58.	Punta kaynak görüntüsüne göre bölümlenmiş ana görüntü	55
Şekil 3.59.	Görüntüdeki geometrik bozulmanın sıcaklık haritası yöntemiyle gösterimi.....	56
Şekil 4.1.	Arka duvar kaynakları temel parametreler eğitim sonuçları	59
Şekil 4.2.	Arka duvar kaynakları histogram verileri eğitim sonuçları	60
Şekil 4.3.	Arka duvar kaynakları Harris köşe sayısı değişim verileri eğitim sonuçları	60
Şekil 4.4.	Arka duvar kaynakları MEF sayısı değişim verileri eğitim sonuçları	61

Şekil 4.5.	Arka duvar kaynakları tüm verilerin bileşimi ile yapılan eğitim sonuçları	61
Şekil 4.6.	Kabin arka duvar punta kaynak görüntüleri ile yapılan CNN eğitimi ve sonucu	62
Şekil 4.7.	Kabin arka duvar üzerinde seri üretim şartlarında yapılan denemelerin sonuçları	63
Şekil 4.8.	Kabin yüzeyi A sütunu altına bulunan yüzey bölgesi	64
Şekil 4.9.	Standart parametreler ile yapılan yapay sinir ağı eğitim sonuçları	65
Şekil 4.10.	Histogram verileri ile yapılan yapay sinir ağı eğitim sonuçları	65
Şekil 4.11.	Harris köşeleri değişim verileri ile yapılan yapay sinir ağı eğitim sonuçları	66
Şekil 4.12.	MEF verileri değişimi ile yapılan yapay sinir ağı eğitim sonuçları	66
Şekil 4.13.	Tüm verilerin birleştirilmesiyle yapılan yapay sinir ağı eğitim sonuçları	67
Şekil 4.14.	A sütunu altı punta kaynak görüntüleri ile yapılan CNN eğitimi ve sonucu	67
Şekil 4.15.	Kabin A Adireği alt bölgesinde yapılan denemenin sonuçları	68
Şekil 4.16.	Cam alt flanş bölgesi standart parametreler eğitim sonuçları	69
Şekil 4.17.	Cam alt flanş histogram verileri eğitim sonuçları	69
Şekil 4.18.	Cam alt flanş Harris köşeleri değişimlerinin eğitim sonuçları	70
Şekil 4.19.	Cam alt flanş MEF Verileri değişimi eğitim sonuçları	70
Şekil 4.20.	Cam alt flanş tüm veriler eğitim sonuçları	71
Şekil 4.21.	Cam alt flanş punta kaynak görüntüleri CNN eğitim sonuçları	71
Şekil 4.22.	Cam alt flanş bölgesi eğitimleri sonrasında denemelerde elde edilen sonuçlar	72
Şekil 4.23.	Cam alt flanş bölgesi YOLOv5 eğitim başarımları	74
Şekil 4.24.	Cam alt flanş YOLOv5 eğitimi duyarlılık güven seviyesi eğrisi	75
Şekil 4.25.	Cam alt flanş YOLOv5 eğitimi hatırlama güven seviyesi eğrisi	75
Şekil 4.26.	Cam alt flanş YOLOv5 eğitimi duyarlılık hatırlama eğrisi	75
Şekil 4.27.	Cam alt flanş bölgesi YOLOv5 eğitimi hata matrisi	76
Şekil 4.28.	Cam alt flanş bölgesi test sonuçları	77
Şekil 4.29.	Arka duvar alt bölgesi YOLOv5 eğitim başarımları	77
Şekil 4.30.	Arka duvar alt YOLOv5 eğitimi duyarlılık güven seviyesi eğrisi	78
Şekil 4.31.	Arka duvar alt YOLOv5 eğitimi hatırlama güven seviyesi eğrisi	78
Şekil 4.32.	Arka duvar alt YOLOv5 eğitimi duyarlılık hatırlama eğrisi	78
Şekil 4.33.	Arka duvar alt bölgesi YOLOv5 eğitimi hata matrisi	79
Şekil 4.34.	Arka duvar alt bölge test sonuçları	79
Şekil 4.35.	A sütunu alt bölgesi YOLOv5 eğitim başarımları	80
Şekil 4.36.	A sütunu alt bölgesi YOLOv5 eğitimi duyarlılık güven seviyesi eğrisi	81
Şekil 4.37.	A sütunu alt bölgesi YOLOv5 eğitimi hatırlama güven seviyesi eğrisi	81
Şekil 4.38.	A sütunu alt bölgesi YOLOv5 eğitimi duyarlılık hatırlama eğrisi	81
Şekil 4.39.	A sütunu alt bölgesi YOLOv5 eğitimi hata matrisi	82
Şekil 4.40.	A sütunu alt bölge test sonuçları	82
Şekil 4.41.	Faster R-CNN uygulaması sonucu cam alt flanş bölgesi tespitleri	85
Şekil 4.42.	Faster R-CNN uygulaması sonucu arka duvar alt bölge tespitleri	86
Şekil 4.43.	Faster R-CNN uygulaması sonucu A sütunu alt bölge tespitleri	87

Şekil 4.44.	Cam alt flanş bölgesi istatistiksel veri seti NN eğitimi sonucu hata matrisi.....	88
Şekil 4.45.	Cam alt flanş bölgesi istatistiksel veri setinin orta seviye Gauss DVM eğitimi sonucu hata matrisi	88
Şekil 4.46	Cam alt flanş bölgesi MEF verileri NN eğitimi sonucu hata matrisi.....	89
Şekil 4.47.	Cam alt flanş bölgesi MEF verileri orta seviye Gauss DVM..... eğitimi sonucu hata matrisi	89
Şekil 4.48.	Cam alt flanş bölgesi Harris köşe sayıları verisi NN eğitimi sonucu hata matrisi.....	90
Şekil 4.49.	Cam alt flanş bölgesi Harris köşe sayıları verileri kaba seviye..... Gauss DVM eğitimi sonucu hata matrisi	90
Şekil 4.50.	Cam alt flanş bölgesi histogram verisi NN eğitimi sonucu hata matrisi.....	91
Şekil 4.51.	Cam alt flanş bölgesi histogram verileri orta seviye Gauss DVM..... eğitimi sonucu hata matrisi	91

TABLÖLAR DİZİNİ

Tablo 3.1. AlexNet CNN katmanları ve açıklamaları.....	32
Tablo 3.2. Yapılan değişiklikler sonrasında AlexNet CNN yapısı	33
Tablo 3.3. CNN yapısında yapılan değişiklikler sonrası katmanların yapısı.....	35
Tablo 3.4. AlexNet CNN'in eğitiminde kullanılan hiperparametreler	35
Tablo 3.5. Temel parametreler matrisi.....	43
Tablo 3.6. Ana görüntüde %20'den daha fazla geometrik deformasyon oluşan bölgelere denk gelen punta kaynak görüntülerine ait tespit oranları.....	56
Tablo 4.1. Arka duvar sonuçlarının doğruluk, duyarlılık, hatırlama ve F1 puanı sonuçları.....	63
Tablo 4.2. A direği alt bölge sonuçlarının doğruluk, duyarlılık, hatırlama ve F1 puanı sonuçları.....	68
Tablo 4.3. Ön cam alt flanş sonuçlarının doğruluk, duyarlılık, hatırlama ve F1 puanı sonuçları.....	72
Tablo 5.1. Geliştirilen sistem ile YOLO v5 ve Faster R-CNN uygulamalarının karşılaştırılması.....	103

SİMGELER VE KISALTMALAR DİZİNİ

α	: Açı (derece)
$\lambda_1, \lambda_2, \dots, \lambda_i$	: Özdeğerler
k	: Katsayı
σ	: Standart sapma
R_{min}	: Dairesel Hough dönüşümünde göz önüne alınacak en küçük yarıçap (piksel)
R_{max}	: Dairesel Hough dönüşümünde göz önüne alınacak en büyük yarıçap (piksel)
t	: Eşik değeri
Y	: Kuşatan kutu alanı
$\bar{Y}$	: Kuşatankutu alanının dışında kalan alan

Kısaltmalar

diğ.	: Diğerleri
hist.	: Histogram
İSG	: İş Sağlığı ve Güvenliği
Std.	: Standart

GÖRÜNTÜ İŞLEME VE YAPAY SİNİR AĞLARI KULLANILARAK ARAÇ KAROSERİSİ SAC YÜZEYİNDEKİ ELEKTRİKSEL DİRENÇ NOKTA KAYNAKLARININ KALİTE SEVİYELERİNİN TESPİTİ

ÖZET

Elektrik direnç nokta kaynağı, uygulama kolaylığı, hızlı uygulanabilirliği ve maliyet gibi nedenlerle ağırlıklı olarak otomotiv sektörü olmak üzere birçok alanda kullanılmaktadır. Punta kaynak olarak da adlandırılan bu kaynak türü, seri üretim şartlarında çeşitli nedenlerden dolayı, her kaynak işleminde hedeflendiği şekilde gerçekleşmeyebilir. Bu durum, tahribatsız muayene yöntemleri kullanılarak seri üretimin takip edilmesini ve punta kaynak kalitesinin izlenmesini gerektirmektedir. Bu çalışmada, kalite uygunluk seviyelerini belirlemek amacıyla, bir yüzey üzerindeki punta kaynaklarını görüntü işleme yöntemleri ile tespit edip, yapay sinir ağları kullanarak sınıflandıran yeni bir algoritma ve bu algoritmayı uygulamak için bir yazılım geliştirildi. Punta kaynak görüntülerinin birbirine benzeyen fakat aynı olmayan yapıları nedeniyle sınıflandırmanın başarı oranını arttırmak için bugüne kadar yapılmış çalışmalardan farklı olarak, punta kaynak görüntülerinden yeni ve farklı ayırt edici öznitelikler çıkartmak amacıyla bir yöntem geliştirildi ve bu özniteliklerin karar vermede birlikte kullanılabilmesi için bir algoritma oluşturuldu. Farklı yapay sinir ağlarının bu veriler ile eğitilmeleri ve nihai sonucu üretmek için birlikte kullanılmaları üzerine geliştirilen algoritma ile robotik olmayan yöntemlerle üretilen ve görsel olarak karar vermede zorluk içeren punta kaynakların sınıflandırılmasında en az %92 başarılı sınıflandırma elde edildi. Robotik kaynak uygulamalarında ise %98 başarılı sınıflandırma oranına ulaşıldı. Geliştirilen sınıflandırma sisteminin kaynak sürecinden ve ortam şartlarından bağımsız olup yüksek hızda sonuç üretme kabiliyeti, sistemin endüstriyel ortamda seri üretim şartlarında kullanımını kolaylaştırdı. Uygulama, punta kaynakların kalite seviyesinin tespit edilmesi ve gerektiğinde önlemlerin devreye alınmasını hızlandırdı. Geliştirilen bu sistem, endüstri 4.0 yolunda dijitalleşme sürecinde ilerlemek isteyen kuruluşlara, ürün kalite seviyesinin tespiti için önemli bir destek sağlayacaktır.

Anahtar Kelimeler: Elektrik Direnç Nokta Kaynağı, Görüntü İşleme, Harris Köşeleri, Özdeğer Sayıları, Yapay Sinir Ağları.

DETERMINATION OF ELECTRICAL RESISTANCE SPOT WELDS QUALITY LEVELS ON AUTOMOTIVE BODY SHEET SURFACES USING IMAGE PROCESSING AND ARTIFICIAL NEURAL NETWORKS

ABSTRACT

Electric resistance spot welding is widely utilized across various industries, particularly in the automotive sector, due to its ease of application, rapid implementation, and cost-effectiveness. Also referred to as spot welding, this method may not always be performed as intended during each welding process in mass production environments due to various factors. This necessitates the use of non-destructive testing methods to monitor mass production and track the quality of spot welds. In this study, a new algorithm and software were developed to detect spot welds on a surface using image processing techniques and classify them using artificial neural networks to determine quality compliance levels. Due to the visually similar yet distinct structures of spot weld images, a novel method was developed to extract new and distinctive features from these images, differing from previous studies, in order to enhance classification accuracy. An algorithm was devised to utilize these features collectively in the decision-making process. By training different artificial neural networks with this data and using them in combination to generate the final result, a classification accuracy of at least 92% was achieved for spot welds produced through non-robotic methods, where visual decision-making posed challenges. In robotic welding applications, a classification accuracy of 98% was attained. The developed classification system is independent of the welding process and environmental conditions, capable of producing high-speed results, facilitating its use in industrial environments under mass production conditions. This application has accelerated the identification of spot weld quality levels and the implementation of necessary measures when required. The system provides significant support to organizations aiming to advance in the digitalization process on the path to Industry 4.0 by enabling the detection of product quality levels.

Keywords: Electrical Resistance Spot Weld, Image Processing, Harris Corners, Eigenvalues, Artificial Neural Networks.

1. GİRİŞ

Otomotiv sektöründe elektriksel direnç nokta kaynağı, metal parçaların birleştirilmesinde sıklıkla kullanılmaktadır. Punta kaynağı olarak da adlandırılan bu birleştirme yönteminde kaynak işlemi, bir çalışan tarafından el ile kullanılan punta kaynak makineleri ile yapılabildiği gibi robotik uygulamalar ile yüksek seviyede otomasyona sahip sistemler kullanılarak da gerçekleştirilmektedir.

Sac parça kalitesi, sac yüzeyinin uygun olmaması, gerilim dalgalanmaları, punta makine çene uçluklarının deforme olması veya çalışan hatası gibi nedenlerle her punta kaynağı, istenilen şekilde gerçekleşmeyebilir. Bu nedenle, seri üretim şartlarında, punta kaynakların, belirli bir proses dahilinde düzenli kontrol edilmesi gereklidir. Punta kaynaklarının uygun olup olmadığını anlamak için tahribatlı ve tahribatsız kaynak kontrol yöntemleri bulunmaktadır. Bu yöntemler arasında, kaynağa zarar vermeden, kaynak uygunluğunun anlaşılabileceği ve en doğru sonucu veren yöntem, ultrasonik kaynak kontrol yöntemidir. Fakat bir araç karoserisinde sayıları binleri bulan punta kaynaklarının hepsinin, ultrasonik kaynak kontrolü yöntemi ile kontrol edilmesi, araç üretimi yapılan bir fabrikada üretim sürelerinin de sınırlılığı göz önüne alındığında, seri üretim şartlarında mümkün değildir. Bu nedenle punta kaynaklar genellikle bir çalışan tarafından göz ile kontrol edilir ve uygun olmadığı düşünülen kaynaklara özel kaynak kontrol yöntemleri ile ilave kontroller uygulanır.

Bu çalışmada amaç, karoseri üzerindeki punta kaynakların görüntü işleme teknikleri ve yapay sinir ağları kullanılarak analiz edilmesi amacıyla bir sistem geliştirilmesi, kaynağın uygun olup olmadığının hızlı ve yüksek doğrulukla değerlendirilmesinin sağlanmasıdır. Geliştirilen sistem, kaynak görüntülerinin alınabilmesi için özel şartlara bağlı olmayacak, tüm punta kaynak proseslerine uygulanabilecektir. Sistemin seri üretim şartlarında kullanılması sayesinde, punta kaynak kontrol prosesinin hızlanması, zamandan ve iş gücünden tasarruf edilmesi, kaynakların göz ile kontrollerinde karşılaşılan yanlış değerlendirmelerin yüksek oranda engellenmesi amaçlanmıştır.

2. GENEL BİLGİLER

Elektriksel direnç nokta kaynağı, özellikle otomotiv gibi metal birleştirme işlemlerinin yoğun olarak uygulandığı sektörlerde kullanılan bir kaynak yöntemidir. Bu yöntem, punta kaynağı olarak da adlandırılır. Bu çalışmada, kamera ile araç karoseri yüzeyi üzerinden elde edilen sac yüzey görüntüleri üzerindeki punta kaynak görüntüleri tespit edildi ve bu görüntüler “uygun”, “uygun olmayan” ve “punta kaynak olmayan” şeklinde sınıflandırıldı. Punta kaynak görüntülerinin tespiti görüntü işleme yöntemleriyle, sınıflandırma ise görüntülerden elde edilen öznitelikler ve ayırt edici özellikler ile eğitilen yapay sinir ağları ile gerçekleştirildi. Ayrıca geliştirilen algoritmanın seri üretim şartlarında kolaylıkla uygulanabilmesi ve çalışanın sınıflandırma sonucu hakkında hızlı ve kolayca bilgilendirilmesi için bir uygulama geliştirildi. Geliştirilen sistemin seri üretim şartlarında, uygulanan endüstriyel alandan ve punta kaynak prosesinden bağımsız olması, dolayısıyla birçok alanda kolaylıkla kullanılabilirliği sağlandı.


2.1. Elektriksel Direnç Nokta Kaynağı

Elektriksel direnç nokta kaynağı, metal yüzeylerin birleştirilmesinde kullanılan kaynak yöntemlerinden biridir ve punta kaynağı olarak da adlandırılmaktadır. Bu yöntemde birleştirilecek parçalar üzerinde, punta kaynağı makinesi kullanılarak, nihai parçanın fiziksel dayanım özellikleri göz önüne alınarak belirlenmiş noktalarda, parçaların üzerinde yüksek noktasal baskı kuvveti uygulanır ve bu kuvvet uygulanan yüzeyden yüksek akım geçirilir (Ciganek, 1940). Akımın geçirildiği süre zarfında, birleştirilen parçaların elektriksel dirençleri nedeniyle, kuvvetin ve akımın uygulandığı noktada yüksek ısı oluşur. Isı sayesinde, baskı kuvveti uygulanan noktada ergime ve baskının da etkisiyle moleküler kaynaşma meydana gelir. Böylece birleştirilecek parçalarda, kuvvetin uygulandığı noktada birleşme ve birbirine kaynama işlemi gerçekleşmiş olur. Ardından, punta kaynak makinesi baskı uçlarında, baskı kuvvetinin uygulandığı noktaya bir soğutma işlemi uygulanır. Bu işlem, baskı yapan kolların içinden, baskı uçlarındaki uçluklara temas edecek şekilde soğutma suyunun geçirilmesi ile gerçekleştirilmektedir. Soğutmanın ardından punta kaynak makinesi bir sonraki kaynak işlemi için hazır hale gelmiş olur. Bununla birlikte, punta kaynakların sadece elektriksel direnç yöntemiyle değil, lazer ışını ile hedeflenen alanın yüksek sıcaklıklara ulaştırılması yöntemiyle de gerçekleştirilmesi ve kaynak kalitesinin değerlendirilmesi incelenmiştir (Saifi ve diğ.,

1976; Shao ve diğ., 2006).

Elektriksel direnç nokta kaynağı işleminde, kaynak yapılan ve kaynak noktası olarak adlandırılan alan, kullanılan kaynak ekipmanının kuvvet, akım ve elektrod temas noktası büyüklüğüne bağlı olarak değişir. Otomotiv sektöründe bu yöntem, genellikle 4-6 milimetre çaplı dairesel kaynak noktaları oluşacak şekilde uygulanmaktadır. Elektrik direnç nokta kaynağı yöntemin en büyük avantajı, görece hızlı şekilde metal yüzeylere uygulanabilmesi ve kaynaklanacak parçaların elektrod kaynağına göre çok daha kısa sürede birleştirilebilmesini mümkün kılmasıdır. Bu aşamada, kaynak yönteminin seçiminde sadece kaynak prosesi hızının değil, tasarımı yapılan nihai ürünün statik ve dinamik kuvvetlere dayanımı gibi faktörlerin de göz önünde bulundurulduğu unutulmamalıdır.

Punta kaynak işleminde kaynak süresi, birleştirilecek yüzeylerin özelliklerine bağlı olmakla birlikte, tek bir kaynak noktası için saniyelerle ölçülmektedir. Ayrıca elektrik direnç nokta kaynağı için geleneksel kaynak yöntemlerinde olduğu gibi özel ortam şartları sağlamak amacıyla inert gaz gibi ek bileşenler kullanılmasına ihtiyaç bulunmamakta ve yöntem, robot kullanılarak da uygulanabilmektedir. Böylece, özellikle seri üretim şartlarında üretim prosesi, diğer kaynak yöntemlerine göre hızlanmaktadır. Şekil (2.1)'de elektrik direnç nokta kaynağının şematik gösterimi görülmektedir.




Şekil 2.1. Elektrik direnç nokta kaynağı şematik gösterimi

Bununla birlikte, bu yöntemin olumsuz yönleri de bulunmaktadır. Kaynak prosesinde kullanılan baskı uçlukları, belirli bir kaynak işlemi sayısından sonra değiştirilmelidir. Bu

sayı kaynak parametrelerine ve kaynak prosesi bileşenlerinin özelliklerine bağlıdır. En uygun kaynak sonucunun elde edilmesi, kaynak işleminin doğru yapılmasına bağlıdır. Bu kaynak yönteminde uygulamanın başarılı olmasına etki eden hususlar arasında baskı kuvvetinin yüzeye dik uygulanması, kuvvetin aynı tip yüzeylerde her kaynak işleminde belirlenen değerde ve birleştirilecek her iki metal yüzeye de eşit şekilde uygulanması, uçlukların kaynak için uygun olması, elektriksel parametreler kapsamında akım ve gerilimin doğru belirlenmesi ve her işlemde aynı değerlerin uygulanması sayılabilir.

Otomotiv sektöründe, araçların ana gövdesini ve yaşam kabinini oluşturan karoseri bölümünün üretiminde, şekillendirilmiş sac parçaların birleştirilmesi aşamasında, elektrik direnç nokta kaynağı yoğun şekilde kullanılmaktadır. Kaynak adedi sayısı, karoserinin büyüklüğüne ve yapılan tasarıma göre değişmekle birlikte, binlerle ifade edilmektedir. Örneğin, bir kamyon karoseri yüzeyinde 3000 adetten fazla punta kaynak noktası bulunabilmektedir. Şekil (2.2)'de bir kamyon kabin karoserisinden ayrıntı üzerinde elektriksel direnç nokta kaynakları görülmektedir.



Şekil 2.2. Kamyon kabin karoserisi üzerinde elektriksel direnç nokta kaynakları

2.2. Punta Kaynakların Değerlendirilmesi Amacıyla Yapılan Çalışmalar

Elektrik kaynağının ilk kez tanımlanmasından bu yana (Hornor, 1918), punta kaynakların

kalite seviyelerinin değerlendirilmesi ve uygun olup olmadıklarının belirlenmesi amacıyla birçok çalışma yapılmıştır. Bunlar genel olarak, kaynak akım ve gerilimi, çene baskı kuvveti, elektriksel direnç değişimi gibi kaynak parametrelerinin incelenmesi yoluyla yapılan değerlendirmeler ve punta kaynak görüntüsünün incelenmesi yoluyla yapılan değerlendirmeler olarak ikiye ayrılarak değerlendirilmiştir (Breitenbach ve diğ., 2021).

Yapılan çalışmalar incelendiğinde kaynak parametrelerinin ve kaynak görüntülerinin incelenip analiz edilmesine yönelik farklı yaklaşımlar görülmüştür. Kaynak kalitesi üzerine yapılan çalışmalarda, akım, gerilim, uçluk ile yapılan kaynak sayısı gibi parametreler kullanılmıştır. (Dilthey ve diğ., 1999). Punta kaynak çapının ölçülmesi üzerine neuro-fuzzy yöntem de kullanılmıştır (Lee ve diğ. 2000; Lin ve diğ. 2004). Bu çalışmalarda da kaynak çenelerinin yani elektrodların hareketi ve kaynak akım, gerilim parametreleri incelenmiştir. Diğer bir çalışmada ise yine bir CNN kullanılmış fakat ağ girdi verisi olarak kaynak direnç değerinin kaynak sürecindeki değişimi incelenmiştir (Lin ve diğ. 2021) Ancak bu şekilde kaynak parametrelerinin incelendiği çalışmalar, kaynak makinesine veya kaynak sistemine bağlantı yapılmasını ve gereken parametre bilgilerinin okunmasını gerektirmektedir.

Hatalı punta kaynakların tespit edilmesi için bir evrimsel sinir ağı (convolutional neural network, CNN) kullanılan ve başarı oranının %99,01 olarak verildiği çalışmada, punta kaynak görüntülerinin genel görüntüsü verilmiş, uygun ve uygun olmayan punta kaynak görüntülerinin ne oldukları açıkça gösterilmemiştir. Ağırlıklı olarak CNN ağ yapısı üzerinde durulan çalışmada kamera pozisyonunun belirlenenin dışına çıkmaması gerektiği ve aydınlatma şartlarının değişmemesi gerektiği belirtilmiştir (Guo ve diğ., 2017).

Punta kaynak prosesinin genişletilmiş k-komşuluk yöntemi kullanılarak değerlendirildiği farklı bir çalışmada, çeşitli metal tipleri için kaynak akım ve gerilim değerlerini analiz süreçlerine girdi olarak alınmıştır (Junno ve diğ. 2005). Bu çalışma da kaynak makinesi sistemine bağlantı yapılmasını gerektirmiştir.

Elektriksel direnç nokta kaynağı kalitesini incelemek amacıyla fraktal teori de kullanılmıştır (Zhanfeng ve diğ. 2010).

Diğer bir çalışmada, yapay sinir ağları ile örüntü tanıma yöntemi kullanılmış, yine akım ve gerilime bağlı olarak hesaplanan elektriksel direnç eğrisinin kaynak işlemi sırasındaki değişimi, örüntü bilgisi olarak kullanılmıştır (Cho ve diğ., 2004). Benzer şekilde yapılan bir çalışmada da kaynak kalitesi gerçek zamanlı izlenmiş ve kaynak noktası çapı tahmin edilmiştir (Subramanian ve diğ., 2004).

Bir başka çalışmada ise kaynak kalitesi için kaynak elektrodlarının kaynak işlemi sırasında ne kadar hareket ettikleri incelenmiştir (Xinmin ve diğ., 2007).

Kaynak noktasının tespitine yönelik bir çalışmada, kaynak noktası ısı izinden hareket edilerek, kaynak konturu tespit edilmiştir (Ruisz ve diğ., 2007).

Kaynak işlemi sırasında ergimenin gerçekleştiği kaynak noktasına ait ultrason izinin incelenmesiyle de kaynak kalitesi değerlendirilmiştir (Karloff ve diğ., 2009; Ulbrich ve diğ., 2023).

Adaptif rezonans teori (ART) yapay sinir ağı kullanılan bir başka çalışmada, özel bir metal alaşım çeşidi olan 780 MPa çeliğinde punta kaynak kalitesini tahmin etmek üzere bir model geliştirilmiştir. Yapay sinir ağının giriş parametreleri olarak yine kaynak gem ve akım bilgileri kullanılmış, çıkış parametreleri olarak ise direnç nokta kaynaklarının çekme kesme mukavemeti, kaynak noktası boyutu ve kırılma şekli kullanılmıştır (Hwang ve diğ., 2018).

Yapılan bir diğer çalışmada da punta kaynak noktasının lazer termografi verileri üzerinde çalışılmış ve bu verilere dayalı kaynak kalitesi belirlemede CNN kullanılmıştır (Kastner ve diğ., 2021). Bunların yanında punta kaynak kalitesi, istatistiksel proses kontrol yöntemleri kullanılarak (Guo ve diğ., 2021) ve gradyan kuvvetlendirmeli karar ağacı yaklaşımlarıyla da incelenmiştir (Peng, 2021). Makine öğrenmesi kullanılarak kaynak kalitesi belirleme ve kaynak parametrelerinin optimizasyonu çalışmaları da yapılmıştır (He ve diğ., 2022). Punta kaynak kalitesinin tespitinde bir diğer uygulama, dijital ikiz kullanımı olmuştur (Dong ve diğ., 2023).

Bu çalışmaların birçoğunda iki temel eksiklik tespit edildi. Bunların ilki, geliştirilen sistemlerin veri toplayabilmeleri için punta kaynak makinelerine bağlanmaları gerekliliği veya uygun sensörler ile akım, gerilim, baskı kuvveti gibi parametreleri okuma

zorunluluğudur. Bu durum, endüstriyel uygulamalarda, geliştirilen sistemin mevcut bir tesise uygulanması aşamasında ek maliyet getirmekte, sistemin kolaylıkla uygulanabilme yeteneğini azaltmaktadır.

Diğer bir eksiklik ise, özellikle görüntü işlemeye dayalı geliştirilen sistemlerin laboratuvar şartlarında olgunlaştırılması nedeniyle, deneysel olarak başarılı sonuçlar vermesine rağmen, seri üretim şartlarında karşılaşılabilecek çok çeşitli punta kaynak yapılarına uyum sağlamak için bir çözüme sahip olmamalarıdır. Bu nedenle, laboratuvar ortamında bir adet punta kaynak makinesi ile üretilen punta kaynaklarda başarılı sonuçlar veren sistemler, endüstriyel seri üretim şartlarında, birçok farklı punta kaynak makinesi içeren üretim ortamlarında, yüksek başarı seviyelerine ulaşmakta zorlanacaktır. Ayrıca, geliştirilen sistemlerin hesap yükleri, seri üretim şartlarında sayıları binleri bulan punta kaynakların tümünün kontrol edilebilmesini, zaman kısıtı nedeniyle, imkânsız hale getirecektir.

2.3. Önerilen Durum ve Hipotez

Bu çalışmada, endüstriyel kullanımın ve seri üretim şartlarının yukarıda belirtilen zorluklarına karşı uyumlandırılabilen, punta kaynakları, görüntü işleme ve yapay sinir ağlarının birlikte kullanımı ile kalite seviyelerine göre “uygun” ve “uygun olmayan” olarak sınıflandırabilen bir tahribatsız muayene sistemi önerildi. Sistemin, özellikle kaynak kalitesini görsel kontrol ile belirleyen çalışanlara destek vermesi, kontrol sonucunu çalışanlara görsel olarak hızlı ve anlaşılır şekilde aktararak, punta kaynak kontrol sürecini kolaylaştırıp hızlandırması hedeflendi.

Şimdiye kadar yapılan çalışmalar incelendiğinde, punta kaynak görüntüsü üzerine yapılan çalışmalarda ağırlıklı olarak yapay sinir ağlarının ve özellikle evrimsel yapay sinir ağlarının kullanıldığı görüldü. Punta kaynağa ait ayırt edici özelliklerin, punta kaynak görüntüsü üzerinden elde edildiği, bu amaçla Hough dönüşümü (Ballard, 1981), görüntü segmentasyonu, trigonometrik hesaplama ile punta kaynak noktasının büyüklüğü ve robotik kaynak prosesleri için üç boyutlu uzayda robot kollarının hareket dinamiklerinin hesaplanması gibi yaklaşımlarının kullanıldığı tespit edildi.

Şimdiye kadar yapılan çalışmalarda gözlemlenen ve incelenen yöntemlerden farklı olarak

bu çalışmanın hipotezi, hızlı çalışan ve kolay uyumlandırılabilen bir sistem elde etmek amacıyla, karmaşık hesaplama yüküne girmeden, görece kolay işlenebilen görüntü parametrelerinin kullanılmasıdır. Hipotezin devamı, Harris köşe tespiti ve en küçük özdeğerler yöntemini kullanan köşe tespiti yöntemlerinin, görüntü piksel yoğunluk değerlerine bağlı olarak elde edilen ve belirli bir aralıkta değiştirilen bir eşik değeri değişkeni çerçevesinde tekrarlanarak, elde edilecek köşe sayıları değişimlerinin, görüntüye ait ayırt edici bir sonuç ortaya koyacağıdır. Çalışmada bu hipotez üzerinde duruldu ve hipotezin deneysel sonuçları gösterildi. Ayrıca çalışmada, nihai kararı desteklemek için punta kaynak görüntülerinin bir CNN kullanılarak sınıflandırılması üzerinde de çalışıldı. Çalışmanın bu noktasındaki hipotez de bir punta kaynak görüntüsünün sınıflandırılmasında, temel istatistiksel verilerin, köşe sayıları değişimlerinin ve CNN sonuçlarının birlikte kullanılması ve nihai karar vermede bu sistemin daha yüksek doğrulukta sonuçlar oluşturacağıdır.

3. ELEKTRİKSEL DİRENÇ NOKTA KAYNAKLARININ GÖRÜNTÜ ÜZERİNDE TESPİTİ VE SINIFLANDIRILMASI

Bu çalışmada, punta kaynak olarak da adlandırılan elektriksel direnç nokta kaynakları, karoseri yüzey görüntüsü üzerinde işlem yapılarak tespit edildi ve bu görüntüler üzerinde işlemler yapılarak punta kaynak görüntüleri “uygun” ve “uygun olmayan” olarak sınıflandırıldı. Punta kaynak görüntülerinin tespit edilmesi sırasında, punta kaynak olmayan unsurlara ait görüntüler de görüntü tespit algoritması tarafından tespit edildi. Bu görüntüler de “punta kaynak olmayan” olarak sınıflandırıldı. Sınıflandırma işlemleri ve sınıflandırma sonucunun ilgili çalışana hızlıca aktarılabilmesi amacıyla bir uygulama geliştirildi ve sonuçlar, kullanılan kamera ile alınan görüntü üzerinde işaretlenerek görselleştirme sağlandı.


3.1. Karoseri Görüntüsünün Alınması Amacıyla Kullanılan Kamera ve Kamera Kalibrasyonu

Karoseri yüzeyinden alınan ana görüntüler, Logitech firmasının C922 Pro HD Stream model kamerası kullanıldı ve görüntüler 1280×720 piksel çözünürlükte alındı. Kameranın kullanımı sırasında titreşim oluşmaması amacıyla bir tripod kullanılarak kamera tripod üzerinde sabitlendi. Kamera, bir CMOS sensöre sahip olup kameranın görüntü kalibrasyonu Matlab programının kamera kalibrasyon uygulaması kullanılarak gerçekleştirildi. Kalibrasyon sırasında, ölçekli dama tahtası kağıt baskısı kullanıldı ve kamera ile bu baskıdan, farklı açılardan görüntüler alındı. Kalibrasyon amacıyla 20 adet görüntü kullanıldı. Şekil (3.1)’de, kalibrasyonda kullanılan görüntülerden örnekler görülmektedir.




Şekil 3.1. Kamera kalibrasyonu için dama tahtası görüntü örnekleri

Kalibrasyon işleminde kullanılan ve Şekil (3.1)’de görülen dama tahtası görüntü baskısında her bir kare kenarı 22,5 mm olarak tespit edildi. Ayrıca, karoseri yüzeyinden alınan ana görüntü 1280× 720 piksel boyutunda olduğu için kamera görüntü ayarı da bu değere getirildi.



Şekil 3.2. Uzak kalibrasyon işleminde kamera-görüntü konumları


Bu çalışmada kamera, karoseri yüzeyine yaklaşık 150 mm ile 200 mm aralığında mesafede konumlandırılarak görüntüler alındı. Şekil (3.2)'de, kameranın görüntü yüzeyine görece daha uzak mesafede, 400 mm ile 700 mm aralığında yerleştirilmesi ile örneklenen görüntülerin konumları gösterildi. Şekil (3.3)'te ise uzak kalibrasyon ile her bir görüntüde oluşan piksel hata değerleri gösterildi. Kameranın bu konumunda alınan görüntüler ile yapılan kalibrasyonda, genel ortalama hata 0,14 piksel olarak tespit edildi.



Şekil 3.3. Uzak kalibrasyonda her bir görüntüye ait piksel hatası


Kamera kalibrasyonu işlemi, kameranın görüntü yüzeyine 100 mm ile 150 mm arası mesafede konumlandırılması durumu için tekrarlandı ve işlem yakın kalibrasyon olarak adlandırıldı. Bunun için dama tahtası görüntüsünün kağıt baskısında %70 küçültme uygulandı ve görüntü %30 büyüklük ile kağıda basıldı. Şekil (3.4)'te, kameranın ve

örneklenen görüntülerin konumları gösterildi.



Şekil 3.4. Yakın kalibrasyon işleminde kamera-görüntü konumları

Şekil (3.5)'te, yakın kalibrasyon ile her bir görüntüde oluşan piksel hata değerleri gösterildi.



Şekil 3.5. Yakın kalibrasyonda her bir görüntüye ait piksel hatası

Yakın kalibrasyon işleminde genel ortalama piksel hatası 0,4 piksel olarak tespit edildi. Çalışmada, ana görüntü 1280×720 piksel, ileride açıklanacağı üzere punta kaynak görüntüleri de 70×70 piksel olarak çalışıldı. Kalibrasyonlarda piksel hatalarının 0,14 ile 0,4 piksel aralığında tespit edildi. Özellikle yakın kalibrasyon işleminde tespit edilen piksel hatası oranı $\frac{0,4}{70} = 0,0057$ olarak, yani yaklaşık %0,6 olarak elde edildi. Bu değer, görüntüde oluşabilecek bir doğrusal geometrik bozukluğun en fazla %0,6 seviyesinde

gerçekleşebileceğini gösterdi. Bu hata seviyesi, çalışmada yapılan görüntü analizi işlemleri için kabul edilebilir bir seviye olarak değerlendirildi.

3.2. Karoseri Görüntüsü Üzerinde Elektriksel Direnç Nokta Kaynakların Tespiti

Karoseri yüzeyi üzerinde elektriksel direnç nokta kaynakların, yani punta kaynakların tespit edilmesi amacıyla, kamera ile karoseri yüzeyi üzerinden görüntüler alındı. Bu görüntüler ana görüntü olarak adlandırıldı. Ana görüntüler işleme tabii tutuldu ve ana görüntülerdeki punta kaynak görüntüleri tespit edildi. Şekil (3.6)'da karoseri yüzeyinden alınan bir ana görüntü örneği ve yüzeydeki punta kaynakları görülmektedir.




Şekil 3.6. Karoseri yüzeyi görüntüsü ve punta kaynaklar

Ana görüntü üzerinde punta kaynaklarının tespit edilmesi için ilk çalışılan yöntem korelasyon oldu. Burada amaç, örnek olarak alınan bir punta kaynak görüntüsünün tüm karoseri görüntüsü üzerindeki korelasyon durumunun incelenerek, en yüksek seviyede uyum sağlayan, yani korelasyonu 1'e yaklaşan bölgelerin punta kaynağı olarak tanımlanmasıdır. Görüntülerin korelasyonu için kullanılan 2 boyutlu korelasyon ifadesi Denklem (3.1)'de belirtildiği gibidir.

$$r(x, y) = \frac{\sum_{i=-m}^m \sum_{j=-n}^n (h(i, j) - \bar{h})(f(x+i, y+j) - \bar{f})}{\sqrt{(\sum_{i=-m}^m \sum_{j=-n}^n (h(i, j) - \bar{h})^2)(\sum_{i=-m}^m \sum_{j=-n}^n (f(x+i, y+j) - \bar{f})^2)}} \quad (3.1)$$

Korelasyon öncesinde ana görüntü ve seçilen punta görüntüsü, kırmızı-yeşil-mavi (RGB) formatından gri yeğnlik seviyesi formatına dönüştürüldü. Şekil (3.7)'de ana görüntü olarak seçilen karoseri görüntüsü ve Şekil (3.8)'te korelasyon ile ana görüntü içinde

aramak amacıyla seçilen örnek punta kaynak görüntüsü görülmektedir.



Şekil 3.7. Korelasyon için ana görüntü olarak seçilen karoseri görüntüsü üzerinde punta kaynaklar ve saplamalar




Şekil 3.8. Örnek olarak seçilen punta kaynak görüntüsü

Geliştirilecek uygulamada, seçilecek punta kaynak görüntülerinin, Şekil (3.7)'de örneği görülen, karoseri üzerinden alınan ana görüntüler içinden seçilerek belirlenmesi düşünüldü. Çünkü her ana görüntü içindeki punta kaynak görüntüleri, karoseri yüzeyinin o bölgesine özgüdür ve farklılık göstermektedir. Bu nedenle Şekil (3.8)'te görülen punta kaynak görüntüsü, ana görüntüden görüntü kırpma yöntemiyle elde edildiği için bulanık görünmektedir.

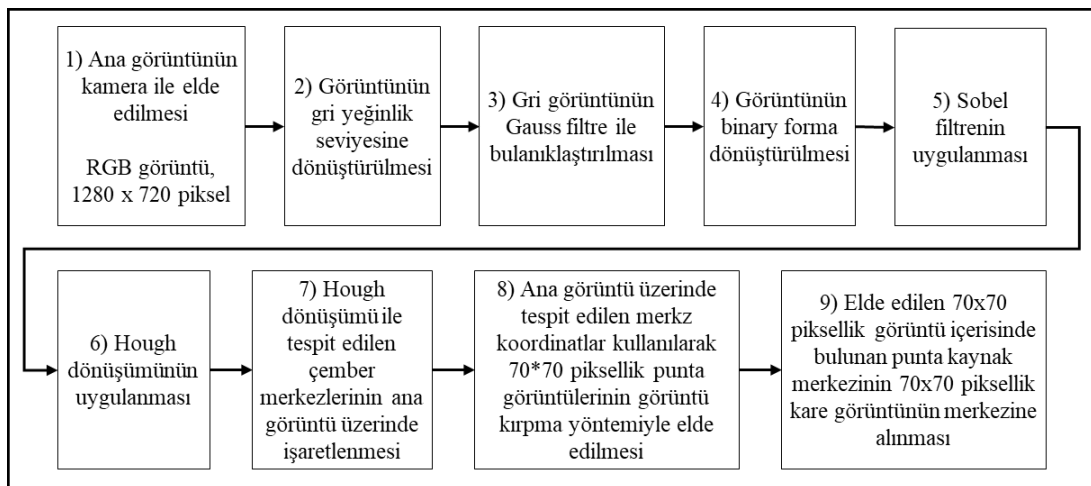
Uygulanan korelasyon sonucunda elde edilen sayısal sonuçlar görselleştirildi ve Şekil (3.9)'da görülen sonuç elde edildi. Şekil (3.9)'da görülen üç boyutlu görüntü detaylı incelendiğinde, korelasyon sonucunun 1 sayısal değerine yakın olduğu koordinatlarda, ana görüntü üzerinde punta kaynak görüntüsü yanında saplama görüntülerinin de bulunduğu görüldü. Üretimin ilerleyen aşamalarında, saplamalar üzerine kablo taşıyıcı gibi parçalar, somun ile monte edilmektedir. Karoseri üzerinde saplamalar, karoseri sac yüzeyine kaynak yapılarak sabitlenmektedir. Korelasyon sonucunda sayısal değer olarak yüksek çıkan bu koordinatlar, punta kaynak olmadıkları için istenmemektedir. Ayrıca,

korelasyon sonucunda punta kaynak görüntülerine benzeyen fakat punta kaynak olmayan farklı görüntü parçaları da tespit edildi. Tüm bu punta kaynak olmayan görüntülerin ayıklanması ilave işlem gerektirdi. Bu nedenle punta kaynakların tespitinde korelasyon uygulamasına devam edilmedi.



Şekil 3.9. Karoseri yüzey görüntüsü ile punta kaynak görüntüsü korelasyon sonucunun 3 boyutlu görünümü

Punta kaynaklar, görüntü olarak genellikle dairesel formdadır, fakat karoseri üzerinde bulunan tüm punta kaynaklar aynı formda ve aynı şekilde değildir. Punta kaynak görüntülerinin form ve şekil farklılıklarından bağımsız olarak tespit edilebilmesi için görüntü işleme yöntemleri ve Dairesel Hough Dönüşümü (Ballard, 1981) kullanıldı. Dairesel Hough dönüşümünün karoseri yüzeyinden alınan ana görüntüler üzerinde uygulanması öncesinde, ana görüntü üzerinde hazırlık işlemleri yapıldı. Uygulanan algoritma Şekil (3.10)'da görülmektedir.



Şekil 3.10. Ana görüntüden punta kaynakların elde edilmesi için uygulanan algoritma

Bu algoritmanın girdisi, karoseri yüzeyinden alınan 1280×720 piksel boyutlu ana

görüntüdür. Şekil (3.11)'de karoseri ön cam alt flanş bölgesinden alınan bir örnek görüntü görülmektedir.



Şekil 3.11. Karoserinin ön cam alt flanş bölgesinden alınan örnek görüntü

Şekil (3.11)'de görülen görüntü RGB formatındadır. Bu ana görüntü, gri ölçekli görüntüye dönüştürüldü. Dönüşüm sonrası Şekil (3.12)'de görülmektedir.



Şekil 3.12. Gri ölçekli görüntüye dönüştürülen ana görüntü

Ardından, bu görüntüye Gauss filtresi uygulanarak görüntü bulanıklaştırıldı. Elde edilen görüntü Şekil (3.13)'te verilmiştir.

Gauss bulanıklaştırma filtresi, Denklem (3.2)'de görüldüğü gibi;

$$H_{i,j} = \frac{1}{2\pi\sigma^2} e^{\left(-\frac{(i-(k+1))^2 + (j-(k+1))^2}{2\sigma^2}\right)} ; 1 \leq i, j \leq (2k + 1) \quad (3.2)$$

şeklindedir. Denklem (3.2)'de, Gauss filtre çekirdeği boyutu $(2k + 1) \times (2k + 1)$ şeklinde ifade edilir. Görüntüye uygulanan Gauss filtre çekirdeği 3×3 boyutludur. Bu nedenle Denklem (3.2)'de $k=1$ olarak alındı.




Şekil 3.13. Gauss filtresi ile bulanıklaştırılan ana görüntü

Ardından, 3×3 Gauss filtre ile bulanıklaştırılan görüntüye Sobel filtre uygulandı (Sobel, 1970). Görüntü üzerinde Sobel filtre uygulamak için kullanılan maskeler, Denklem (3.3)'te görüldüğü gibi;

$$S_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad S_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad (3.3)$$

şeklindedir. Sobel filtre uygulama öncesinde görüntünün Gauss filtre kullanılarak bulanıklaştırılmasının nedeni, Sobel filtrenin, görüntüde kenar olarak adlandırılan bölgeleri piksel yeğinlik değeri farkları üzerinden tespit etmesi ve bulanıklaştırılmamış görüntüde bulunan gürültü nedeniyle, Sobel filtre uygulama sonrasında, istenmeyen kenar geçişlerinin de tespit edilmesidir. Bunun önlenmesi için Sobel filtre uygulama öncesinde Gauss filtre ile görüntüdeki gürültü giderildi. Sobel filtre uygulama sonrasında elde edilen görüntü Şekil (3.14)'te görülmektedir.




Şekil 3.14. Sobel filtre uygulama sonrasında elde edilen görüntü

Bu aşamada, Gauss filtre çekirdeğinin 5×5 ve 7×7 gibi farklı çeşitleri de ana görüntüye

uygulandı. Fakat, ana görüntüde elde edilen yüksek bulanıklaşma nedeniyle, Sobel filtre uygulama sonrasında görüntüde, Şekil (3.14)'te görüldenden daha az düşey ve yatay kenarların tespit edildiği görüldü. Bunun ise daha sonra uygulanan dairesel Hough dönüşümü sonucunda, punta kaynakların tümünün tespit edilmemesine neden olduğu tespit edildi. Bu nedenle ana görüntüye bulanıklaştırma amacıyla 3×3'ten daha yüksek boyutlu çekirdekler uygulanmadı.

Şekil (3.14)'te görüldüğü üzere, Sobel filtre uygulama sonrasında, ana görüntü üzerinde punta kaynakların bulunduğu bölgelerde dairesel formlar, ikili (Binary) formdaki görüntü üzerinde elde edildi. Sonraki aşamada, bu görüntüye Dairesel Hough Dönüşümü uygulandı.

Hough dönüşümü, temelde bir görüntüdeki doğrusal formları yani kenarları tespit etmede kullanılmaktadır. Fakat bu dönüşüm, farklı formdaki şekillerin tespitinde de kullanılabilir. Dairesel Hough dönüşümü, dairesel formda konumlanan pikselleri tespit etmek amacıyla, belirli bir yarıçaptan başlayıp belirli bir yarıçapa kadar çemberler oluşturup, bu çemberlerin dairesel formda yan yana gelmiş pikseller ile belirli bir oranda uyuşması ve bunların birer çember olarak tespit edilmesi esasına dayanmaktadır. Bu işlem oylama (Voting) olarak adlandırılır. Bu çalışmada, dairesel Hough dönüşümü için referans yarıçaplar $R_{min} = 16$ ve $R_{max} = 30$ piksel olarak alındı. Dairesel Hough dönüşümü sonrasında tespit edilen dairesel formlu piksellerin Sobel filtre uygulanmış görüntü üzerindeki yerleşimleri Şekil (3.15)'te görülmektedir.




Şekil 3.15. Dairesel Hough dönüşümü sonrasında elde edilen çemberler



Şekil 3.16. Ana görüntü üzerinde tespit edilen punta kaynaklar

Bu koordinatların ana görüntü üzerinde işaretlenmesi ile tespit edilen punta kaynak koordinatları görselleştirildi. Şekil (3.16)'da ana görüntü üzerinde tespit edilen punta kaynak koordinatları görülmektedir. Şekil (3.16)'da, ana görüntü üzerinde punta kaynak olmayan, karoseri yüzeyindeki diğer delikler ve bu deliklere kaynak ile sabitlenmiş somunlar gibi dairesel formda olan görüntülerin de tespit edildikleri görüldü. Bu tip görüntüler, punta kaynak görüntüsü olmadıkları için ayrı bir sınıf olarak tanımlandı.



Şekil 3.17. Kameranın konumu ve yanlardaki görüntülerin deformasyonu

Hough dönüşümünde kullanılan R_{min} ve R_{max} değerlerinin belirlenmesinde görüntünün


çözünürlüğü ve kameranın araç karoseri yüzeyine uzaklığı önemli faktörlerdir. Şekil (3.17)'de kameranın araç karoseri yüzeyine dik olacak şekilde konumlandırılmasının üstten görünüşü ve CMOS kamera sensörünün belirli bir açı ile örneklediği punta kaynak görüntülerinin CMOS sensör üzerindeki geometrik deformasyonu görülmektedir. Bu çalışmada, kamera ile araç yüzeyinden alınan ana görüntüler 1280×720 piksel boyutludur. Punta kaynak görüntüleri de 70×70 piksel boyutlu olarak belirlendi. Görüntünün trigonometrik deformasyonu, ana görüntünün ortası düşey merkez eksek olarak alınıp, ana görüntünün sağ yarısı üzerinden incelendi. Ana görüntünün yarısı ele alındığında X eksenini 640 piksel genişlikte olup, bu alana $640/70 = 9,14$ eşitliğinden hareketle 9 adet tam punta kaynak görüntüsü girebildiği görüldü. Her bir punta kaynak görüntüsünün, punta kaynağın merkezinden 10 mm'lik bir yarıçaplı bir alanı kapsadığı göz önüne alındığında, punta kaynak görüntüsünün bir kenarının araç karoseri yüzeyinde yaklaşık 20 mm'lik uzunluğa karşı geldiği belirlendi. Buna göre, kameranın araç karoseri yüzeyinden 20 cm uzaklıkta konumlandırılması, yani Şekil 3.12'de $X = 200 \text{ mm}$ olması ve $Y_2 = 9 \times 20 \text{ mm} = 180 \text{ mm}$ olması durumunda, $Y_1 = 180 - 20 = 160 \text{ mm}$ olarak elde edildi. Punta kaynak görüntüsünde 70 piksellik uzunluk yaklaşık 20 mm olduğu için punta kaynağın bulunduğu 30 piksellik bölge, yani $Z_1 = \frac{30}{70} \times 20 \cong 8,6 \text{ mm}$ olarak tespit edildi. α Açısı değeri, $\tan^{-1} \frac{200}{180}$ ifadesinden $\alpha \cong 48$ derece olarak bulundu. Bu durumda trigonometrik olarak kamera CMOS sensörü tarafından görülen punta kaynak görüntüsü uzunluğu $(\sin 48) \times 70 \cong 52$ piksel olarak ve bunun punta kaynağa ait görüntü uzunluğu da $Z_2 = 52 \times \frac{30}{70} \cong 22,3$ piksel olarak bulundu. $\frac{Z_2}{Z_1}$ Oranı üzerinden, kameranın örneklediği ana görüntüde yan uç taraflara denk gelen punta kaynak görüntülerinin boyutlarının, kameraya dik olarak konumlanan görüntü boyutlarına göre $1 - \frac{22,3}{30} \cong 0,26$ oranında, yani %26 daha küçük görüldüğü tespit edildi. Bu hesaplama, ana görüntünün sağ ve sol uç yanlarında görülen punta kaynak görüntülerin orijinal boyutlarına göre %26 deforme olduklarını gösterdi.

Bu nedenle R_{min} ve R_{max} değerleri, X değerinin yani kameranın yüzeye uzaklığının her zaman sabit 200 mm olarak ayarlanamayacağı, tespit edilen geometrik deformasyon durumu ve seri üretim şartlarında, punta kaynak makinelerinde uçluk aşınması veya makine çenelerinin yan basması gibi nedenlerle punta kaynakların daima aynı boyutta


üretilemeyeceği göz önüne alınarak, punta kaynak görüntüsündeki bu deformasyonu tolere edebilmek amacıyla $R_{min} = 16$ ve $R_{max} = 30$ olarak belirlendi.

3.3. Punta Kaynak Görüntülerinin Analizi ve Sınıflandırılması

Karoseri yüzeyinden alınan ana görüntü üzerinde tespit edilen punta kaynaklar, “uygun” ve “uygun olmayan” kaynak olarak sınıflandırıldı. Punta kaynak olmayan tespitler ise “punta kaynak olmayan” olarak sınıflandırıldı. Şekil (3.18)’de kaynak olmadığı halde dairesel formda olduğu için tespit edilen bir saplama örneği, Şekil (3.19)’da ise kaynak olmadığı halde dairesel formda olduğu için tespit edilen bir delik örneği görülmektedir. Bu gibi görüntüler “kaynak olmayan” olarak sınıflandırıldı.



Şekil 3.18. Tespit edilen bir saplama örneği




Şekil 3.19. Tespit edilen bir delik örneği

Punta kaynak görüntülerinin sınıflandırılması amacıyla çeşitli yöntemler geliştirilmiş ve uygulanmıştır. Burada önerilen yaklaşım, önce kaynak görüntülerinin tespit edilmesi ve geliştirilen sistem ile bu görüntülerin sınıflandırılıp tanıtılarak öğretilmesi, sonrasında sistemin seri kullanıma alınarak, seri üretim şartlarında tespit edilen punta kaynak görüntülerinin sistem tarafından sınıflandırılmasını sağlamaktır.

Punta kaynak görüntülerinin sınıflandırılması amacıyla görüntülerin benzerlikleri üzerinde çalışıldı. Görüntü benzerliklerinin belirlenmesi amacıyla görüntü öz nitelikleri tespit edildi. Görüntülerin öz nitelikleri olarak çeşitli yaklaşımlar denendi ve yapılan uygulamalar ile en uygun öz nitelikler belirlendi.

3.3.1. Analiz ve Sınıflandırma İçin Temel Özniteliklerin Kullanılması

Yapılan ilk çalışmalarda punta kaynak görüntüsü iç, dış ve sınır bölge olmak üzere 3 alana ayrıldı. Şekil (3.20)'de punta görüntüsü üzerinde tanımlanan bu bölgeler görülmektedir.




Şekil 3.20. Punta kaynak görüntüsünün bölgelere ayrılması

Şekil (3.15)'de, punta kaynak görüntüsü üzerinde, mavi renk ile gösterilen kaynak çemberi gösterildi. Dış bölge, kaynak çemberine dışarıdan teğet olarak geçecek şekilde kırmızı renkli karenin dışında kalan bölge olarak gösterildi. Kaynak çemberine içeriden çizilebilecek en büyük kare ile kaynak bölgesi tanımlandı. Dış kare ile iç kare arasında kalan bölge de kaynak sınır bölgesi olarak tanımlandı.

Bölgelere ayrılan punta kaynak görüntüsü üzerinde öz nitelikler olarak; iç bölge alanının (sarı renkli kare içinde kalan alanın) piksellerinin yeğlilik ortalaması S ve sınır bölgesinin (kırmızı renkli karenin içi ile sarı renkli karenin dışı) piksellerinin yeğlilik ortalaması K üzerinden $\frac{K}{S}$ oranı, iç bölge görüntüsünün histogramı ve iç bölgedeki piksellerin yeğlilik değerlerinin standart sapması alındı.


Görüntülere ait veriler üzerinden gerekli sınıflandırmanın yapılabilmesi amacıyla bir yapay sinir ağı kullanıldı. Yapay sinir ağına girdi olarak $\frac{K}{S}$ oranı, standart sapma ve

histogram verileri girildi. Böylece oluşturulan toplam girdi sayısı 258 adet olarak belirlendi. Oluşturulan yapay sinir ağı modeli Şekil (3.21)'de görülmektedir.



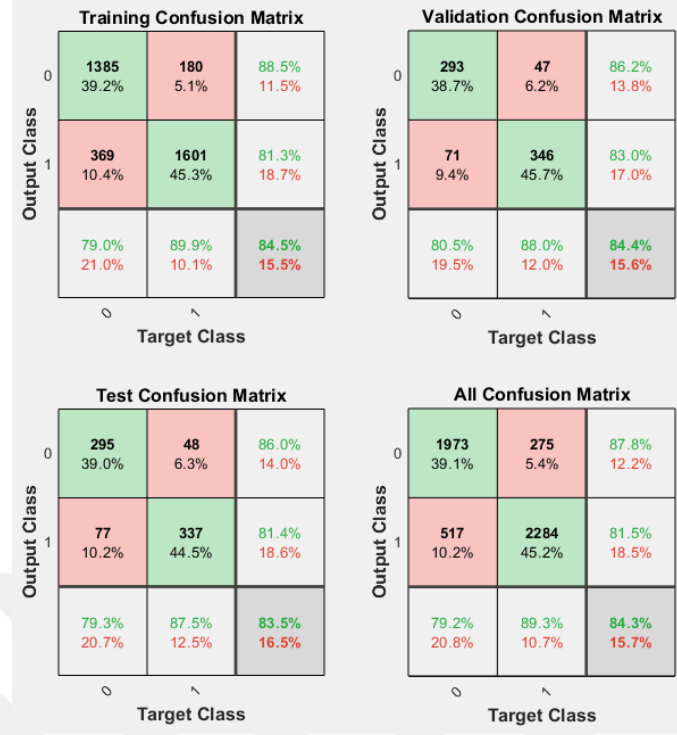
Şekil 3.21. İlk analiz kapsamında oluşturulan yapay sinir ağı modeli

Punta kaynaklara ait verilerin elde edilmesi amacıyla 284 adet karoseri yüzey görüntüsü alındı ve bu görüntülerden 5049 adet punta kaynak görüntüsü elde edildi. Bu görüntülerin göz kontrolü yapılarak ön sınıflandırılması tamamlandı ve sınıflandırılan bu veriler, Şekil (3.21)'de görülen geri yayılım (Backpropagation) eğitilmiş öğrenme modeli ile çalışan yapay sinir ağına eğitimde kullanılmak üzere girdi olarak verildi.



Şekil 3.22. Eğitim sonunda elde edilen hata histogramı

Bu veriler ile yapılan eğitim sonunda elde edilen hata histogramı Şekil (3.22)'de görülmektedir. Eğitim sonucuna göre elde edilen doğru ve hatalı tespitleri gösteren hata matrisi (Confusion matris) Şekil (3.23)'te görülmektedir.



Şekil 3.23. Doğru ve hatalı tespitlerin dağılımı


Şekil (3.23)'te görülen ve yapay sinir ağı eğitiminin başarısını gösteren matriste, eğitim, test ve validasyon başarımlarının birbirlerine çok yakın olduğu görüldü. Tüm sistemin başarısı %84,3 olarak tespit edildi. Bu başarı oranının, görüntülerin seçilen bu öz nitelikler ile sınıflandırılabilmesi açısından makul ve kabul edilebilir olduğu, fakat endüstriyel ortamda seri üretim şartlarında kullanılması planlanan bir sistem için yeterli olmadığı görüldü.

Tüm bunların yanında, piksel yeşinlik değerleri ile çalışmak, görüntü alınan yüzeyin aydınlatılmasında belirli bir stabilitenin ve sürekliliğin sağlanmasını gerektirmektedir. Çalışmanın yapıldığı alandaki aydınlatma sabit olacak şekilde, ulusal İş Sağlığı ve Güvenliği (İSG) yönetmeliklerine uygun olarak kuruldu. Ancak seri üretim şartlarında, kontrol alanı çevresinde çalışanların hareketi, diğer kabinlerin hareket ettirilmesi gibi nedenlerle kontrol edilen kabin yüzeyine yansıyan ışımaların, mevcut görüntü piksel yeşinlik değerlerini ± 3 sayısal değeri aralığında değiştirdiği gözlemlendi. Bu değişkenlik nedeniyle, sadece piksel yeşinlik değerleri üzerinden yapılan hesaplama dayalı görüntü özelliklerinin, görüntüleri sınıflandırmada, %90'ın üzeri olarak beklenen başarı seviyesini sağlamadığı tespit edildi.

3.3.2. Analiz ve Sınıflandıma İçin HOGs Verilerinin Kullanılması

HOGs (Histograms of Oriented Gradients) yöntemi, görüntünün tanımlayıcı (Descriptor) verilerini elde edip, aynı nesneye ait fakat farklı şartlarda alınmış görüntülerin aynı sınıfa dahil edilebilmesini sağlamak amacıyla kullanılan yöntemlerden biridir (Dalal ve diğ., 2005). Buradan hareketle, benzer görüntülerin aynı sınıfa dahil edilecek şekilde sınıflandırılabilmesi mümkün olacaktır. Yapılan çalışmalarda trafik işareti gibi değişmeyen görüntülerin sınıflandırılmasında bu yöntemin etkin olduğu görülmüştür. Fakat punta kaynak görüntüleri, robotik uygulamalarda dahi asla birbirinin aynı şekilde oluşmamaktadır. Bu nedenle, öncelikle punta kaynak görüntülerinin HOGs verileri kullanılarak sınıflandırılması çalışmasında, HOGs verileri arasında bir benzerlik tespit edilmeye çalışıldı.

Şekil (3.24)'te “uygun” sınıfına ait bir punta kaynak görüntüsünde tanımlanan kaynak bölgeleri görülmektedir. Buradaki bölgeler; 1) kaynak alanı dışındaki bölge, 2) kaynak alanı başlangıç çizgisi, 3) kaynak kenar bölgesi, 4) kaynak iç yüzeyinin başlama çizgisi, 5) kaynak içinde kalan iç bölge yani kaynak yüzeyi şeklinde tanımlandı. Punta kaynağın görüntü analizinde, değerlendirilmesi gereken alan olarak kaynak iç bölgesi seçildi. Bu nedenle, analiz edilecek kaynak görüntüsünde kaynak alanı dışında kalan bölgedeki piksellerin yeğlilik değerleri, HOG verilerinin oluşturulması sırasında sonuçları etkilememesi amacıyla sıfır (0) değeri ile değiştirildi. Bu durum, Şekil (3.25)'te görülmektedir.



Şekil 3.24. Uygun bir punta kaynak görüntüsünde tanımlanan kaynak bölgeleri




Şekil 3.25. Kaynak dış bölge piksel yeğlilik değerlerinin değiştirilmesi

Bu aşamada punta kaynak görüntüsü 56x56 piksel büyüklüğünde seçildi. Uygulanan HOG gradyanı ise 9x9 büyüklüğünde bir matris olarak belirlendi. HOGs uygulaması sonucunda $9 \times 9 \times 8 \times 2 = 1296$ sütunlu bir matris elde edildi. HOGs gradyanı 9×9 boyutlu bir matris olduğu için 1296 sütunlu matris içinde 9 sütunlu HOGs gradyan değerleri tekrar etmektedir. Bu nedenle 1296 sütunlu matris, 9'lu tekrar eden gruplar şeklinde ele alınarak sırayla, 1., 10., 19., ..., 1287. sütunlar toplandı ve 1. sütun olarak alındı. Benzer şekilde bu işlem tüm sütunlara uygulandı. Böylece 9 sütunlu bir veri tablosu elde edildi. Şekil (3.26)'da örnek bir punta kaynak görüntüsünde HOGs işleminin uygulanması ve sonrasında tekrar eden sütunların toplanarak birleştirilmesi ile elde edilen 9 sütunlu matris görülmektedir. Satır sayısı, örnek olarak alınan punta görüntüsü sayısıdır.

0,292493	0,335837	0,372322	0,316723	0,299038	0,339088	0,403552	0,35337	0,265696
0,239978	0,320459	0,397001	0,376603	0,354769	0,351108	0,361829	0,309562	0,253752
0,292351	0,357194	0,424064	0,364428	0,303451	0,294323	0,344445	0,315016	0,278782
0,30622	0,321105	0,299337	0,288599	0,249837	0,325669	0,40738	0,412301	0,354682
0,241293	0,335998	0,403345	0,384276	0,329334	0,30271	0,387935	0,320122	0,255855
0,297679	0,358629	0,380738	0,339692	0,266696	0,312391	0,362179	0,339427	0,327598
0,277598	0,364199	0,440587	0,375957	0,298649	0,31426	0,330991	0,296692	0,263261
0,266765	0,26909	0,33723	0,353264	0,366661	0,358152	0,355506	0,354623	0,321018
0,296323	0,350542	0,375931	0,316673	0,214001	0,296553	0,429621	0,365953	0,308983
0,288156	0,353103	0,39493	0,347155	0,344747	0,370449	0,326166	0,270843	0,282798


Şekil 3.26. HOGs işleminin uygulanması sonrasında elde edilen matris

Elde edilen bu veri, Şekil (3.27)'de şema olarak gösterilen yapay sinir ağına girdi olarak verildi ve yapay sinir ağı eğitildi. Bu yapay sinir ağı 9 girişli, 36 ara katmanlı ve 1 çıkış katmanı içerecek şekilde tasarlandı.



Şekil 3.27. HOGs verileri ile eğitilen yapay sinir ağı

Eğitim sonunda elde edilen hata histogramı Şekil (3.28)'de görülmektedir.



Şekil 3.28. HOGs verileri ile eğitilen yapay sinir ağının hata histogramı

Bu eğitime ait hata matrisi sonucu Şekil (3.29)'da verildi.

Training Confusion Matrix			Validation Confusion Matrix		
Output Class	0	1	Output Class	0	1
0	3 1.2%	0 0.0%	0 0.0%	0 0.0%	NaN%
1	15 6.0%	231 92.8%	4 7.4%	50 92.6%	7.4%
	16.7% 83.3%	100% 0.0%	0.0% 100%	100% 0.0%	92.6% 7.4%
Test Confusion Matrix			All Confusion Matrix		
Output Class	0	1	Output Class	0	1
0	0 0.0%	0 0.0%	3 0.8%	0 0.0%	100%
1	7 13.0%	47 87.0%	26 7.3%	328 91.9%	7.3%
	0.0% 100%	100% 0.0%	10.3% 89.7%	100% 0.0%	92.7% 7.3%

Şekil 3.29. HOGs verileri ile yapılan eğitime ait hata matrisi

Sonuçlar incelendiğinde, genel başarımlar oranının %92,7 seviyesinde olduğu görüldü.


Ayrıca, hatalı olarak sınıflandırılan verilere bakıldığında, Şekil (3.28)'de, sonuç değerinden -0,9 sapma görülen en az 20 adet veri olduğu görüldü. Böylece, hatalı sınıflandırmada oldukça uç değerlerde sapma olduğu tespit edildi. Birçok farklı punta kaynak görüntüsü ile yapılan denemelerde, sonucun farklı olmadığı, uç değerlerde sapma durumunun devam ettiği tespit edildi.

Ayrıca, HOGs algoritması, bir görüntüdeki piksel yeşinlik değerlerinin değişimine, her bir piksel yeşinlik değerinin komşu piksel yeşinlik değerlerinden ne kadar farklı olduğuna bağlı olarak bir sonuç üretmektedir (fark ve gradyan değerleri). Bu durum, görüntünün piksel yeşinlik değerlerinden, yani görüntünün genellikle düşük değerli pikseller veya açık değerli pikseller içermesinden bağımsızdır. Bu nedenle, sadece HOGs verileri kullanılarak bir görüntü sınıflandırması yapmanın, uygun olmayan görüntülerin de uygun kategorisinde çıkma olasılığının yüksek olmasına sebep olabileceği nedeniyle uygun görülmedi.

3.3.3. Görüntü Sınıflandırmada SIFT ve SURF Yöntemlerinin Uygulanması


Bir görüntünün ölçek, büyüklük gibi farklı görünüşleri üzerinde yapılan çalışmada (Lowe, 2004), bu görünüşler arasında güvenilir bir eşleşme sağlayabilmek amacıyla kullanılabilecek, görüntülerden ayırt edici değişmez özniteliklerin çıkartılmasına yönelik bir yöntem sunulmuş ve ölçek değişmez öznitelik dönüşümü (Scale Invariant Feature Transform - SIFT) olarak adlandırılmıştır. Bu çalışmada, genel olarak alınan bir görüntünün 500×500 piksel olması durumunda, görüntüler arasında bir eşleşme sağlanabilmesi için en az 3 özniteliğin doğru şekilde eşleşmesi gerektiği belirtilmiştir. Çalışma, görüntülerin tanınabilmesi amacıyla, önce bu görüntülerden elde edilen SIFT özniteliklerinin bir veri tabanında saklanması, daha sonra aynı görüntünün değişen formlarından elde edilen SIFT özniteliklerinin bu veri tabanındakiler ile karşılaştırılmasını ve eşleşme durumunda görüntünün sınıflandırılmasını içermektedir. Öznitelik karşılaştırma aşaması için hızlı en yakın komşuluk algoritması önerilmiştir. SIFT algoritması, ölçek-uzay ekstremum tespiti (Scale-Space Extrema Detection), anahtar nokta yerleştirilmesi (keypoint localization), yön ataması (orientation assignment) ve anahtar noktaların tanımlanması (keypoint descriptor) ana adımlarından oluşturulmuştur.

SIFT yöntemi, boyutsal veya yön açısından farklı olup aslında eş olan görüntülerin tespit edilmesinde hem hızlı çalışmıştır hem de yüksek başarımla elde edilmiştir. Bu yöntemin punta kaynak görüntüleri üzerinde uygulaması yapılmadan önce, bilinen bir görüntü üzerinde denemesi yapıldı. Şekil (3.30)'da deneme amacıyla seçilen yol tabelası görüntüsü ve bunun 90 derece döndürülmüş hali görülmektedir.



Şekil 3.30. SIFT uygulaması için örnek yol tabelası görüntüsü


Bu görüntüye uygulanan SIFT yöntemi sonucunda elde edilen anahtar noktaların görüntüler üzerindeki yerleri ve eşleşme sonuçları Şekil (3.31)'de verildi. Görüldüğü şekilde, bu yöntem ile birbirleri ile eş olan görüntülerin boyut, yön ve hatta eğiklikten bağımsız olarak tespit edilmesi kolayca gerçekleştirildi.



Şekil 3.31. Yol tabelası görüntüsünde tespit edilen ve eşleştirilen anahtar noktalar

Ardından bu yöntem, aynı robotik punta kaynak makinesinden elde edilen punta kaynaklara uygulandı. Şekil (3.32)'de SIFT yöntemi uygulanan punta kaynak görüntüleri görülmektedir.

Şekil (3.32)'de görüldüğü üzere, punta kaynak görüntülerinde tespit edilen anahtar noktalar, yeşil renk ile işaretlendi. Ardından bu iki görüntü üzerinde eşleşen anahtar noktaların tespiti yapıldı. Fakat, punta kaynakların aynı robotik kaynak makinesi tarafından aynı yüzeyde üretilmiş olmasına ve görüntülerin birbirlerine benzer olmalarına rağmen, eşleşen tanımlayıcılar (descriptor) tespit edilemedi. Şekil (3.33)'te bu eşleşme sonucu görülmektedir.



Şekil 3.32. (a) Ve (b) robotik punta kaynak makinesi ile üretilen punta kaynak görüntülerine SIFT yönteminin uygulanması




Şekil 3.33. SIFT yönteminin uygulanması sonucunda eşleşme elde edilememesi

Yukarıdakine benzer şekilde, farklı bir detektör-tanımlayıcı (descriptor) yaklaşımında, (Bay ve diğ., 2007) integral görüntüler kullanan bir Hessian matrisine dayanan detektör ile odaklanılan noktanın komşuluğundaki Haar dalgacık tepki dağılımını veren tanımlayıcı geliştirilmiştir. Bu yöntem hızlandırılmış gürbüz öznelilikler (Speeded-Up Robust Features; SURF) olarak adlandırılmıştır. Geliştirilen algoritma, hızlı çalışması ve güvenilir olmasıyla diğerlerinden ayrılmıştır. Bunu sağlamak için dedektörde, basitçe DoG (Difference of Gaussian) yaklaşımı kullanılmıştır. Burada da hızlı çalışma için integral görüntülerden yararlanılmıştır. İşlemlerde 64 boyut kullanılmış ve hesaplama – eşleştirme süresi görece azaltılmıştır. Bu durum algoritmanın güvenilirliğini de arttırmıştır.

SURF yönteminin amacı, aynı nesneye ait iki görüntü arasındaki eşleşmelerin bulunması olarak belirtilmiştir. Algoritma üç ana adımda; görüntülerdeki köşe ve T-bağlantıları gibi noktaların belirlenmesi, bu noktaların çevrelerinin bir özellik vektörü ile tanımlanması ve farklı görüntüler üzerinde oluşturulan bu vektörlerin eşleştirilmeleri şeklinde tanımlanmıştır.


SURF yönteminin punta kaynak görüntülerine uygulanarak bir eşleşme tespit edilmesi

öncesinde, bu yöntem de daha önce Şekil (3.30)'da verilen görüntü üzerinde uygulandı. Eşleşme sonucu Şekil (3.34)'te verildi.



Şekil 3.34. SURF yönteminin trafik işareti görüntüsüne uygulanması ve elde edilen eşleşmeler

Şekil (3.34)'te görüldüğü üzere, SURF yöntemi ile birbirinin eşi olan fakat boyut ve yön açısından farklı iki görüntü arasında çok sayıda eşleşme elde edildi. Bu yöntem de öncekine benzer şekilde aynı robotik kaynak makinesinden elde edilen birbirine benzer fakat farklı iki punta kaynak görüntüsüne uygulandı. Bu kaynak görüntülerine SURF yönteminin uygulanması ile ilgili sonuç Şekil (3.35)'te görülmektedir.



Şekil 3.35. (a) Ve (b) robotik punta kaynak makinesi ile üretilen punta kaynak görüntülerine SURF yönteminin uygulanması

Şekil (3.35)'te görüldüğü üzere, kaynak görüntülerinde SURF yöntemi ile herhangi bir tanımlayıcı elde edilemedi. Bunu takiben Şekil (3.36)'da da görüldüğü üzere, iki kaynak görüntüsü üzerinde SURF yöntemi ile bir eşleşme tespit edilemedi.



Şekil 3.36. SURF yönteminin uygulanması sonucunda tanımlayıcı ve eşleşme elde edilememesi

Bu sonuçlar, SIFT ve SURF yönteminin punta kaynak görüntüleri üzerinde uygulanamayacağını göstermektedir. Bunun en büyük nedeni, daha önce de belirtildiği gibi, aynı kaynak makinesi tarafından üretilmiş olsa da hiçbir punta kaynak görüntüsünün tamamen birbirinin eşi olmamasıdır.

3.3.4. Robotik Punta Kaynak Görüntülerinin Yapay Sinir Ağı Kullanılarak Sınıflandırılması

Punta kaynak görüntülerinin sınıflandırılmasında görüntülerin benzerlik ve farklılıklarından yola çıkılarak görüntünün kendisini girdi olarak alan ve bir sonuç üreten yapay sinir ağları da incelendi. Çok katmanlı yapılarıyla derin yapay sinir ağı (Deep Neural Network) olarak isimlendirilen bu ağlar, çalışma yöntemlerine göre farklı şekillerde tasarlanabilmektedir. Bu çalışmada evrimsel derin yapay sinir ağları üzerinde duruldu ve çalışmada bu tür bir yapay sinir ağı kullanıldı.

Evrimsel yapay sinir ağları (CNN) kategorisinde geliştirilen ilk ağlardan biri AlexNet olmuştur (Krizhevsky ve diğ., 2012). 227×227 Piksel renkli (RGB) formatında görüntüleri girdi olarak alabilen bu CNN, 1.000 farklı nesneyi sınıflandırabilecek şekilde eğitilmiştir. Bu çalışmada, AlexNet CNN, karoseri yüzeyinden alınan ana görüntülerde tespit edilen punta kaynak görüntülerine uyacak şekilde yeniden tasarlandı ve hiperparametreleri (Eğitimin gerçekleştirilmesi aşamasında yapay sinir ağına özgü parametreler) punta kaynak görüntüleri için uyumlandırıldı. Tablo 3.1’de AlexNet CNN katmanları detaylı olarak görülmektedir.

Giriş görüntülerinin 227×227 piksel olması nedeniyle AlexNet CNN’in orijinal haliyle kullanımı mümkün değildir.

Tablo 3.1. AlexNet CNN katmanları ve açıklamaları

Katman No	Katman Adı	Katman Açıklama
1	Giriş Görüntüsü	227x227x3 görüntüler (sıfır merkezli normalizasyon ile)
2	Evrişim	96 11x11x3 evrişim [4 4] aşım ve [0 0 0] dolgulama ile
3	ReLU	ReLU
4	Çapraz Kanal Normalizasyonu	her kanalda 5 elemanlı çapraz kanal normalizasyonu
5	Maks. Birikim	3x3 maksimum birikim [2 2] aşım ve [0 0 0] dolgulama ile
6	Gruplanmış Evrişim	2 gruplu 128 5x5x48 evrişim [1 1] aşım ve [2 2 2] dolgulama ile
7	ReLU	ReLU
8	Çapraz Kanal Normalizasyonu	her kanalda 5 elemanlı çapraz kanal normalizasyonu
9	Maks. Birikim	3x3 maksimum birikim [2 2] aşım ve [0 0 0] dolgulama ile
10	Evrişim	384 3x3x256 evrişim [1 1] aşım ve [1 1 1] dolgulama ile
11	ReLU	ReLU
12	Gruplanmış Evrişim	2 gruplu 192 3x3x192 evrişim [1 1] aşım ve [1 1 1] dolgulama ile
13	ReLU	ReLU
14	Gruplanmış Evrişim	2 gruplu 128 3x3x192 evrişim [1 1] aşım ve [1 1 1] dolgulama ile
15	ReLU	ReLU
16	Maks. Birikim	3x3 maksimum birikim [2 2] aşım ve [0 0 0] dolgulama ile
17	Tam Bağlanım	4.096 tam bağlanım katmanı
18	ReLU	ReLU
19	Eleme	%50 eleme
20	Tam Bağlanım	4.096 tam bağlanım katmanı
21	ReLU	ReLU
22	Eleme	%50 eleme
23	Tam Bağlanım	1.000 tam bağlanım katmanı
24	Softmax	softmax
25	Sınıflandırılmış Çıktı	1.000 farklı sınıf içeren çıktı

Geliştirilen sistem ile yapılan denemelerde, geliştirilen algoritmanın işleyeceği görüntünün büyük olmasının işlem süresini uzattığı, fakat punta kaynak görüntüsünün 30x30 veya 50x50 piksel gibi boyutlarda görece küçük seçilmesi durumunda kaynak özelliklerini yeteri kadar iyi yansıtmadığı ve bu nedenle yeğlilik değişimine dayalı görüntü işleme işlemlerinin kaynak özelliklerini ayırt etmede yetersiz kaldığı görüldü. Bu sonuçlara dayanarak, punta kaynak görüntüleri için en uygun görüntü büyüklüğü olarak 70x70 piksel belirlendi. Yapılan değişiklikler ile AlexNet CNN yapısı tablo 3.2’de görüldüğü şekilde belirlendi.

Bu uyumlandırma değişiklikleri sonrasında, “uygun”, “uygun olmayan” ve “punta kaynağı olmayan” olarak sınıflandırılmış 70x70 piksel boyutlu görüntülerden 1.000’er adet seçildi ve önceden sınıflandırılmış olarak AlexNet’e girdi olarak verildi. Şekil (3.37)’de “uygun” olarak sınıflandırılmış punta kaynağı ve Şekil (3.38)’de “uygun olmayan” olarak sınıflandırılmış punta kaynağı örnek görüntüleri görülmektedir.

Tablo 3.2. Yapılan değişiklikler sonrasında AlexNet CNN yapısı

Katman No	Katman Adı	Katman Açıklama
1	Giriş Görüntüsü	70x70x3 görüntüler (sıfır merkezli normalizasyon ile)
2	Evrişim	3 3x3 evrişim [2 2] aşım ve [1 1 1 1] dolgulama ile
3	ReLU	ReLU
4	Çapraz Kanal Normalizasyonu	her kanalda 5 elemanlı çapraz kanal normalizasyonu
5	Maks. Birikim	3x3 maksimum birikim [2 2] aşım ve [0 0 0 0] dolgulama ile
6	Gruplanmış Evrişim	2 gruplu 35 3x3 evrişim [1 1] aşım ve [1 1 1 1] dolgulama ile
7	ReLU	ReLU
8	Çapraz Kanal Normalizasyonu	her kanalda 5 elemanlı çapraz kanal normalizasyonu
9	Maks. Birikim	3x3 maksimum birikim [2 2] aşım ve [0 0 0 0] dolgulama ile
10	Evrişim	120 3x3 evrişim [1 1] aşım ve [1 1 1 1] dolgulama ile
11	ReLU	ReLU
12	Gruplanmış Evrişim	2 gruplu 60 3x3 evrişim [1 1] aşım ve [1 1 1 1] dolgulama ile
13	ReLU	ReLU
14	Gruplanmış Evrişim	2 gruplu 40 3x3 evrişim [1 1] aşım ve [1 1 1 1] dolgulama ile
15	ReLU	ReLU
16	Maks. Birikim	3x3 maksimum birikim [2 2] aşım ve [0 0 0 0] dolgulama ile
17	Tam Bağlanım	9 tam bağlanım katmanı
18	ReLU	ReLU
19	Eleme	%50 eleme
20	Tam Bağlanım	9 tam bağlanım katmanı
21	ReLU	ReLU
22	Eleme	%50 eleme
23	Tam Bağlanım	3 tam bağlanım katmanı
24	Softmax	softmax
25	Sınıflandırılmış Çıktı	3 farklı sınıf içeren çıktı




Şekil 3.37. Uygun punta kaynağı örnek görüntüsü




Şekil 3.38. Uygun olmayan punta kaynağı örnek görüntüsü

Eğitim sonunda, uyarlanmış AlexNet'in başarı seviyesinin %33 olduğu görüldü. Seçilen görüntüler ve AlexNet CNN'in bu parametreleri ile yapılan denemede elde edilen sonuçlar, %33 değerinden daha yükseğe çekilemedi. Şekil 3.39'da AlexNet CNN'de yapılan ilk değişiklik sonrasında yapılan eğitimin sonucu görülmektedir.



Şekil 3.39. AlexNet CNN’de yapılan ilk değişiklik sonrasında yapılan eğitimin sonucu

Eğitim başarısının düşük olmasının nedenleri incelendiğinde, 9. katman ve sonrasında oluşan 8×8 matris boyutlarının, görüntü üzerinde yeterince ayırt edici öz nitelik oluşturma olasılığının düşük olması, ayrıca 17. ve sonrasındaki katmanlarda oluşan 1×9 hücre boyutlu katmanlardaki çözünürlüğün yetersiz olması tespit edildi. Sonrasında, 17. tam bağlanım katmanında kanal sayısı 9’dan 80’ye, 20. tam bağlanım katmanında ise kanal sayısı 9’dan 20’ye çıkartıldı. Yapılan değişiklikler Tablo (3.3)’te görüldüğü şekildedir. Bu değişiklikler ile CNN tekrar eğitildi ve Şekil (3.40)’ta görüldüğü şekilde, %91 eğitim başarı seviyesi elde edildi.



Şekil 3.40. CNN yapısında yapılan 2. değişiklik sonrasında elde edilen başarı

Tablo 3.3. CNN yapısında yapılan değişiklikler sonrası katmanların yapısı

Katman No	Katman Adı	Katman Açıklama	Aktivasyonlar
1	Giriş Görüntüsü	70x70x3 görüntüler (sıfır merkezli normalizasyon ile)	70x70x3
2	Evrişim	3 3x3 evrişim [2 2] aşım ve [1 1 1 1] dolgulama ile	35x35x3
3	ReLU	ReLU	35x35x3
4	Çapraz Kanal Normalizasyonu	her kanalda 5 elemanlı çapraz kanal normalizasyonu	35x35x3
5	Maks. Birikim	3x3 maksimum birikim [2 2] aşım ve [0 0 0 0] dolgulama ile	17x17x3
6	Gruplanmış Evrişim	2 gruplu 35 3x3 evrişim [1 1] aşım ve [1 1 1 1] dolgulama ile	17x17x105
7	ReLU	ReLU	17x17x105
8	Çapraz Kanal Normalizasyonu	her kanalda 5 elemanlı çapraz kanal normalizasyonu	17x17x105
9	Maks. Birikim	3x3 maksimum birikim [2 2] aşım ve [0 0 0 0] dolgulama ile	8x8x105
10	Evrişim	120 3x3 evrişim [1 1] aşım ve [1 1 1 1] dolgulama ile	8x8x120
11	ReLU	ReLU	8x8x120
12	Gruplanmış Evrişim	2 gruplu 60 3x3 evrişim [1 1] aşım ve [1 1 1 1] dolgulama ile	8x8x120
13	ReLU	ReLU	8x8x120
14	Gruplanmış Evrişim	2 gruplu 40 3x3 evrişim [1 1] aşım ve [1 1 1 1] dolgulama ile	8x8x80
15	ReLU	ReLU	8x8x80
16	Maks. Birikim	3x3 maksimum birikim [2 2] aşım ve [0 0 0 0] dolgulama ile	3x3x80
17	Tam Bağlanım	80 tam bağlanım katmanı	1x1x80
18	ReLU	ReLU	1x1x80
19	Eleme	%50 eleme	1x1x80
20	Tam Bağlanım	20 tam bağlanım katmanı	1x1x20
21	ReLU	ReLU	1x1x20
22	Eleme	%50 eleme	1x1x20
23	Tam Bağlanım	3 tam bağlanım katmanı	1x1x3
24	Softmax	softmax	1x1x3
25	Sınıflandırılmış Çıktı	3 farklı sınıf içeren çıktı	-

Tablo 3.4. AlexNet CNN'in eğitiminde kullanılan hiperparametreler

Ağ Eğitim Parametreleri	Toplam görüntü sayısı:	1000
	Eğitim için kullanılan görüntü sayısı:	800
	Eğitim ve validasyon görüntülerinin seçimi:	Rastgele (Random)
	SGDM için Momentum başlangıç değeri:	0.9
	Öğrenme oranı:	0.001
	Maksimum Epok:	3000
	Görüntülerin karıştırılması:	Her epokta.
	Validasyon verisinin kaynağı:	Görüntü verilerinden kullanılacak
	Validasyon test sıklığı:	5
	Ağ öğrenme / çözümleme mekanizması:	SGDM (Momentum optimizasyonu ile stokastik gradyan azaltma)

Bu uygulamalar sırasında, görüntülerin hangilerinin eğitim, hangilerinin validasyon


amacıyla kullanılacağıın belirlenmesi parametresi “rastgele” olarak seçildiği için her eğitim denemesinde, 1000’er adet görüntüden rastgele seçilen 800 adedi eğitim, kalan 200 adedi ise validasyon amacıyla kullanıldı. Böylece, eğitim prosesi her tekrarlandığında, rastgele seçimin etkisiyle, farklı görüntüler test ve validasyon için seçildi. Bu nedenle, şekillerde sonuçları görülen eğitimler tekrarlanarak tüm CNN yapısı, aynı parametreler ile 10’dan fazla kez tekrar eğitildi. Eğitim süreçleri sonucunda, özellikle ikinci kez yapılan ağ yapısı değişikliğinden sonra, minimum %90, maksimum %92 aralığında eğitim başarı sonuçları elde edildi.

Buraya kadar yapılan çalışmalarda, araç karoserisinden alınan görüntülerde ağırlıklı olarak karoserinin robotik uygulamalar ile yapılan punta kaynak bölgeleri (örneğin arka duvar yüzeyi) üzerinde duruldu. Ancak bir aracın karoseri yüzeyi, sadece robotik uygulamalar ile gerçekleştirilen punta kaynakları içermemektedir. Bunların yanında, bir çalışan tarafından kullanılan punta kaynak makinesi ile gerçekleştirilen kaynaklar da bulunmaktadır. Bu nedenle, takip eden çalışmalarda bir çalışan tarafından el ile (manuel) yapılan punta kaynakları içeren bölgelerden alınan görüntüler üzerinde çalışıldı. Bu görüntüler ile uyumlandırılmış AlexNet CNN kullanılarak sınıflandırma çalışmaları yapıldı. Bu tür manuel punta kaynak görüntüleri, daha önce üzerinde çalışılan robotik kaynak görüntülerinden farklı olduğu tespit edildi. Önceki punta kaynak görüntülerinde “uygun olmayan” olarak sınıflandırılan bir görüntü, manuel punta kaynak yapılan bölgelerde ön değerlendirme aşamasında “uygun” olarak sınıflandırılabilir. Bunun en temel nedeni, kullanılan kaynak makinelerinin ve uygulanan kaynak proseslerinin farklılıklardır. Bu nedenle, yapılan çalışmalarda öncelikle punta kaynak görüntülerinin sadece uyumlandırılmış AlexNet ile sınıflandırılabilirliği incelendi.

3.3.5. Manuel Punta Kaynak Görüntülerinin Yapay Sinir Ağı Kullanılarak Sınıflandırılması

Çalışmanın bu aşamasında, karoseri yüzeyi üzerinde bir çalışan tarafından punta kaynak makinesi kullanılarak oluşturulan punta kaynaklara ait görüntüler üzerinde çalışıldı. Bu görüntüler, kabin yüzeyinde farklı bölgelerden elde edildi ve bir ön sınıflandırmadan geçirildi, yani hangi punta kaynak görüntüsünün hangi sınıfa ait olduğu belirlendi. Her sınıf için 1.000 adet görüntü olmak üzere toplam 3.000 adet punta kaynak görüntüsü üzerinde çalışıldı. Ardından katman yapısı Tablo (3.3)’te verilen uyumlandırılmış

AlexNet CNN ile bu görüntüler üzerinde eğitim çalışması gerçekleştirildi. Hiperparametrelerde bir değişiklik yapılmayarak, Tablo (3.4)'te verilen hiperparametre değerleri uygulandı.



Şekil 3.41. Manuel punta kaynak görüntüleri ile yapılan eğitim

Bu eğitimin sonucunda %64,28 başarımları elde edildi. Bu görüntü seti üzerinde yapılan çok sayıda eğitim denemesi sonrasında başarımları olarak %60 - %70 aralığında değerlere ulaşıldı.

Yapılan detaylı incelemelerde, eğitimden önceki ön sınıflandırma işlemi sırasında, “uygun” sınıfına ait bazı punta kaynaklara görsel olarak benzeyen ve karoseri yüzeyindeki farklı bölgelerde “uygun olmayan” olarak sınıflandırılan punta kaynak görüntüleri olduğu tespit edildi. Benzer şekilde, ön sınıflandırma işlemi sırasında “uygun olmayan” olarak sınıflandırılan punta kaynak görüntülerine görsel olarak benzeyen ve karoserinin farklı bölgelerinde “uygun” olarak tanımlanan punta kaynak görüntüleri bulunduğu görüldü. Görsel olarak birbirine benzeme durumu incelendi. Punta kaynak görüntülerinin piksel yoğunluk değerleri açısından birbirlerine benzer, yani yaklaşık değerler içerdikleri, hatta görüntünün yaklaşık aynı bölgelerinde birbirlerine yakın piksel yoğunluk değerleri içerdikleri tespit edildi. Şekil (3.42)'de bu durumda olup piksel

yeğinlik değerleri birbirlerine yakın olan fakat farklı sınıflarda tanımlanan kaynak görüntüleri görülmektedir.



Şekil 3.42. Yeğinlik değerleri birbirine yakın olan (a) "uygun olmayan" olarak sınıflandırılan, (b) "uygun" olarak sınıflandırılan punta kaynak görüntüleri

Buna benzer durumlar nedeniyle uyumlandırılmış AlexNet CNN'in başarımları beklenen değerler olan %90 ve üzeri değil, görece daha düşük oranlar olarak elde edildi. Bununla birlikte, punta kaynak görüntülerinin ön değerlendirmesi aşamasında olası yanlış sınıflandırma durumlarına karşı kaynak tekniği uzmanlarından destek alındı. Ayrıca, olası bir hatalı ön sınıflandırma durumunun engellenmesi amacıyla sınıflandırılan kaynaklar karşılıklı kontrol edildi. Yine başarımlarını arttırma amacıyla uyumlandırılmış AlexNet CNN'e ait hiperparametre değerlerinde de değişiklikler yapıldı ve eğitimler tekrarlandı. Yapılan bir çok eğitim denemesinde, %60 - %70 aralığında sonuçlar elde edildi ve bunun üzerine çıkılamadı.

Elde edilen başarımları, böyle bir sistemin seri üretim şartlarında kullanımı için yeterli olmayıp, yukarıda belirtilen riskleri içermesi nedeniyle, punta kaynak görüntülerinin CNN ile doğrudan sınıflandırılması kapsamında daha farklı bir yaklaşım üzerinde çalışıldı. Bu yaklaşımda, karoserinin belirli bölgelerinden alınan manuel punta kaynakları için ayrı ayrı sınıflandırma işlemleri yapıldı.

3.3.6. Bölgesel Seçilen Manuel Punta Kaynak Görüntülerinin Yapay Sinir Ağı Kullanılarak Sınıflandırılması

Çalışmanın bu aşamasında, karoseri yüzeyi üzerinde çeşitli bölgelerde bulunan ve manuel yöntemle (bir çalışan tarafından punta kaynak makinesi kullanılarak) oluşturulan kaynak görüntülerinin uyumlandırılmış AlexNet CNN ile sınıflandırılması üzerinde çalışıldı.


Bu yaklaşımda, farklı bölgelerdeki kaynakların farklı manuel punta kaynak makineleriyle ve farklı çalışanlar tarafından oluşturulduğu göz önüne alındı. Böylece, farklı sınıflardaki benzer görüntülerin temel nedenini bu durumun oluşturduğu, seri üretim tesislerinde

yapılan incelemeler sonucunda tespit edildi.

Ayrıca, farklı bölümlerden alınan punta kaynak görüntülerinin oluşturduğu girdi görüntüleri veri kümesinin çok büyük olması -ki bu çalışmada her bir sınıfa ait 1.000 adet görüntü ile çalışılmıştır- görüntüler arasında benzer piksel yoğunluk değerine sahip olup farklı sınıflara ait olan görüntü olma olasılığını da arttırdığı gözlemlendi.

Bu bölümde, manuel yöntemle oluşturulan punta kaynaklar içeren karoserinin ön cam alt flanş bölgesi üzerinde çalışıldı. Karoserinin bu bölümünde yaklaşık 60 adet punta kaynak görüntüsü ile çalışıldı. Fakat, örnekler daha fazla sayıda kabinden alındığı için aynı bölge olmak üzere daha fazla sayıda kaynak görüntüsü elde edildi.

Ön cam alt flanş bölgesinden ana görüntüler alındı ve bunların üzerindeki punta kaynak alt görüntüleri tespit edildikten sonra ana görüntüden 70×70 piksel punta kaynak görüntüleri olacak şekilde kesilerek alındı (Cropping işlemi). Eğitim için Tablo (3.3)'te verilen uyumlandırılmış AlexNet CNN kullanıldı. Eğitim işlemi öncesinde “uygun”, “uygun olmayan” ve “punta kaynak olmayan” şeklinde 3 sınıf olarak görüntüler sınıflandırıldı. Çalışmanın bu aşamasında her bir sınıftan 55 adet olmak üzere toplam 165 adet görüntü kullanıldı.



Şekil 3.43. Ön cam alt flanş bölgesinden alınan punta kaynak görüntülerinin eğitim sonucu

Şekil (3.43)'te ön cam alt flanş bölgesinden alınan punta kaynak görüntülerinde gerçekleştirilen eğitimin başarımları oranı görülmektedir. Bu eğitimde %77,54 başarımları oranına ulaşıldı. Aynı görüntü veri kümesi ve aynı CNN ile yapılan eğitim denemelerinde %72 ile %78 aralığında başarımları oranlarına ulaşıldı.

Elde edilen bu başarımları oranlarının, manuel punta kaynak görüntülerinin tümü ile yapılan eğitimde elde edilen başarımları oranlarından daha yüksek olduğu görüldü. Fakat halen, böyle bir sistemin gerçek üretim şartlarında kullanımı için gerekli başarımları oranlarına ulaşamadığı tespit edildi.

Uyumlandırılmış AlexNet CNN ile yapılan ve doğrudan punta kaynak görüntülerinin sınıflandırıldığı eğitim çalışmalarında, başarımları sonucuna etki eden en önemli faktörün görüntü piksel yoğunluk değerleri olduğu, yapılan çok sayıda deneme çalışması ile tespit edildi. Bu tespit doğrultusunda, punta kaynak görüntüsünde piksel yoğunluk değerleri üzerinden oluşturulabilecek ve görüntülerin sınıflandırılmasında kullanılabilecek görüntü özelliklikleri incelendi. Sonraki bölümde bu konu üzerinde yapılan çalışmalar açıklandı.

3.3.7. Punta Kaynakların Sınıflandırılmasında Kullanılan Diğer Görüntü Özelliklikleri

Çalışmada şimdiye kadar, punta kaynakların sınıflandırılması amacıyla görüntünün kendisi, Şekil (3.20)'de gösterildiği gibi iç bölge alanının (sarı renkli kare içinde kalan alanın) piksellerinin yoğunluk ortalaması (S) ve sınır bölgesinin (kırmızı renkli karenin içi ile sarı renkli karenin dışı) piksellerinin yoğunluk ortalaması (K) üzerinden $\frac{K}{S}$ oranı, iç bölge görüntüsünün histogramı ve iç bölgedeki piksellerin yoğunluklarının standart sapması veri olarak kullanıldı.

Çalışmanın bu aşamasında, punta kaynak görüntüleri üzerinde daha önce Şekil 3.20'de açıklanan bölge ayrımı değiştirildi. Karoseri yüzeyindeki punta kaynak görüntülerinin tespiti için uygulanan algoritmada, özellikle 9. aşama olan punta kaynak görüntüsünün 70×70 piksellik kare görüntü içerisinde merkezlenmesi, yani tespit edilen daire merkezinin kare formlu görüntünün merkezi yapılması ve punta kaynak görüntüsünün kare formlu görüntünün merkezine alınması sayesinde punta kaynak görüntülerinin, daima 70×70 piksellik görüntü alanı içerisinde olduğu, bu çalışmada daha önce tespit

edilmişti. Elde edilen birçok punta kaynak görüntüsünde yapılan incelemelerde punta kaynak iç bölgesi başlangıcının, yani kaynağın etki ettiği ve analiz edilmesi gereken bölgenin, kaynak merkezinden 23 piksel uzakta başladığı tespit edildi. Punta kaynak görüntüsünün kare formulu görüntü alanı içerisinde merkezlenmesi sayesinde oluşan bu durumun, punta kaynak görüntü analizinde büyük fayda sağladığı görüldü.

Sonraki aşamada, punta kaynak görüntülerinde 23 piksel yarıçapın dışında kalan görüntü alanındaki piksel yeğlilik değerleri 100 sayısal değerine eşitlendi. Geliştirilen algoritmada dışarıda kalan bu bölge piksellerine ait yeğlilik değerleri kullanılmıyor olsa da punta kaynak görüntüsü histogramı, 70x70 piksellik kare görüntü üzerinden elde edildiği için bu alanda kalan piksellerin yeğlilik değerlerini “0” veya “255” değerlerine eşitlemenin histogramda yanıltıcı bir etki yarattığı görüldü (histogramda, görüntüde olmamasına rağmen çok sayıda aşırı karanlık veya aşırı aydınlık piksel sayısı görülmesi durumu). Ayrıca, histogram sonucunu etkilememesi amacıyla histogram grafiğinde 100 numaralı sütunun değeri, 99 ve 101 numaralı sütunların değerlerinin ortalaması olarak değiştirildi. Bu işlemin yapılmaması durumunda, 100 numaralı sütuna ait histogram verisinin diğer sütunlara göre yanıltıcı şekilde aşırı yüksek elde edildiği görüldü. Şekil (3.44)’te ana görüntüden elde edilen punta kaynak görüntüsü ve aynı görüntüde kaynak iç bölgesi dışındaki alanda bulunan piksellerin yeğlilik değerinin 100 sayısal değerine eşitlenmesi durumundaki görüntü görülmektedir.




Şekil 3.44. Kaynak iç bölgesi dışında kalan alanda; (a) görüntünün orijinal hali, (b) piksel yeğlilik değerlerinin 100 sayısal değerine eşitlenmesi durumu

Bu sayede, punta kaynak görüntü analizinde doğrudan iç bölgede kalan ve punta kaynak kalitesini yansıtan görüntü alanı üzerinde duruldu. Görüntünün sınıflandırılmasında kullanılmak üzere seçilen temel görüntü parametreleri, punta kaynak iç görüntüsünün piksel yeğlilik ortalama değeri (ortalama), piksel yeğlilik standart sapma değeri (std. sapma), varyans katsayısı $\left(= 100 \times \frac{\text{standart sapma}}{\text{ortalama}}\right)$, piksel yeğlilik mod değeri (mod), piksel yeğlilik medyan değeri (medyan), piksel yeğlilik değerleri medyan oranı

$\left(\text{medyan oranı} = 100 \times \left| \frac{(\text{mod değeri} - \text{medyan değeri})}{\text{medyan değeri}} \right| \right)$, 70×70 punta görüntüsüne uygulanan Harris köşeleri (Harris corners) (Harris ve diğ., 1988) tespiti sonuncunda bulunan Harris köşe sayısı (Harris), 70×70 punta görüntüsü histogramının en yüksek değeri (hist. 1 max), bu değer histogram grafiğinde X eksenindeki koordinatı (hangi piksel yeğlilik değerinin en çok kez tekrar ettiği) (X_1), histogramdaki ikinci en yüksek değer (hist. 2 max.), ikinci en yüksek değerin X eksenindeki koordinatı (X_2), histogramda en yüksek birinci ve ikinci değerlerin X eksenindeki koordinatları arasındaki farkın X eksen uzunluğuna (256 değerine) oranı $\left(\text{oran} = \frac{|X_1 - X_2|}{256} \right)$ şeklindedir. Son parametre, birinci ve ikinci en yüksek değerlerin yerleri (yani hangi piksellerin en çok tekrar ettiği bilgisi) ile birlikte değerlendirilip görüntünün ağırlıklı olarak düşük değerli veya yüksek değerli pikseller içerdiğini gösteren bir parametre olarak kullanıldı. Böylece görüntüdeki punta kaynağın yanıklık, aşırı ısı altında kalmış olması veya yetersiz baskı kuvveti uygulanmış olması ve kaynağın zayıf olması gibi durumlar, piksel yeğlilik değerleri üzerinden tespit edilebilir hale getirildi.

Bu veriler, punta kaynak görüntüsünün temel parametreleri olarak elde edildi ve her bir sayısal veri, yan yana eklenerek [ortalama stdandard_sapma varyans_katsayısı mod medyan medyan_oranı Harris_köşeleri_sayısı hist_1_max X_1 hist_2_max X_2 oran] şeklinde bir dizi oluşturuldu. Her bir görüntüden elde edilen bu dizi verileri ile 12 sütunlu ve satır sayısı da eğitimde kullanılan punta kaynak görüntüsü sayısı kadar olacak şekilde bir matris elde edildi. Tablo (3.5)'te bu şekilde oluşturulan 21 adet kaynak görüntüsü için örnek matris verileri görülmektedir.



Şekil 3.45. Punta kaynak görüntüsünün histogramı

Şekil (3.45)'te örnek bir punta kaynak görüntüsünün histogramı görülmektedir.

Histogramda Y ekseninde 1. ve 2. en yüksek sayısal değerler arasındaki mesafenin oranı, görüntünün bir özelliği olarak kullanıldı.

Tablo 3.5. Temel parametreler matrisi

Orta-lama	Std. Sapma	Varyans Katsayısı	Mod	Medyan	Medyan Oranı	Harris Köşeleri Sayısı	Hist. 1. Max.	X ₁	Hist. 2. Max.	X ₂	Oran
138	18	13,04348	145	142	2,11268	18	68	146	65	143	0,01172
167	21	12,57485	170	171	0,58480	27	59	171	55	173	0,00781
168	17	10,11905	171	169,5	0,88496	28	57	172	48	174	0,00781
140	12	8,57143	137	139	1,43885	22	74	138	67	137	0,00391
172	16	9,30233	173	173	0,00000	29	55	174	48	181	0,02734
174	17	9,77011	168	173	2,89017	17	58	169	53	171	0,00781
170	37	21,76471	193	182	6,04396	29	43	194	39	186	0,03125
164	12	7,31707	166	166	0,00000	15	80	172	79	167	0,01953
81	16	19,75309	66	77	14,28571	16	71	67	59	69	0,00781
118	17	14,40678	115	118	2,54237	24	59	116	57	113	0,01172
148	23	15,54054	140	148	5,40541	27	40	142	37	141	0,00391
166	22	13,25301	186	171	8,77193	14	52	187	46	190	0,01172
161	24	14,90683	179	166	7,83133	20	50	180	45	181	0,00391
126	17	13,49206	132	127	3,93701	22	53	133	51	128	0,01953
160	22	13,75000	172	161	6,83230	23	42	173	40	151	0,08594
166	25	15,06024	189	169	11,83432	26	40	190	36	195	0,01953
128	27	21,09375	134	132	1,51515	25	43	135	40	130	0,01953
169	22	13,01775	170	169	0,59172	17	40	171	38	180	0,03516
154	30	19,48052	164	161	1,86335	30	55	165	53	161	0,01563
146	25	17,12329	145	150	3,33333	23	37	146	37	155	0,03516
177	18	10,16949	174	178	2,24719	13	62	175	58	179	0,01563

Tespit edilen bu 12 adet veri, punta kaynak görüntüsünün temel parametreleri olarak ele alındı ve bu veriler ile bir yapay sinir ağı eğitildi. Bu verilere ek olarak, punta kaynak görüntüsü üzerinde tespit edilen, 256 sütunlu histogram verileri de punta kaynak görüntüsünün ayırt edici bir özelliği olarak alındı ve bu verilerle de bir yapay sinir ağı eğitildi.

3.3.8. Harris Köşeleri Sayısının Değişimi Ve Punta Kaynak Görüntüsünde Tanımlayıcı Özellik Olarak Kullanılması

Harris köşelerinin varlığı, görüntüdeki piksel yeğlilik değerlerinde görülen keskin değişimlerin bir göstergesidir. Harris köşe algılama algoritması, Denklem (3.4)'teki gibi;

$$E(u, v) = \sum_{x,y} w(x, y) [I(x + u, y + v) - I(x, y)]^2 \quad (3.4)$$

ifade edilir. Bu denkleme Taylor açılımı uygulanıp ikinci terim geliştirilerek ifade Denklem (3.5)'teki gibi;

$$E(u, v) \approx [u \ v] M \begin{bmatrix} u \\ v \end{bmatrix} \quad (3.5)$$

elde edilir. Burada M , Denklem (3.6)'da görüldüğü şekilde;

$$M = \sum_{x,y} w(x, y) \begin{bmatrix} I_x I_x & I_x I_y \\ I_x I_y & I_y I_y \end{bmatrix} \quad (3.6)$$

ifade edilir. I_x ve I_y , sırasıyla x ve y yönlerine göre görüntünün türevlerini temsil eder. M matrisine dayalı olarak, bileşenlerinin pencerenin bir köşe içerip içermediğini gösterecek şekilde bir katsayı tanımlanır ve Denklem (3.7)'de görüldüğü şekilde

$$R = \det(M) - k(\text{trace}(M))^2 \quad (3.7)$$

ifade edilir. Bu eşitlikte $\det(M) = \lambda_1 \times \lambda_2$ ve $\text{trace}(M) = \lambda_1 + \lambda_2$ şeklindedir. Bu ifadelerde λ_1 ve λ_2 , M matrisinin özdeğerleridir. Burada $\lambda_1 \gg \lambda_2$ olması durumu görüntüde düşey kenarların olduğunu, $\lambda_2 \gg \lambda_1$ durumu ise görüntüde yatay kenarların olduğunu gösterir. λ_1 ve λ_2 değerlerinin görece çok büyük ve birbirine yakın olması durumu ise görüntüdeki köşeleri (corner) tanımlar.

Harris köşe tespit algoritmasının uygulandığı görüntüye bir eşik değeri uygulanması, eşik değerinin altındaki piksel yeğlilik değerlerinin 0 olarak ayarlanmasını sağlar. Eşik değeri, görüntüdeki en yüksek piksel yeğlilik değeri ile bir katsayının çarpılmasıyla Denklem (3.8)'deki gibi;

$$t = k \times \max(I(x, y)) \quad (3.8)$$


elde edilir. Denklem (3.8)'deki t eşik değeri kullanılarak Denklem (3.9)'da görülen;

$$I(x, y) = \begin{cases} 0 & I(x, y) \leq t \\ I(x, y) & I(x, y) > t \end{cases} \quad (3.9)$$

ifade ile görüntüdeki piksel yeğlilik değerlerinin tanımlanan eşik değerine göre


değiştirilmesi sağlanır. Bu durum, Harris köşe tespit algoritması ile tespit edilen köşelerin, görüntüde bir hassasiyet seviyesi veya görüntüde bir kalite seviyesi olarak tanımlanan eşik değerine göre yüksek veya az sayıda olmasını mümkün hale getirir.

Bu çalışmada, Harris köşe tespit algoritmasının bu özelliği kullanıldı. Punta kaynak görüntüleri üzerinde eşik değeri olarak k değişkeni, 0,001 ile 0,1 arasında değiştirilerek, her bir k değeri için tespit edilen Harris köşelerinin sayısı elde edildi ve bu veriler ile 100 elemanlı bir dizi oluşturuldu. Şekil (3.46)'da, kaynak merkezine odaklanabilmek amacıyla kaynak dış bölgesindeki piksel yeğlilik değerleri 100 sayısal değeri ile değiştirilmiş ve “uygun” olarak sınıflandırılmış bir punta kaynak görüntüsünden elde edilen 100 elemanlı Harris köşeleri değişimi görülmektedir.




Şekil 3.46. 100 Elemanlı Harris köşeleri değişimi dizisinin grafik gösterimi

Bu aşamada, kameradan alınan görüntülerdeki olası farklı aydınlanmalar nedeniyle görüntü piksel yeğlilik değerlerinde oluşabilecek değişimlerin Harris köşe sayısı değişimine etkisi incelendi. Şekil (3.47)'de bu amaçla piksel yeğlilik değerleri sırasıyla 20, 40, 60, 80 ve 100 azaltılarak oluşturulmuş yeni punta kaynak görüntüleri görülmektedir.



Şekil 3.47. Piksel yeğlilik değerleri azaltılarak elde edilen punta kaynak görüntüleri



Şekil 3.48. Yeğlilik değerleri değiştirilmiş punta kaynak görüntülerine ait Harris köşe sayıları değişimi grafiği

Bu punta kaynak görüntüleri kullanılarak elde edilen Harris köşe sayı değişimleri grafiği Şekil 3.43'te görülmektedir. Ardından elde edilen Harris köşe sayı değişimleri arasındaki korelasyon incelendi. İki değişkenli korelasyon Eşitlik (3.10)'da verildiği şekilde

$$\rho(A, B) = \frac{1}{N-1} \sum_{i=1}^N \left(\frac{A_i - \mu_A}{\sigma_A} \right) \left(\frac{B_i - \mu_B}{\sigma_B} \right) \quad (3.10)$$

ifade edilir. Buradan korelasyon sabiti matrisi de Eşitlik (3.11)'de görüldüğü şekilde

$$R = \begin{pmatrix} \rho(A, A) & \rho(A, B) \\ \rho(B, A) & \rho(B, B) \end{pmatrix} \quad (3.11)$$

yazılır. Çalışmanın bu aşamasında 6 farklı punta kaynak görüntüsü üzerinde korelasyon matrisi oluşturulduğu için ifade Eşitlik (3.12)'de görüldüğü şekilde


$$R = \begin{pmatrix} \rho(A, A) & \rho(A, B) & \rho(A, C) & \rho(A, D) & \rho(A, E) & \rho(A, F) \\ \rho(B, A) & \rho(B, B) & \rho(B, C) & \rho(B, D) & \rho(B, E) & \rho(B, F) \\ \rho(C, A) & \rho(C, B) & \rho(C, C) & \rho(C, D) & \rho(C, E) & \rho(C, F) \\ \rho(D, A) & \rho(D, B) & \rho(D, C) & \rho(D, D) & \rho(D, E) & \rho(D, F) \\ \rho(E, A) & \rho(E, B) & \rho(E, C) & \rho(E, D) & \rho(E, E) & \rho(E, F) \\ \rho(F, A) & \rho(F, B) & \rho(F, C) & \rho(F, D) & \rho(F, E) & \rho(F, F) \end{pmatrix} \quad (3.12)$$

genişletildi. Yapılan hesaplama sonucunda R matrisi, Eşitlik (3.13)'te görüldüğü şekilde;

$$R = \begin{pmatrix} 1,0000 & 1,0000 & 1,0000 & 0,9997 & 0,9993 & 0,9855 \\ 1,0000 & 1,0000 & 1,0000 & 0,9997 & 0,9993 & 0,9855 \\ 1,0000 & 1,0000 & 1,0000 & 0,9997 & 0,9993 & 0,9855 \\ 0,9997 & 0,9997 & 0,9997 & 1,0000 & 0,9994 & 0,9864 \\ 0,9993 & 0,9993 & 0,9993 & 0,9994 & 1,0000 & 0,9886 \\ 0,9855 & 0,9855 & 0,9855 & 0,9864 & 0,9886 & 1,0000 \end{pmatrix} \quad (3.13)$$

elde edildi. Burada A, B, C, D, E ve F ile sırasıyla punta kaynak görüntüsünün piksel değerlerinin değişmemiş hali ve ardından piksel yeğlilik değerlerinden 20, 40, 60, 80 ve 100 azaltılmış görüntüler ifade edildi. Sonuç matrisi incelendiğinde, en düşük korelasyon değerinin 0,9855 olduğu görüldü. Böylece, piksel yeğlilik değerlerinin görece çok yüksek seviyede azalması durumunda dahi Harris köşe sayıları değişiminin neredeyse değişmediği ve görüntüye özgü bir değişim gösterdiği görüldü.


Ardından Harris köşe sayıları değişiminin, punta kaynak görüntüsü kontrastının değişmesi durumunda nasıl sonuç verdiği incelendi. Şekil (3.49)'da kontrastı değiştirilmemiş punta kaynak görüntüsü (a) ve kontrastı %20 (b) ile %40 (c) oranında değiştirilmiş punta kaynak görüntüleri görülmektedir.



Şekil 3.49. (a) Kontrastı değiştirilmemiş görüntü, (b) ve (c) kontrastı sırasıyla %20 ve %40 değiştirilmiş görüntüler

Bu görüntüler üzerinde yapılan Harris köşe sayısı değişimi işleminde Şekil (3.50)'de görülen sonuç elde edildi.

Şekil (3.50)'deki çizgilerden sırasıyla yeşil çizgi Şekil (3.49)'daki (a) görüntüsünün, mavi çizgi (b) görüntüsünün ve kırmızı çizgi (c) görüntüsünün Harris köşe sayısı değişimlerini göstermektedir. Bu eğriler arasındaki korelasyon sırasıyla (a) ile (b) görüntüleri arasında 0,9898 olarak, (a) ile (c) görüntüleri arasında 0,9803 olarak ve (b) ile (c) görüntüleri arasında 0,9818 olarak tespit edildi. Bu sonuçlar ile görüntüdeki kontrast değişiminin de Harris köşe sayısı değişimlerine büyük bir etki etmediği, tespit edilen farklılığın kabul edilebilir olduğu görüldü.




Şekil 3.50. Kontrastı değiştirilmiş görüntülerin Harris köşe sayısı değişimleri

Ardından, bu yaklaşımın farklı sınıflara ait punta kaynak görüntülerinde nasıl sonuç verdiği incelendi. Şekil (3.51)'de sırasıyla “uygun” ve “uygun olmayan” olarak sınıflandırılmış iki adet punta kaynak görüntüsü görülmektedir. Bu görüntülere uygulanan Harris köşe sayıları değişimi sonuçları, Şekil (3.52)'de gösterilmiştir.



Şekil 3.51. (a) "uygun" sınıfına, (b) "uygun olmayan" sınıfına ait punta kaynak görüntüleri



Şekil 3.52. "Uygun" ve "uygun olmayan" punta kaynak görüntülerinin Harris köşe sayısı değişimleri

Şekil (3.52)'de yeşil renkli çizgi “uygun” olarak sınıflandırılmış punta kaynak görüntüsü sonucunu, kırmızı renkli çizgi ise “uygun olmayan” olarak sınıflandırılmış punta kaynak görüntüsü sonucunu göstermektedir. Bu sonuçlar arasındaki korelasyon da incelendiğinde 0,82 olarak bulundu. Bu sonuç ile uygun ve uygun olmayan olarak

sınıflandırılmış olan punta kaynaklara ait Harris köşe sayısı değişimlerinde ayırt edici bir fark olduğu görüldü. Çalışmanın sonraki aşamasında bu farktan yararlanıldı ve Harris köşe sayısı değişimi, punta kaynak görüntülerinin sınıflandırılmasında bir karakteristik özellik olarak kullanıldı.

3.3.9. Punta Kaynak Görüntüsünde En Küçük Özdeğerler Algoritması İle Bulunan Köşe Sayısı Değişiminin Tanımlayıcı Özellik Olarak Kullanılması

Punta kaynak görüntülerinde Harris köşe sayısı değişimi üzerine yapılan çalışmaya benzer şekilde, görüntüde en küçük özdeğer (minimum eigenvalue) algoritması kullanılarak tespit edilen köşe sayısının bir eşik değeri değişimi ile nasıl değiştiği incelendi. Harris köşe sayısı değişimi ile ilgili yapılan tüm çalışmalar, en küçük özdeğer algoritması ile tespit edilen köşe sayıları için de uygulandı.

Yapılan çalışmada, hareketli görüntülerde görüntünün doğrusal (affine) değişiminin takip edilebilmesi için deformasyon matrisi D 'ye ve yer değiştirme vektörü d 'ye bağlı olarak elde edilen $z^T = [d_{xx} \ d_{yx} \ d_{xy} \ d_{yy} \ d_x \ d_y]$ vektörü üzerinden, I görüntüsünün hareket sonucu değişimi ile oluşan J görüntüsü arasındaki fark olarak tanımlanan hata (a değeri) Denklem (3.14)'te görüldüğü şekilde;

$$a = \iint_W [I(x) - J(x)] \begin{bmatrix} xg_x \\ xg_y \\ yg_x \\ yg_y \\ g_x \\ g_y \end{bmatrix} wdx \quad (3.14)$$

ifade edilmiş ve buradan 6×6 boyutlu olacak şekilde bir T matrisi Denklem (3.15)'te verildiği şekilde;

$$T = \iint_W \begin{bmatrix} U & V \\ V^T & Z \end{bmatrix} wdx \quad (3.15)$$


tanımlanmıştır (Shi ve diğ. 1994). Burada Z , Denklem (3.16)'daki gibi;

$$Z = \begin{bmatrix} g_x^2 & g_x g_y \\ g_x g_y & g_y^2 \end{bmatrix} \quad (3.16)$$

ifade edilmiştir. Bu aşamada, hareketi takip edilecek olan görüntü nedeniyle Z 'in

özdeğerlerinin de gerektiği kadar büyük olması gerektiği belirtilmiştir. Özdeğerlerin küçük olması görüntüde genel olarak değişmeyen piksel yenginlik değerlerini, birbirlerine göre büyük ve küçük özdeğerlerin tek yönlü bir doku desenini, büyük özdeğerlerin ise köşeleri göstereceği belirtilmiştir.

Bu çalışmada, Z 'in λ_i özdeğerleri üzerinde duruldu ve $\lambda_i > k$ eşik değerleri için tespit edilen köşe (corner) sayıları, t 'nin $[0,001 - 0,1]$ aralığındaki değişimi için 100 adet değer olarak elde edildi. Yapılan çalışmalarda, Şekil (3.51)'de görülen uygun ve uygun olmayan olarak sınıflandırılmış punta kaynak görüntülerine ait köşe sayısı değişimleri Şekil (3.53)'te görülmektedir.



Şekil 3.53. En küçük özdeğer yöntemi ile elde edilmiş köşe sayılarının eşik değeri ile değişimi

Şekil (3.48)'de yeşil çizgi ile uygun olan punta kaynak görüntüsüne ait köşe sayısı değişimi, kırmızı çizgiyle uygun olmayan punta kaynak görüntüsüne ait köşe sayısı değişimi gösterildi. Bu yöntemle elde edilen köşe sayıları değişiminin de görüntü için ayırt edici olduğu ve punta kaynakları sınıflandırmada kullanılabileceği görüldü.

3.3.10. Verilerin Birleştirilmesi

Çalışmanın bu bölümünde, punta kaynak görüntülerinden elde edilen tüm ayırt edici veriler yan yana getirilerek bir dizi elde edildi. Bu dizi [temel_parametreler histogram Harris_köşeleri_değişimi MEF_sayıları_değişimi] şeklinde yan yana yazılan sayısal veriler ile 468 elemanlı olacak şekilde oluşturuldu. Her bir punta kaynak görüntüsünden elde edilen bu dizinin verileri kullanılarak, punta sayısı kadar satır içerecek şekilde bir matris elde edildi ve bu matris verileriyle de bir yapay sinir ağı eğitildi.

Son olarak, üzerinde çalışılan karoseri bölümünden elde edilen ve yukarıda belirtilen parametreleri elde edilen tüm punta kaynak görüntüleri kullanılarak elde edilen veri yapısı ile tablo 3.5’te verilen uyumlandırılmış AlexNet CNN eğitildi.

Cam alt flanş bölgesi gibi karoseri yüzeyinin belirli ve sınırlı bölgelerinden alınan punta kaynak görüntülerinden elde edilen veriler ile eğitilen “temel parametreler yapay sinir ağı”, histogram verileri ile eğitilen “histogram yapay sinir ağı”, Harris köşeleri değişim verileri ile eğitilen “Harris yapay sinir ağı”, MEF verileri değişimi ile eğitilen “MEF yapay sinir ağı”, tüm parametrelerin birleştirilmesi ile elde edilen veriler ile eğitilen “tüm veri yapay sinir ağı” (All_NN) ve görüntülerin doğrudan kullanımı ile eğitilen uyumlandırılmış “AlexNet CNN” yapay sinir ağlarının tümü birlikte, seri üretim şartlarında punta kaynak sınıflandırması amacıyla kullanıldı.

3.3.11. Algoritmaların Tümü İçin Geliştirilen Yazılım

Tüm bu algoritmayı uygulamak amacıyla bir yazılım geliştirildi. Yazılımda ilk olarak üzerinde çalışılacak karoseri bölgesi tanımlandı. Şekil (3.54)’te yeni bir bölgenin tanıtımının yapıldığı yazılım bölümü görülmektedir.

Area N...	Path
Cam Alt Fl...	C:\Spot Weld Recognition\Cam Alt Flansh Altı 1
Cam Alt Fl...	C:\Spot Weld Recognition\Cam Alt Flansh Altı 2
Deneme 1	C:\Spot Weld Recognition\Deneme 1
Cam Alt Fl...	C:\Spot Weld Recognition\Cam Alt Flansh 3

New Area Name :


Directory Path :

Şekil 3.54. Yazılımda karoseri yüzeyi üzerinde yeni bölge tanıtım bölümü

Ardından bu karoseri bölümü için ana görüntülerin elde edilmesi işlemi gerçekleştirildi. Bu aşamada kameradan en iyi görüntünün alınabilmesi amacıyla kameranin odaklanma, parlaklık, keskinlik ve kontrast ayarları da ayarlanabilir ve seçilebilir birer bileşen olarak yazılıma eklendi. Böylece araç karoseri yüzeyi üzerinden, ışıklandırmanın yetersiz olduğu durumlarda dahi en uygun piksel yoğunluk değerine sahip görüntülerin


alınabilmesi sağlandı. Yazılımda karoseri yüzeyinden görüntülerin alınması aşaması Şekil (3.55)'te görülmektedir.

Görüntülerin alınmasını takiben, punta kaynak görüntülerinin tespiti ve ön sınıflandırılması işlemi yapıldı. Geliştirilen yazılım ile sınıflandırma işlemi için kaçınıcı ana görüntü üzerinde çalışıldığı, sürecin ilerlemesi boyunca kaç adet görüntü tespit edildiği ve hangi sınıfa kaç adet görüntü atamasının yapıldığı bilgileri kolayca görülebilir şekilde programlandı. Yazılımda bu işlemin yapıldığı bölüm Şekil (3.56)'da görülmektedir.



Şekil 3.55. Karoseri yüzeyinden görüntülerin alınması aşaması

Bu işlemi takiben, sınıflandırılan kaynak verileri kullanılarak, yapay sinir ağları eğitildi. Görüntüler ile eğitimi yapılan uyumlaştırılmış AlexNet CNN dışındaki tüm yapay sinir ağları, örüntü tanıma amacıyla oluşturulmuş geri yayılım yapay sinir ağı model alınarak oluşturuldu. Oluşturulan yapay sinir ağları yapıları sırasıyla temel parametreler için 12 girişli 50 gizli katmanlı, histogram için 256 girişli 150 gizli katmanlı, Harris ve MEF değişimleri için ayrı ayrı olmak üzere 100 girişli 150 gizli katmanlı ve son olarak tüm veriler için 468 girişli ve 250 gizli katmanlı yapay sinir ağları oluşturuldu. Tüm bu yapay sinir ağları, 3 adet çıkışları olacak şekilde tasarlandı.



Şekil 3.56. Tespit edilen puna kaynak görüntülerinin eğitimler öncesinde sınıflandırılması

Yazılım, her eğitimin istenildiği kadar tekrarlanmasını ve elde edilen son başarımlar oranı ile eğitilen yapay sinir ağının bilgisayara kaydedilmesini sağlayacak şekilde geliştirildi. Böylece, yapay sinir ağlarının eğitiminde, kontrollü bir şekilde elde edilen olası en yüksek başarımlar oranları kayıt altına alındı.


Yazılım, eğitim sonrasında sistem seri üretim şartlarında kullanıldığında, karoseri yüzeyinden alınan ana görüntü üzerine, tespit edilen punta kaynakların sınıflandırma sonuçları yazdırılarak, çalışan tarafından sistemin kolayca kullanılması ve yönetilmesi sağlandı. Sistemin seri üretim şartlarında kullanımı durumundaki ekran görüntüsü Şekil (3.57)'de görülmektedir.

3.3.12. Sistemin Nihai Kararı Oluşturması

Sistemin çalışması sırasında, kameranın hareket ettirilmemesi durumunda, sistem sürekli aynı görüntüyü almaya devam edecek şekilde programlandı. Kamerada hareket olup olmaması, alınan ana görüntünün ortalama piksel yeğinlik değerinin %3'ten fazla değişip değişmemesi yöntemi ile kontrol edildi. Görüntünün değişmemesi durumunda, sistemin punta kaynak görüntüleri için oluşturduğu 6 adet yapay sinir ağı sonuç verisi bir veri deposuna kayıt edildi. Kameranın hareket etmesi ve ana görüntünün değişmesi durumu algılandığında, veri deposundaki kayıtlar silindi ve sabitlenen yeni görüntü üzerinden üretilen sonuçlar, tekrar veri deposuna yazılmaya başlandı.

Nihai sonucun elde edilmesi işleminde, veri deposunda kayıtlı olan her bir yapay sinir ağı sonuç verisi ele alındı ve “uygun”, “uygun olmayan” ve “punta kaynak değil” kategorilerinin her yapay sinir ağı çıktısında kaç kez tekrar ettiği saydırıldı. Buna göre bir yapay sinir ağı sonuç kümesinde bulunan en fazla sınıf sayısı, ekrana o yapay sinir ağının ağırlıklı sonucu olarak yazdırıldı. Şekil (3.57)’de, ekranda tespit edilen punta kaynak görüntülerinin yanındaki sarı zemin renkli açıklama alanlarında bu sayaç sonuçları görülmektedir. Nihai sonuç için de bu 6 veride hangi sınıfın fazla sayıda olması durumu saydırıldı ve nihai sonuç ekranda, punta koordinatı çevresine renkli çember çizdirilerek gösterildi.


Burada kırmızı renkli çember ile “uygun olmayan” punta kaynağı, yeşil renkli çember ile “uygun” olan punta kaynağı, mavi renkli çember ile “punta kaynağı olmayan” karoseri yüzey bileşeni gösterildi. Eğer, 6 yapay sinir ağının ağırlıklı sonuçlarına göre bu 3 sınıf sayısından herhangi biri baskın, yani büyük rakam olarak elde edilemiyorsa, yani bir eşitlik durumu oluşursa, punta kaynak beyaz renkli çember ile işaretlendi. Bununla birlikte, bu tür tespitlerin ihmal edilebilecek kadar görece çok az olduğu ve kameranın ilk hareketi ile kaybolarak tekrar etmediği tespit edildi.



Şekil 3.57. Geliştirilen sistemin seri üretim şartlarında kullanımı sırasında ekran görüntüsü

Sistemin seri üretim şartlarında kullanımı sırasında, daha önce Şekil 3.17’de açıklanan geometrik görüntü deformasyonu da incelendi. Kamerada yapılan doğrulama çalışmaları sayesinde, alınan görüntüde kameradan kaynaklı bozulmanın, en fazla yakın mesafeden

alınan görüntülerde olmak üzere 0.45 piksel olduğu tespit edilmişti. Fakat, kameranın yüzeye dik açı ile konumlandırılması sonrasında, görüntünün en uç noktalarında kalan punta kaynak görüntülerinde yaklaşık %26'lık bir geometrik deformasyon olduğu daha önce gösterilmişti. Şekil 3.58'de, 70×70 piksel büyüklüğündeki punta kaynak görüntüleri baz alındığında, 1280×720 piksel büyüklüğündeki ana görüntü üzerinde yatayda ve düşeyde yapılan inceleme bölgeleri, örnek bir ana görüntü üzerinde görülmektedir. Şekil 3.58'de de görüldüğü üzere, ana görüntü yatayda $\frac{1280}{70} \cong 18$ alt bölgeye, düşeyde ise $\frac{720}{70} \cong 10$ alt bölgeye ayrıldı. 1280×720 piksel olarak alınan görüntüde oluşan bozulma hesaplandı ve Şekil 3.59'da sıcaklık haritası yöntemiyle (Heatmap) gösterildi.



Şekil 3.58. Punta kaynak görüntüsüne göre bölümlenmiş ana görüntü

Yapılan çalışmalarda, sistem ile tespit edilen punta kaynak görüntülerinin, ana görüntüde yatayda veya düşeyde kenarlara denk gelebildiği gözlemlendi. Sistemin bu punta kaynak görüntülerini sınıflandırması aşamasında, yaklaşık %20'den fazla geometrik deformasyonun olduğu bölgelere denk gelen kaynak görüntülerinde doğru sonuçlar üretilmediği tespit edildi. Tablo 3.6'da tespit edilen punta kaynak sayıları, bunların kaç adedinin görüntünün yatayda veya düşeyde %20'den daha yüksek bozulmanın olduğu kenar bölgelerine denk geldiği ve değerlendirme sonuçları gösterilmiştir. Sistemin, %20'den daha düşük geometrik bozulma oluşan bölgelere denk gelen punta kaynak görüntülerindeki doğruluk değerlerinin daha yüksek olduğu ve tespit edilen sonuçlar, sonraki bölümde açıklandı. Bu nedenle sistemin başarımının hesaplanması aşamasında,

görüntü üzerinde %20'den daha az geometrik bozulmanın görüldüğü alanlarda bulunan punta kaynaklara ait sonuçlar üzerinden sistem başarımı hesaplanmıştır

	9	8	7	6	5	4	3	2	1	1	2	3	4	5	6	7	8	9
5	%29.2	%26.9	%24.4	%22.2	%20.1	%18.2	%16.5	%15.3	%14.2	%14.2	%15.3	%16.5	%18.2	%20.1	%22.2	%24.4	%26.9	%29.2
4	%28.0	%25.5	%22.9	%20.6	%18.2	%16.1	%14.2	%12.7	%11.4	%11.4	%12.7	%14.2	%16.1	%18.2	%20.6	%22.9	%25.5	%28.0
3	%26.9	%24.3	%21.6	%19.1	%16.5	%14.2	%12.0	%10.2	%8.5	%8.5	%10.2	%12.0	%14.2	%16.5	%19.1	%21.6	%24.3	%26.9
2	%26.2	%23.5	%20.7	%18.0	%15.3	%12.7	%10.2	%7.1	%5.7	%5.7	%7.1	%10.2	%12.7	%15.3	%18.0	%20.7	%23.5	%26.2
1	%25.6	%22.8	%19.9	%17.1	%14.2	%11.4	%8.5	%5.7	%2.8	%2.8	%5.7	%8.5	%11.4	%14.2	%17.1	%19.9	%22.8	%25.6
1	%25.6	%22.8	%19.9	%17.1	%14.2	%11.4	%8.5	%5.7	%2.8	%2.8	%5.7	%8.5	%11.4	%14.2	%17.1	%19.9	%22.8	%25.6
2	%26.2	%24.3	%20.7	%18.0	%15.3	%12.7	%10.2	%7.1	%5.7	%5.7	%7.1	%10.2	%12.7	%15.3	%18.0	%20.7	%24.3	%26.2
3	%26.9	%23.5	%21.6	%19.1	%16.5	%14.2	%12.0	%10.2	%8.5	%8.5	%10.2	%12.0	%14.2	%16.5	%19.1	%21.6	%23.5	%26.9
4	%28.0	%25.5	%22.9	%20.6	%18.2	%16.1	%14.2	%12.7	%11.4	%11.4	%12.7	%14.2	%16.1	%18.2	%20.6	%22.9	%25.5	%28.0
5	%29.2	%26.9	%24.4	%22.2	%20.1	%18.2	%16.5	%15.3	%14.2	%14.2	%15.3	%16.5	%18.2	%20.1	%22.2	%24.4	%26.9	%29.2

Şekil 3.59. Görüntüdeki geometrik bozulmanın sıcaklık haritası yöntemiyle gösterimi

Tablo 3.6. Ana görüntüde %20'den daha fazla geometrik deformasyon oluşan bölgelere denk gelen punta kaynak görüntülerine ait tespit oranları

İncelenen Bölgeler	Kenarlara Denk Gelme Eksen	İşlem Gören Punta Kaynak Sayısı	Kenarlara Denk Gelen Punta Kaynak Sayısı (A)	Oran	Tespit Edilemeyen Punta Kaynak Sayısı	Oran (A'ya göre)	Hatalı Tespit Edilen Punta Kaynak Sayısı	Oran (A'ya göre)	Doğru Tespit Oranı
Cam Alt Flanş	Yatay	1125	52	%4.6	12	%23.1	23	%44.2	%32.7
Cam Flanş Altı	Yatay ve Düşey	768	37	%4.8	9	%24.3	18	%48.6	%27.0
Arka Duvar	Yatay ve Düşey	810	32	%4.0	7	%21.9	14	%43.8	%34.4
A Direği Altı	Düşey	192	6	%3.1	1	%16.6	2	%33.3	%33.3

Tablo 3.6'da verilen değerlerde de görüldüğü üzere, ana görüntülerde tespit edilen punta kaynak görüntülerinin yaklaşık %5'i, geometrik deformasyonun %20'den fazla olduğu alanlara denk gelebilmektedir. Bu punta kaynakların doğru sınıflandırılma oranı ise yaklaşık %30 - %35 aralığında gerçekleşmektedir. Bu nedenle, ana görüntüde tespit

edilen punta kaynaklardan, Şekil 3.59'daki sıcaklık haritasında beyaz renkli rakamlar ile gösterilen bölgelerde kalanların değerlendirmeye alınması gerektiği tespit edildi ve bunların dışında kalan alanlarda bulunan punta kaynak görüntüleri değerlendirmeye alınmadı.



4. BULGULAR VE TARTIŞMA

Bu çalışmada geliştirilen algoritma ve yazılım, seri üretim şartlarında, üretim süreci devam ederken denendi. Tüm eğitim çalışmalarında, seri üretim şartlarında üretilen araç kabinleri kullanıldı, çalışmalar seri üretim şartlarında, karoseri üretim bandının son kontrol istasyonunda gerçekleştirildi. Seri üretim şartlarında bir kabinin kontrol istasyonunda kalma süresi, üreticinin proseslerine ait çeşitli parametre ve gerekliliklere bağlı olarak 9 ile 13 dakika arasında değişti (Takt süresi). Bu süre, bir kabinin cam alt flanş bölgesi, arka duvar, A sütunu altı gibi belirlenen bölgelerinden görüntü almak için yeterlidir. Tüm denemeler ve eğitim süreçleri, kabinler seri üretim şartlarında kontrol istasyonuna geldiğinde, kabinlerin ilgili bölgelerinden görüntü alınıp bu görüntüler ile gerçekleştirildi. Ana görüntülerin alınmasının ardından bu kabinler, seri üretimin gereği olarak, sonraki süreç olan boyahane sürecine gönderildi. Dolayısıyla, eğitim için görüntülerin alındığı kabinler hiçbir zaman test amacıyla kullanılmadı, eğitilen sistem daima üretimden gelen yeni kabinler üzerinde test edildi.

Her deneme ve her eğitim için yeterli sayıda ana görüntü elde edebilmek amacıyla seri üretim şartlarında art arda gelen 4-5 kabinden görüntü alındı. Böylece yaklaşık 100 adet ana görüntü elde edildi. Her bir ana görüntüdeki punta kaynak sayısı değişken olmakla birlikte, sistem tarafından bir örnekleme başına 400-500 adet aralığında punta kaynak ve delik, somun deliği gibi punta kaynak benzeri görüntü tespit edildi. Her bir deneme çalışması başına eğitim süreci, kabinlerden elde edilen bu görüntüler ile tamamlandı. Bu sayıdaki görüntünün eğitim süresi, her bir görüntünün önce manuel değerlendirilmesini gerektirdiği için 1 saatten daha uzun sürdü. Mevcut seri üretim şartlarında, kısaca takt süresi olarak adlandırılan kabinin bir istasyonda kalma süresi, yukarıda da belirtildiği gibi yaklaşık 9-13 dakika arasındadır. Seri üretimin bir gereği olarak, üzerinden örnekler alınan kabinler, en fazla 13 dakika sonra, takip eden üretim süreçlerine aktarıldı. Yukarıda da belirtildiği gibi, sistemin eğitimi sonrasında başarımlı testleri, üretim planına göre kontrol istasyonuna gelen yeni kabinler üzerinde gerçekleştirildi. Dolayısıyla örnekleme yapılarak eğitimde kullanılan hiçbir kabin, sistemin test aşamasında kullanılmadı.

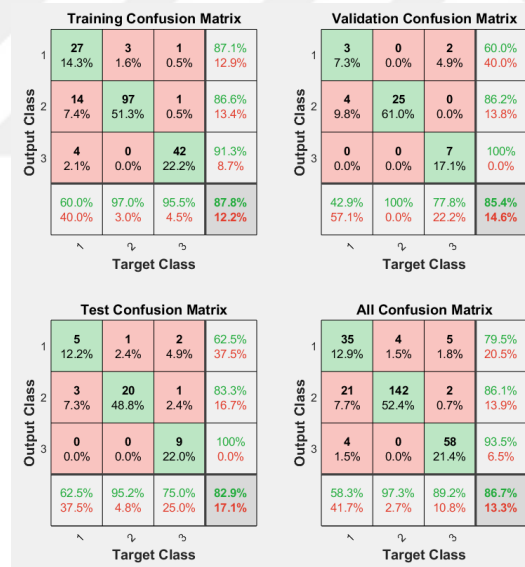
Denemeler, kabin yüzeyinde robotla oluşturulan punta kaynaklar üzerinde ve manuel, bir çalışan tarafından punta kaynak makinesi kullanılarak el ile oluşturulan punta kaynaklar üzerinde gerçekleştirildi. Bu kapsamda uygulama yüzeyleri olarak kabin aka duvarı,

kabin A direği altı ve ön cam alt flanş bölgeleri seçildi.

4.1. Algoritmanın Kabin Arka Duvar Bölgesinde Denenmesi ve Elde Edilen Sonuçlar

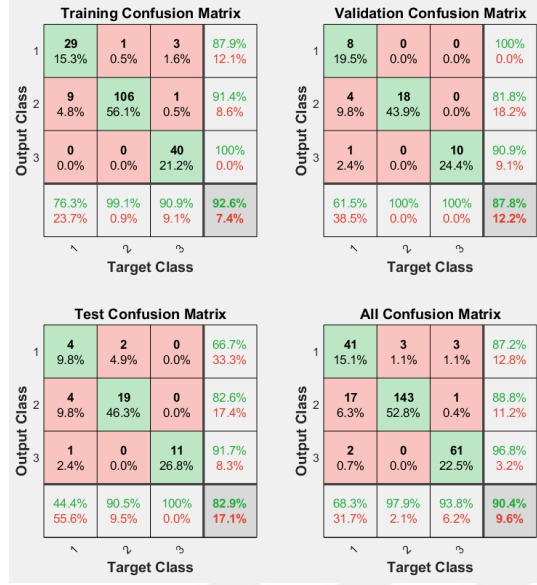
İlk denemede yazılım, araç kabini arka duvarı üzerinde bulunan ve seri üretim şartlarında robotlar ile yapılan punta kaynaklar üzerinde çalıştırıldı. Bu denemede yapılan ilk eğitim, görüntü standart parametreleri ile tamamlandı. Standart parametreler ile eğitilen yapay sinir ağında %86,7 başarımlı oranın elde edildi. Bu eğitime ait hata matrisi Şekil (4.1)'de görülmektedir. Burada eğitim, validasyon ve test sonuçları arasında çok büyük bir fark görülmemektedir. Dolayısıyla sistemin sağlıklı bir öğrenme gerçekleştirdiği söylenebilir.

Bunu takiben, görüntü histogramı verileri ile yapay sinir ağı eğitimi gerçekleştirildi. Bu eğitim sonucunda %90,4 başarımlı oranın elde edildi. Bu eğitime ait hata matrisi Şekil (4.2)'de görülmektedir.

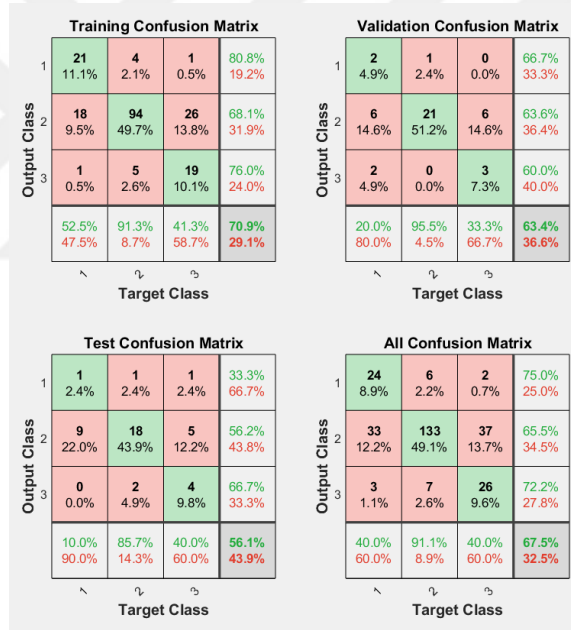


Şekil 4.1. Arka duvar kaynakları temel parametreler eğitim sonuçları

Arka duvar histogram verileri eğitiminde test başarımlı oranının eğitim başarımlı oranına göre $\left(1 - \frac{82,9}{92,6}\right) \cong 0,1$ yani %10 kadar düşük olduğu görüldü. Bu durum, bir aşırı öğrenme durumunu gösterebilmekle birlikte kabul edilebilir seviye olarak alındı. Ardından, Harris köşe değişim verileri ile ilgili yapay sinir ağı eğitildi. Bu eğitimde %67,5 başarımlı oranın elde edildi. Bu eğitime ait hata matrisi Şekil (4.3)'te görülmektedir



Şekil 4.2. Arka duvar kaynakları histogram verileri eğitim sonuçları

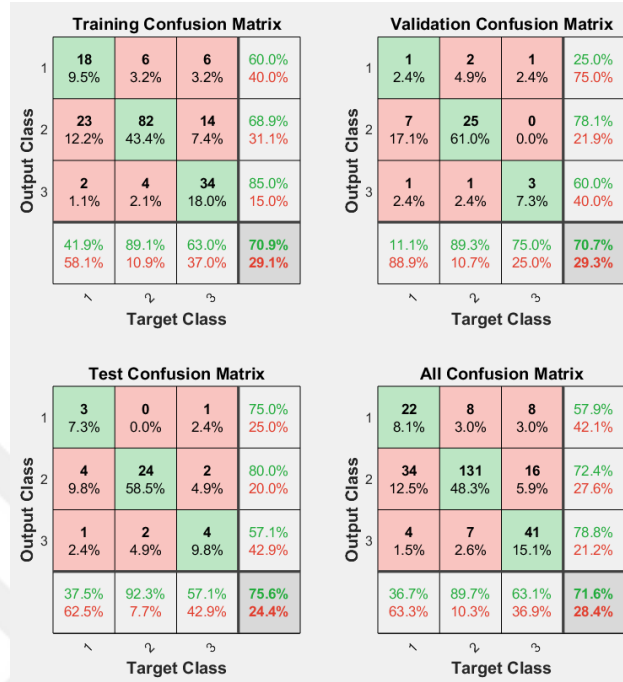


Şekil 4.3. Arka duvar kaynakları Harris köşe sayısı değişim verileri eğitim sonuçları

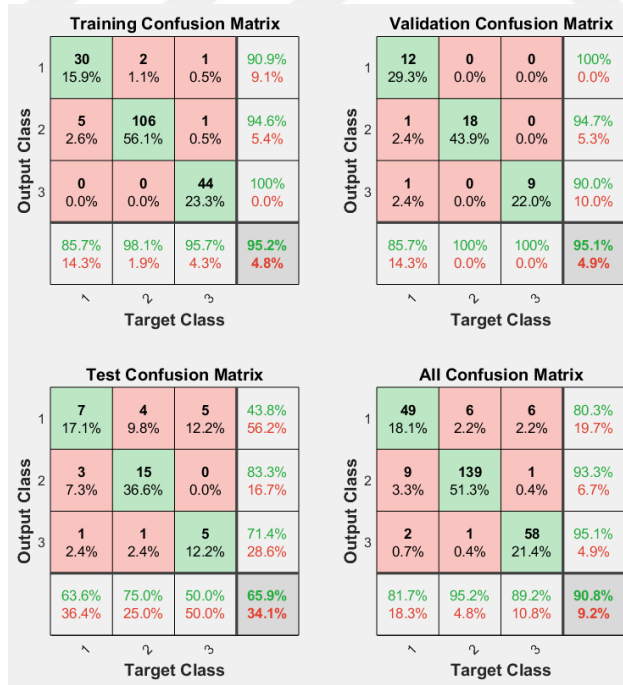
Harris köşe sayıları değişim verileri ile eğitim sonucunda validasyon ve test başarımlarının eğitim sonucundan yaklaşık %21 daha düşük olduğu görüldü. Bu durum, yapay sinir ağının eğitiminde aşırı öğrenmeye eğilim olduğunu göstermektedir.

Bu eğitimden sonra, MEF değişim verileri için yapay sinir ağı eğitimleri tamamlandı. Elde edilen başarımlar seviyesi %71,6 olarak gerçekleşti. Bu eğitime ait hata matrisi Şekil (4.4)'te görülmektedir. Eğitim, validasyon ve test sonuçlarının birbirleriyle tutarlı olduğu

görüldü. Böylece, MEF köşe sayısı değişimi parametresinin arka duvardaki punta kaynaklar için daha sağlıklı bir ayırt edici özellik olduğu görüldü.



Şekil 4.4. Arka duvar kaynakları MEF sayısı değişim verileri eğitim sonuçları




Şekil 4.5. Arka duvar kaynakları tüm verilerin bileşimi ile yapılan eğitim sonuçları

Tüm parametrelerin birleştirilmesi ile oluşturulan veriler kullanılarak yapılan yapay sinir

ağı eğitiminde ise başarı oranı %90,8 olarak elde edildi. Bu eğitime ait hata matrisi Şekil (4.5)'te görülmektedir. Bu eğitimde, test başarı oranı ile eğitim başarı oranları arasında yaklaşık %30 fark olduğu görüldü. Bunun nedeninin, eğitim sırasında rastgele belirlenen eğitim, validasyon ve test verilerinin uygun dağılmaması olduğu tespit edildi.

Parametre eğitimlerinin tamamlanmasının ardından, uyumlanmış AlexNet CNN ile punta kaynak görüntülerinin eğitimi tamamlandı. Bu eğitimde başarı oranı %94,25 olarak elde edildi. Bu eğitim ve başarı oranı Şekil (4.6)'da görülmektedir.



Şekil 4.6. Kabin arka duvar punta kaynak görüntüleri ile yapılan CNN eğitimi ve sonucu

CNN eğitimi sonucunun hedeflenen değer olan %90'ın üzerinde olması ve kayıp (loss) değerinin eğitimin ilerlemesi ile artmıyor olması, bu CNN eğitiminin etkili şekilde gerçekleştiğini göstermektedir.

Bu eğitimler sonrasında, kabin arka duvar yüzeyinde 3 ayrı deneme yapıldı. Elde edilen sonuçlar Şekil (4.7)'de görülmektedir.

Araç kabin yüzeyi arka duvar üzerinde yapılan denemelerde elde edilen sonuçların, önceki çalışma sonuçlarına göre daha yüksek olduğu görüldü. Nihai başarı oranları sırasıyla %91,9, %98,3 ve %90,6 olarak elde edildi.

1. Deneme Sonuçları											
Kaynak Sayıları				Başarım Oranları							
OK	20		2	OK	90,9%		9,1%	Nihai Değerler	Kaynak Sayısı	Başarım Oranı	
NOK	1	14		NOK	6,7%	93,3%		Doğru tespitler	34	91,9%	
NON			0	NON		0,0%		Yanlış tespitler	3	8,1%	
	OK	NOK	NON		OK	NOK	NON				
2. Deneme Sonuçları											
Kaynak Sayıları				Başarım Oranları							
OK	40			OK	100,0%			Nihai Değerler	Kaynak Sayısı	Başarım Oranı	
NOK	1	7		NOK	12,5%	87,5%		Doğru tespitler	57	98,3%	
NON			10	NON		100,0%		Yanlış tespitler	1	1,7%	
	OK	NOK	NON		OK	NOK	NON				
3. Deneme Sonuçları											
Kaynak Sayıları				Başarım Oranları							
OK	84	5	1	OK	93,3%	5,6%	1,1%	Nihai Değerler	Kaynak Sayısı	Başarım Oranı	
NOK	8	42		NOK	16,0%	84,0%		Doğru tespitler	135	90,6%	
NON			9	NON		100,0%		Yanlış tespitler	14	9,4%	
	OK	NOK	NON		OK	NOK	NON				

Şekil 4.7. Kabin arka duvar üzerinde seri üretim şartlarında yapılan denemelerin sonuçları

Geliştirilen sistem, bir yapay sinir ağı bütünü olduğu için sistemin başarımları parametreleri olan doğruluk (accuracy), duyarlılık (precision), hatırlama (recall) ve F1 puanı hesaplanabilir. Dikkat edilmesi gereken husus, bu parametrelerin iki durumlu çıktıları bulunan yapay sinir ağı için hesaplanıyor olmasıdır. Burada 3 değişkenli durum olması nedeniyle bu değerler, çıktıların ikili kombinasyonları için hesaplandı. Sonuçlar tablo 4.1’de görülmektedir.

Tablo 4.1. Arka duvar sonuçlarının doğruluk, duyarlılık, hatırlama ve F1 puanı sonuçları

Bölge	İlişki Grubu	Doğruluk (Accuracy)	Duyarlılık (Precision)	Hatırlama (Recall)	F1 Puanı
Arka Duvar 1	OK-NOK ilişkisi	0,9714	0,9524	1,0000	0,9756
	OK-NON ilişkisi	0,9091	1,0000	0,9091	0,9524
	NOK-NON ilişkisi	1,0000	1,0000	1,0000	1,0000
Arka Duvar 2	OK-NOK ilişkisi	0,9792	0,9756	1,0000	0,9877
	OK-NON ilişkisi	1,0000	1,0000	1,0000	1,0000
	NOK-NON ilişkisi	1,0000	1,0000	1,0000	1,0000
Arka Duvar 3	OK-NOK ilişkisi	0,9065	0,9130	0,9438	0,9282
	OK-NON ilişkisi	0,9894	1,0000	0,9882	0,9941
	NOK-NON ilişkisi	1,0000	1,0000	1,0000	1,0000

4.2. Algoritmanın Kabin A Direği Altındaki Punta Kaynak Bölgesinde Denenmesi ve Elde Edilen Sonuçlar

Bunu takiben sistem, araç kabin yüzeyi A direği altında bulunan yüzeydeki punta kaynaklar üzerinde denendi. Şekil (4.8)’de kabin yüzeyi A sütunu altına bulunan yüzey

bölgesi çerçeve içine alınmış olarak görülmektedir.

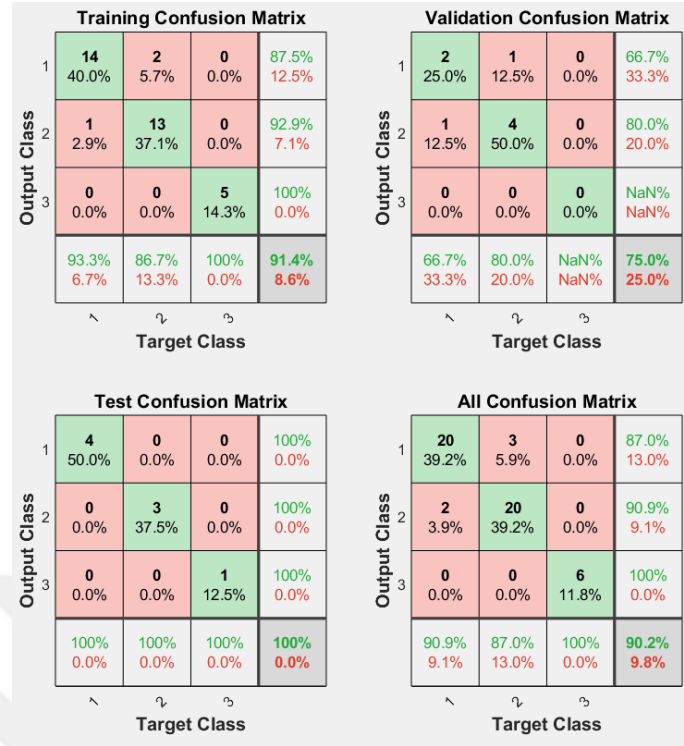


Şekil 4.8. Kabin yüzeyi A sütunu altına bulunan yüzey bölgesi

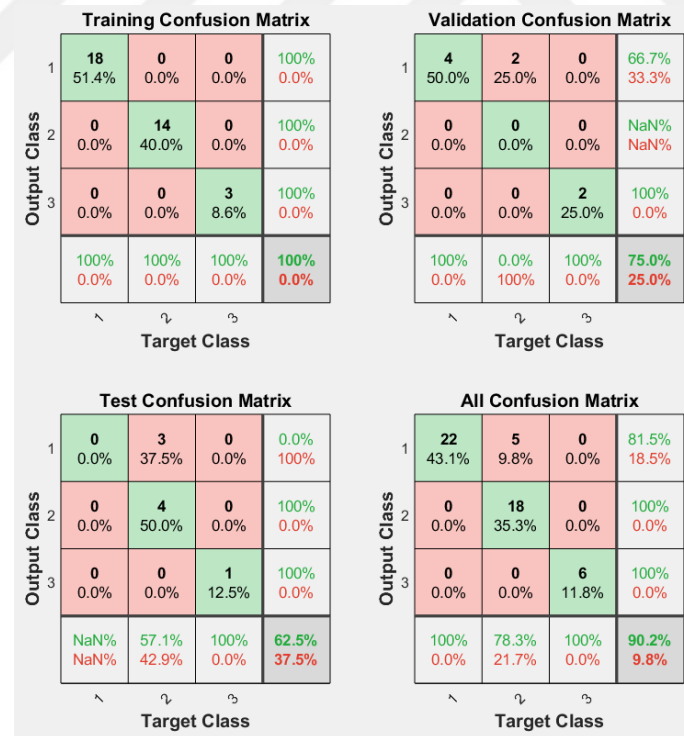
Kabin yüzeyinin bu bölgesinde bulunan punta kaynak işlemleri robot tarafından gerçekleştirilmektedir. Fakat yüzeyin girintili olması nedeniyle, oluşan punta kaynaklara ait görüntülerin piksel yeğlilik değerlerinin, arka duvar yüzeyindekilere daha fazla değişim gösterdikleri görüldü.

Punta kaynak görüntülerinin ön sınıflandırma işlemleri sonrasında gerçekleştirilen yapay sinir ağı eğitimlerinde başarımları sırasıyla, temel parametreler eğitiminde %90,2, histogram verileri eğitiminde %90,2, Harris köşeleri değişimi eğitiminde %92,2, MEF verileri değişimi eğitiminde %62,7, tüm parametrelerin birleşimi ile elde edilen verilerin eğitiminde %96,1 ve son olarak görüntüler ile CNN üzerinde yapılan eğitimde %100 olarak elde edildi. Başarımları ve hata matrisleri sırasıyla Şekil (4.9), Şekil (4.10), Şekil (4.11), Şekil (4.12), Şekil (4.13) ve Şekil (4.14)'te görülmektedir.

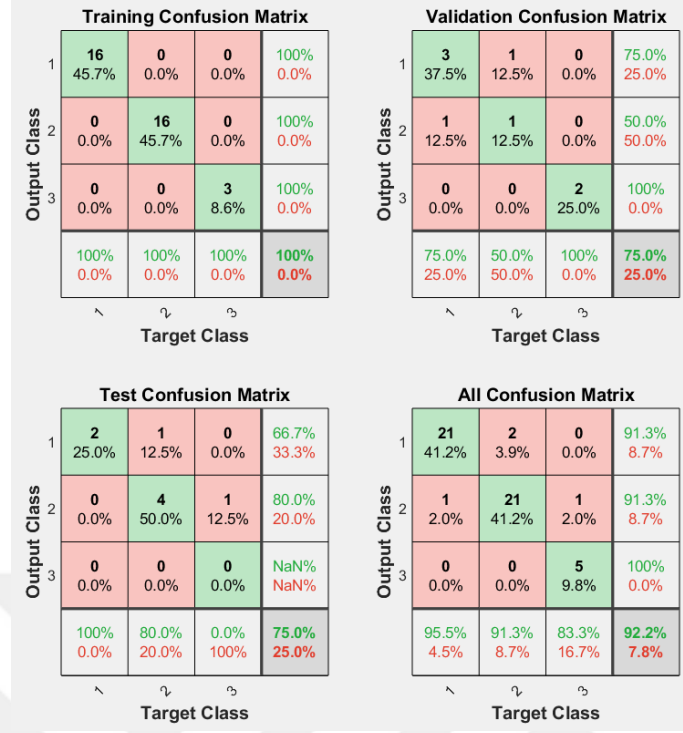
Eğitim sonrasında seri üretim şartlarında yapılan deneme çalışmaları sonucunda %94,4 başarımları tespit edildi. Hata matrisi ve nihai başarımları Şekil (4.15)'te görülmektedir.



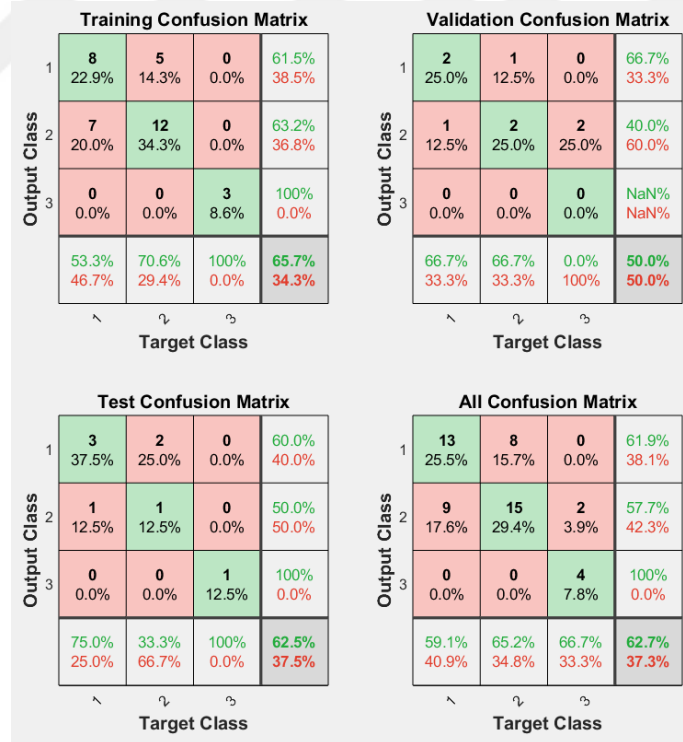
Şekil 4.9. Standart parametreler ile yapılan yapay sinir ağı eğitim sonuçları



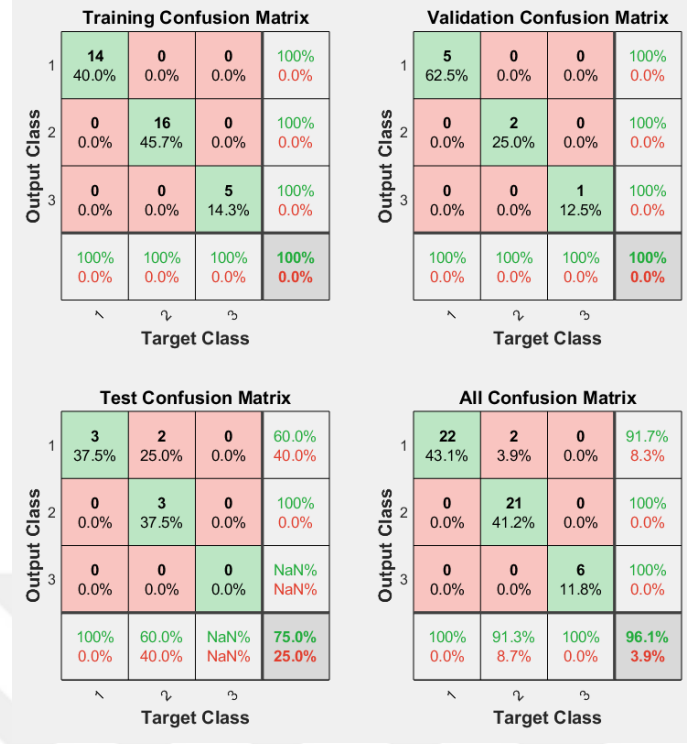
Şekil 4.10. Histogram verileri ile yapılan yapay sinir ağı eğitim sonuçları




Şekil 4.11. Harris köşeleri değişim verileri ile yapılan yapay sinir ağı eğitim sonuçları



Şekil 4.12. MEF verileri değişimi ile yapılan yapay sinir ağı eğitim sonuçları



Şekil 4.13. Tüm verilerin birleştirilmesiyle yapılan yapay sinir ağı eğitim sonuçları



Şekil 4.14. A sütunu altı punta kaynak görüntüleri ile yapılan CNN eğitimi ve sonucu

Bu eğitimlerde, validasyon ve test başarımlarının, eğitim başarımlarına göre %10'dan daha fazla düşük olan eğitimler için eğitimde aşırı öğrenme veya rastgele dağıtılan eğitim-validasyon-test verilerinin uygun dağılmaması durumu olduğu söylenebilir. Bunun nedeni ise -daha önce de belirtildiği gibi- “uygun” ve “uygun olmayan” sınıflarına ait bazı punta kaynak görüntülerinin piksel yoğunluk değerleri ve piksel konumları açısından birbirlerine benzer olmaları ve bu benzerliğin yapay sinir ağı

tarafından ayırt edilememesidir. Bu nedenden dolayı, punta kaynak görüntüleri sadece tek tip parametreler ve yapay sinir ağı kullanılarak değil, farklı veriler ile eğitilmiş yapay sinir ağları sonuçlarının bir kombinasyonu ile değerlendirilmekte ve sınıflandırılmaktadır. Bu nedenle, bazı yapay sinir ağı sonuçları başarımları düşük elde edilse de nihai sonuçlar hedeflenen değerin üzerinde elde edilebilmektedir. Şekil (4.15)'te kabin A direği alt bölge nihai sınıflandırma başarımları görülmektedir.

Kaynak Sayıları				Başarımları			
OK	49	2	1	OK	94,2%	3,8%	1,9%
NOK	1	17		NOK	5,6%	94,4%	
NON			1	NON			100,0%
	OK	NOK	NON		OK	NOK	NON

Nihai Değerler	Kaynak Sayısı	Başarımları
Doğru tespitler	67	94,4%
Yanlış tespitler	4	5,6%

Şekil 4.15. Kabin A Adireği alt bölgesinde yapılan denemenin sonuçları

Bölüm 4.2'de açıklandığı şekilde, kabin A direği alt bölgesinde yapılan deneme sonuçlarından elde edilen başarımları parametreleri Tablo (4.2)'de verilmiştir.

Tablo 4.2. A direği alt bölge sonuçlarının doğruluk, duyarlılık, hatırlama ve F1 puanı sonuçları

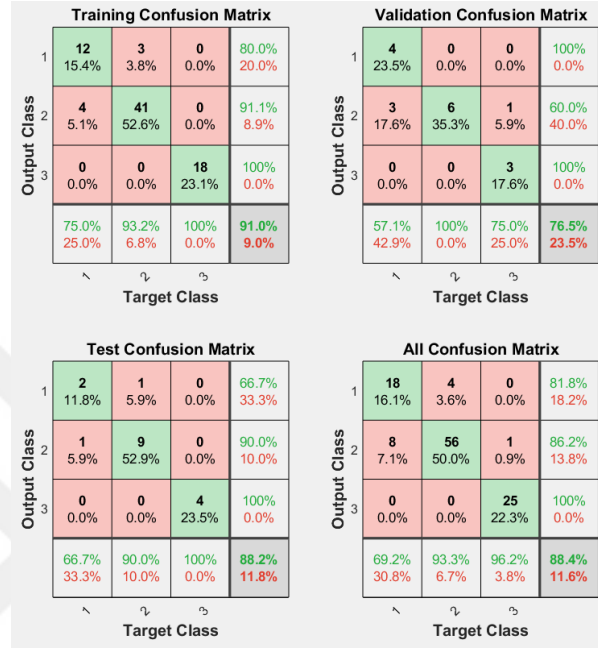
Bölge	İlişki Grubu	Doğruluk (Accuracy)	Duyarlılık (Precision)	Hatırlama (Recall)	F1 Puanı
A Direği Altı	OK-NOK ilişkisi	0,95652	0,98000	0,96078	0,97030
	OK-NON ilişkisi	0,98039	1,00000	0,98000	0,98990
	NOK-NON ilişkisi	1,00000	1,00000	1,00000	1,00000

4.3. Sistemin Kabin Ön Cam Alt Flanş Bölgesinde Denenmesi ve Elde Edilen Sonuçlar

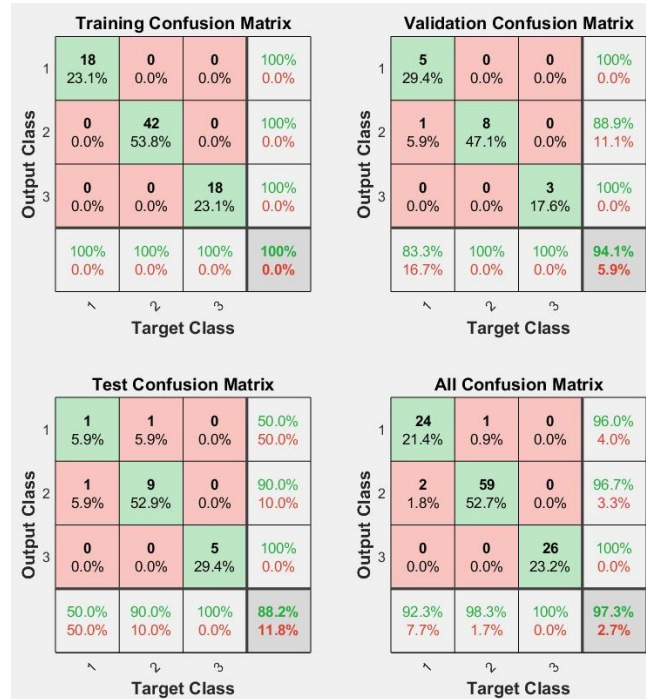
Geliştirilen sistem ile manuel punta kaynakların daha fazla bulunduğu kabin ön cam alt flanş bölgesinde de denemeler yapıldı. Bu bölgede bulunan punta kaynaklara ait görüntülerde piksel yeğnlik değerlerinin arka duvar bölgesindeki punta kaynak görüntülerine göre daha fazla değişkenlik gösterdikleri görüldü.

Yapılan eğitim çalışmalarında başarımları oranları sırasıyla, standart parametreler için %88,4, histogram için %97,3, Harris köşeleri değişimi için %76,8, MEF verileri değişimi

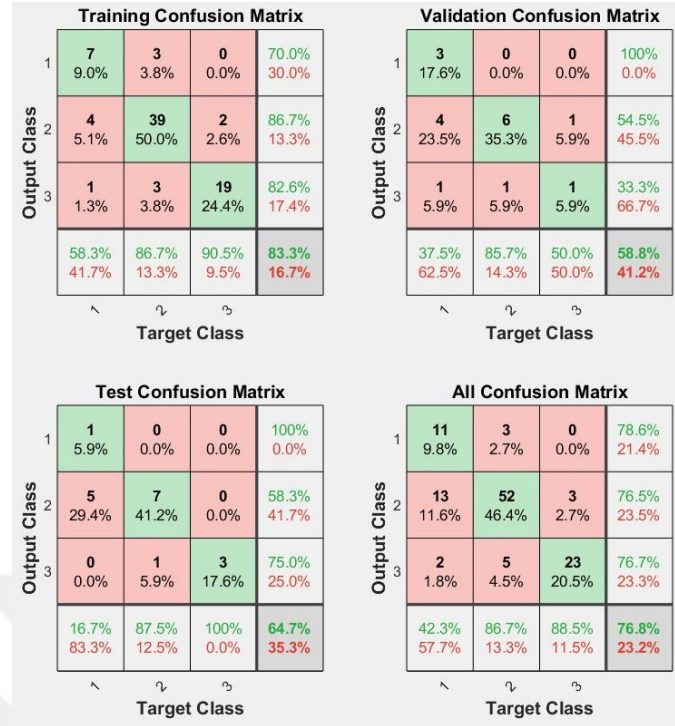
için %75,0, tüm verilerin birleştirilmesi ile yapılan eğitimde %92,9 ve görüntülerin doğrudan sınıflandırıldığı CNN eğitiminde %91,67 başarımları elde edildi. Eğitim başarımları ve hata matrisleri sırasıyla Şekil (4.16), Şekil (4.17), Şekil (4.18), Şekil (4.19), Şekil (4.20) ve Şekil (4.21)'de verilmiştir.



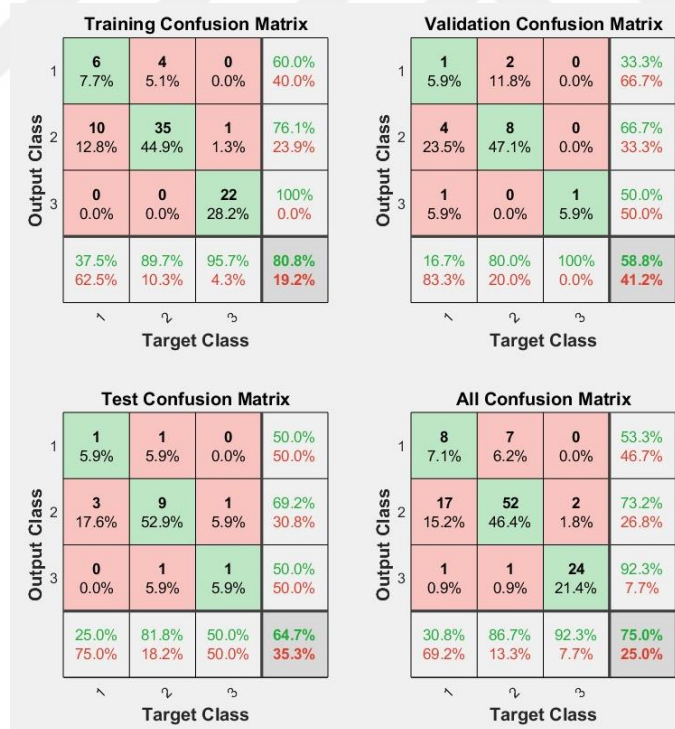
Şekil 4.16. Cam alt flanş bölgesi standart parametreler eğitim sonuçları



Şekil 4.17. Cam alt flanş histogram verileri eğitim sonuçları




Şekil 4.18. Cam alt flanş Harris köşeleri değişimlerinin eğitim sonuçları



Şekil 4.19. Cam alt flanş MEF Verileri değişimi eğitim sonuçları



Şekil 4.20. Cam alt flanş tüm veriler eğitim sonuçları



Şekil 4.21. Cam alt flanş punta kaynak görüntüleri CNN eğitim sonuçları

Eğitim sonuçları ile ilgili olarak kabin A sütunun alt bölgesi yapay sinir ağı eğitimleri ile ilgili yapılan değerlendirme, burada da geçerlidir. Eğitim sonuçlarının öncekilere göre daha düşük değerler olarak edilmesinin, bu bölgede manuel olarak üretilen ve eğitim aşamasında farklı sınıflara atanan punta kaynak görüntülerinde benzerlikler olmasıyla da ilişkili olduğu görüldü. Ardından, farklı kabinlerde yapılan denemelerde, sırasıyla %93,6 ve %95,1 başarımlar elde edildi. Şekil (4.22)'de yapılan denemelerin sonuçları

görülmektedir.

1. Deneme Sonuçları									
Kaynak Sayıları				Başarım Oranları					
OK	42	2		OK	95,5%	4,5%		Nihai Değerler	Kaynak Sayısı
NOK	2	13		NOK	13,3%	86,7%		Doğru tespitler	77
NON			22	NON			100,0%	Yanlış tespitler	4
	OK	NOK	NON		OK	NOK	NON		Başarım Oranı
									95,1%
									4,9%
2. Deneme Sonuçları									
Kaynak Sayıları				Başarım Oranları					
OK	33		1	OK	97,1%		2,9%	Nihai Değerler	Kaynak Sayısı
NOK		2	1	NOK		66,7%	33,3%	Doğru tespitler	44
NON	1		9	NON	10,0%		90,0%	Yanlış tespitler	3
	OK	NOK	NON		OK	NOK	NON		Başarım Oranı
									93,6%
									6,4%

Şekil 4.22. Cam alt flanş bölgesi eğitimleri sonrasında denemelerde elde edilen sonuçlar

Bölüm 4.1 ve bölüm 4.2’de açıklandığı şekilde bu eğitim sonuçlarına ait yapay sinir ağı başarımları Tablo (4.3)’te verilmiştir.

Tablo 4.3. Ön cam alt flanş sonuçlarının doğruluk, duyarlılık, hatırlama ve F1 puanı sonuçları

Bölge	İlişki Grubu	Doğruluk (Accuracy)	Duyarlılık (Precision)	Hatırlama (Recall)	F1 Puanı
Ön Cam Alt Flanş 1	OK-NOK ilişkisi	0,93220	0,95455	0,95455	0,95455
	OK-NON ilişkisi	1,00000	1,00000	1,00000	1,00000
	NOK-NON ilişkisi	1,00000	1,00000	1,00000	1,00000
Ön Cam Alt Flanş 2	OK-NOK ilişkisi	1,00000	1,00000	1,00000	1,00000
	OK-NON ilişkisi	0,95455	0,97059	0,97059	0,97059
	NOK-NON ilişkisi	0,91667	1,00000	0,66667	0,80000

4.4 Geliştirilen Sistemin YOLO Nesne Tanıma Modeli İle Karşılaştırılması

Bu çalışmada geliştirilen sistem, seri üretim şartlarında, ürüne ait yüzeylerden örnekleme yaparak görüntüler almakta, bunların içerdikleri punta kaynak görüntülerini tespit edip, sistemin eğitim yapabilmesi için bir ön sınıflandırma yapılması amacıyla kullanıcıya sunmakta, eğitim sonrasında test edilip seri üretime alınmaktadır. Bu amaçla sistem, ana görüntülerdeki punta kaynak görüntülerini Hough dönüşümü yöntemiyle tespit etmekte, bu görüntülerin belirleyici özelliklerini çıkartmakta ve her bir özellik için ayrı bir yapay sinir ağı eğitilmektedir. Ayrıca sistem, görüntünün kendisini de bir CNN ile sınıflandırmaktadır. Böylece ana algoritma sadece görüntünün CNN ile sınıflandırılmasına dayanmamakta, olası düşük başarımlı sonuçları engellemek amacıyla

görüntüye ait diğer özellikleri de kullanmaktadır. Bu nedenle, bir çalışan tarafından el ile kullanılan punta kaynak makineleri ile üretilen punta kaynaklarda dahi sistemin sınıflandırma başarımlarını %90'ın üzerinde elde edildi.

Bununla birlikte, ana görüntü üzerinde punta kaynak görüntülerinin doğrudan, sadece bir CNN kullanılarak tespit edilmesi ve sınıflandırılması mümkündür. Bir karşılaştırma yapılabilmesi amacıyla, AlexNet CNN'den farklı olarak, geleneksel nesne tanıma yöntemlerine bir alternatif olarak öne sürülen YOLO (You Only Look Once) nesne tanıma modeli kullanıldı (Redmon ve diğ., 2016).

YOLO modelinin uygulanması, geleneksel bir evrişimli yapay sinir ağının (CNN) kullanımından farklı olarak, görüntüde kuşatan kutuların (bounding box) tanımlanmasını ve bunların sınıflarının tespit edilmesini gerektirir. YOLO, çalışması sırasında birden fazla kuşatan kutuyu ve bu kutuların sınıflarını tahmin etmektedir. Burada tespit işlemi, bir regresyon problemi olarak ele alınır ve YOLO bu nedenle karmaşık bir ağ yapısı kullanmamaktadır. Çalışmada, R-CNN'in (Girshick ve diğ., 2014) görüntüdeki tüm bağlamı algılayamaması nedeniyle görüntüdeki nesneleri arka plan ile karıştırabildiği, fakat YOLO'da bu durumun R-CNN'e göre yarıdan daha az olduğu belirtilmiştir (Redmon ve diğ., 2016). Bununla birlikte, YOLO'nun küçük görüntülerin tanınmasında doğruluk değerinin görece düşük olduğu da belirtilmiştir. Fakat YOLO üzerinde yapılan iyileştirme ve geliştirmeler bu sorunun aşılmasında rol oynamıştır. Bu çalışmada, ana görüntüler kullanılarak eğitim amacıyla YOLO v5 kullanıldı.


YOLO v5 nesne tanıma modelinin eğitilmesi amacıyla daha önce araç kabin yüzeyinde tanımlanan bölgeler olan cam alt flanş, arka duvar alt kısmı ve A sütunu altı bölgelerinden sistemin eğitimi amacıyla alınmış görüntüler kullanıldı. Böylece, YOLO v5 nesne tanıma modelinin başarısı, aynı eğitim görüntüleri kullanıldığı için geliştirilen sistemin başarısı ile karşılaştırılabilir. Tüm bölgelerin eğitim sürecinde, eğitim, validasyon ve test için farklı görüntüler kullanıldı. Böylece eğitim, validasyon ve test görüntülerinin birbirlerinden farklı olması sağlandı.

4.4.1 Cam Alt Flanş Bölgesinde YOLOv5 Uygulaması

YOLO v5'in cam alt flanş bölgesinde eğitilmesi kapsamında 1280×720 piksel


çözünürlüklü 20 adet ana görüntü eğitim amacıyla, 8 adet ana görüntü de validasyon amacıyla olmak üzere toplam 28 ana görüntü kullanıldı. Eğitim öncesinde eğitim ve validasyon görüntülerinde bulunan punta kaynak görüntüleri üzerinden kuşatan kutular (bounding boxes) belirlendi ve YOLO v5'e görüntüler ile girdi olarak verildi. Şekil 4.23'te cam alt flanş bölgesi YOLOv5 eğitim sonuçları görülmektedir.

YOLO modelinin kuşatan kutular kullandığı daha önce belirtildi. Eğitim, daha önceden belirlenen kuşatan kutular ile modelin belirlediği kutuların kesişim alanının büyüklüğünü, bir başarıım parametresi olarak değerlendirir. Bu kesişim alanı Intersection of Union (IoU) olarak adlandırılır ve
$$IoU = \frac{\text{Kesişim Alanı (Intersection)}}{\text{Birleşim Alanı (Union)}}$$
 eşitliği ile hesaplanır. Bu değeri kullanarak elde edilen mAP50 (IoU değeri 0.5'ten büyük olan tespitler için ortalama duyarlılık, mean Average Precision at IoU=0.5) değeri ise eğitim sonucunda elde edilen başarıımın bir ölçütü olarak kullanılmaktadır.




Şekil 4.23. Cam alt flanş bölgesi YOLOv5 eğitim başarıımı


Bu çalışmada eğitim 300 epok sonunda sonlandırıldı. mAP50 değerleri sırasıyla “uygun” punta kaynaklar için 0,989, “uygun olmayan” punta kaynaklar için 0,995 ve “punta kaynak olmayan” görüntüler için 0,995 olarak tespit edildi. Eğitimin genel mAP50 değeri 0,993 olarak elde edildi. Şekil 4.24'te eğitime ait duyarlılık güven seviyesi (precision-confidence) eğrisi, Şekil 4.25'te hatırlama güven seviyesi (recall-confidence) eğrisi ve Şekil 4.26'da duyarlılık-hatırlama (precision-recall) eğrisi görülmektedir.



Şekil 4.24. Cam alt flanş YOLOv5 eğitimi duyarlılık güven seviyesi eğrisi



Şekil 4.25. Cam alt flanş YOLOv5 eğitimi hatırlama güven seviyesi eğrisi




Şekil 4.26. Cam alt flanş YOLOv5 eğitimi duyarlılık hatırlama eğrisi

Bunları takiben şekil 4.27’de ise hata matrisi görülmektedir. Hata matrisi verilerine göre, uygun kaynak görüntülerinin %40’ının, uygun olmayan kaynak görüntülerinin %20’sinin

ve kaynak olmayan görüntülerin de %40'ının arka plan (background) olarak sınıflandırıldığı, ayrıca “uygun olmayan” kaynak görüntülerinin %50'sinin “uygun” olarak sınıflandırıldığı görüldü.

Eğitim sonrasında modelin başarısı 12 adet test görüntüsü ile kontrol edildi. Test görüntülerine ait çıktılarından 4 adedi toplu olarak Şekil 4.28’de görülmektedir. Test işlemi sonunda sınıflandırma başarımlarının daha düşük olduğu, bazı “uygun olmayan” sınıfına ait kaynakların aynı zamanda “uygun” olarak da sınıflandırıldığı görüldü. Şekil 4.28’de 2 no’lu görüntüde bu durum görülmektedir. Şekil 4.28’de 3 no’lu görüntüde ise “uygun olmayan” sınıfına ait iki adet punta kaynak görüntüsünün, “uygun” olarak sınıflandırıldığı görülmektedir.




Şekil 4.27. Cam alt flanş bölgesi YOLOv5 eğitimi hata matrisi


4.4.2 Arka Duvar Alt Bölgede YOLOv5 Uygulaması

YOLO v5’in arka duvar alt bölgesinde eğitilmesi kapsamında 1280×720 piksel çözünürlüklü 57 adet ana görüntü eğitim amacıyla, 11 adet ana görüntü de validasyon amacıyla olmak üzere toplam 68 ana görüntü kullanıldı. Eğitim öncesinde eğitim ve validasyon görüntülerinde bulunan punta kaynak görüntüleri üzerinden kuşatan kutular

(bounding boxes) belirlendi ve YOLO v5'e görüntüler ile girdi olarak verildi. Şekil 4.29'da ark duvar alt bölgesi YOLOv5 eğitim sonuçları görülmektedir.




Şekil 4.28. Cam alt flanş bölgesi test sonuçları




Şekil 4.29. Arka duvar alt bölgesi YOLOv5 eğitim başarımları


Bu çalışmada eğitim, 300 epok sonunda sonlandırıldı. mAP50 değerleri sırasıyla “uygun” punta kaynaklar için 0,956, “uygun olmayan” punta kaynaklar için 0,847 ve “punta kaynak olmayan” görüntüler için 0,995 olarak tespit edildi. Eğitimin genel mAP50 değeri 0,932 olarak elde edildi. Şekil 4.30’da eğitime ait duyarlılık güven seviyesi eğrisi, Şekil 4.31’de hatırlama güven seviyesi eğrisi ve Şekil 4.32’de duyarlılık hatırlama eğrisi görülmektedir.



Şekil 4.30. Arka duvar alt YOLOv5 eğitimi duyarlılık güven seviyesi eğrisi



Şekil 4.31. Arka duvar alt YOLOv5 eğitimi hatırlama güven seviyesi eğrisi




Şekil 4.32. Arka duvar alt YOLOv5 eğitimi duyarlılık hatırlama eğrisi


Bunları takiben Şekil 4.33'te ise hata matrisi görülmektedir. Hata matrisi verilerine göre uygun kaynak görüntülerinin 0,09 oranında uygun olmayan kaynak olarak tespit edildiği,

aynı zamanda arka plan (background) olarak tespit edilen görüntülerin de “uygun olmayan” olarak sınıflandırıldığı görüldü.

Eğitim sonunda test amacıyla 15 adet farklı görüntü, eğitilen sisteme verildi. Şekil 4.34’te bunlardan 4 adedinin değerlendirme başarımları görülmektedir. Sistemin, “uygun” ve “uygun olmayan” sınıflarına ait punta kaynak görüntülerini 0,9’un üzerinde bir başarımla doğru şekilde sınıflandırdığı görüldü. Fakat burada 4 no’lu görüntüde görüldüğü üzere, sistemin bazı kaynak görüntülerini tespit etmediği ve sınıflandırmadığı da görüldü.



Şekil 4.33. Arka duvar alt bölgesi YOLOv5 eğitimi hata matrisi




Şekil 4.34. Arka duvar alt bölge test sonuçları

4.4.3 A Sütunu Alt Bölgesinde YOLOv5 Uygulaması


YOLO v5'in kabin A sütunu alt bölgesinde eğitilmesi kapsamında 1280×720 piksel çözünürlüklü 47 adet ana görüntü eğitim amacıyla, 10 adet ana görüntü de validasyon amacıyla olmak üzere toplam 57 adet ana görüntü kullanıldı. Eğitim öncesinde eğitim ve validasyon görüntülerinde bulunan punta kaynak görüntüleri üzerinden kuşatan kutular belirlendi ve YOLO v5'e görüntüler ile girdi olarak verildi. Şekil 4.35'te A sütunu alt bölgesi YOLOv5 eğitim sonuçları görülmektedir.

Bu çalışmada eğitim, 300 epok sonunda sonlandırıldı. mAP50 değerleri sırasıyla “uygun” punta kaynaklar için 0,928, “uygun olmayan” punta kaynaklar için de 0,955 olarak tespit edildi. Bu görüntülerde “punta kaynak olmayan” sınıfına ait görüntü bulunmamaktadır. Eğitimin genel mAP50 değeri 0,941 olarak elde edildi. Şekil 4.36'da eğitime ait duyarlılık güven seviyesi eğrisi, Şekil 4.37'de hatırlama güven seviyesi (confidence) eğrisi ve Şekil 4.38'de duyarlılık-hatırlama eğrisi görülmektedir




Şekil 4.35. A sütunu alt bölgesi YOLOv5 eğitim başarımları


Şekil 4.39'da hata matrisi görülmektedir. Hata matrisi verilerine göre arka plan (background) görüntülerinin %50'sinin “uygun” ve diğer %50'sinin “uygun olmayan” olarak sınıflandırıldığı, ayrıca “uygun olmayan” sınıfına ait görüntülerin %15'inin “uygun” olarak sınıflandırıldığı da görüldü.



Şekil 4.36. A sütunu alt bölgesi YOLOv5 eğitimi duyarlılık güven seviyesi eğrisi




Şekil 4.37. A sütunu alt bölgesi YOLOv5 eğitimi hatırlama güven seviyesi eğrisi




Şekil 4.38. A sütunu alt bölgesi YOLOv5 eğitimi duyarlılık hatırlama eğrisi

Eğitim sonrasında sisteme, 10 adet test görüntüsü verildi ve sonuçları incelendi. Şekil 4.40'te test sonucu görüntülerinden 4 adedi görülmektedir. Test sonuçlarının %95'in

üzerinde oranla doğru olduğu görüldü. Şekil 4.40'ta 3. görüntüde görüldüğü üzere, bir adet yarım görünen ve “uygun olmayan” sınıfına ait görüntünün sistem tarafından “uygun” olarak sınıflandırıldığı görüldü.



Şekil 4.39. A sütunu alt bölgesi YOLOv5 eğitimi hata matrisi



Şekil 4.40. A sütunu alt bölge test sonuçları

4.5. Geliştirilen Sistemin Faster R-CNN Modeli İle Karşılaştırılması

Bu çalışmada, ana görüntünün kendisi değil, “uygun”, “uygun olmayan” ve “punta kaynak olmayan” olarak sınıflandırılmak üzere alt görüntüler, ana görüntü üzerinde tespit edilip görüntü kesme (cropping) yöntemi ile elde edilip yukarıdaki bölümlerde anlatılan

çeşitli işlemlerden geçirildikten sonra, uyumlandırılmış AlexNet CNN ağına girdi olarak verildi. Burada elde edilen sonuçları destekleme üzere bu alt görüntülerden elde edilen diğer belirleyici istatistiksel özellikler ile Harris köşe sayısı ve özdeğer sayısı değişimleri de ek veri olarak kullanıldı. Çalışmanın bu bölümünde, tüm bu sistem yerine Faster R-CNN modelinin kullanılıp kullanılamayacağı incelendi.

Bir görüntünün birden fazla nesne içermesi durumunda, görüntünün doğrudan bir CNN ile sınıflandırılması mümkün değildir. Bu nedenle bölge bazlı CNN (Region based CNN, R-CNN) modeli geliştirilmiştir (Girshick ve diğ., 2014). R-CNN modelinde ilk işlem olarak seçici arama (selective search) algoritması ile bir nesne olmaya aday olabilecek bölgeler belirlenir. Ana görüntüde yaklaşık 2000 adet alt bölge ile başlanılan işlemde, birbiri ile yakın görüntü öznitelikleri içeren bölgeler birleştirilir ve ana görüntü üzerinde alt ana bölgeler tespit edilir. Böylece görüntüdeki objeler kümelenmiş olur. Seçici arama algoritması ile belirlenen bölgelerin her biri ayrı bir CNN ağına girdi olarak verilir. CNN ağlarından elde edilen görüntü öznitelikleri kullanılarak destek vektör makinesi (support vector machine, SVM) ile bu görüntünün sınıfı, regresyon algoritmaları ile de kuşatan kutular (bounding box) belirlenir.

Bu algoritmaların uygulanması ile bir görüntüdeki alt görüntüler için çok sayıda kuşatan kutu tespit edilebilir. Bunların hangilerinin kullanılacağını tespit etmek için en büyük olmayanların baskılanması (Non-Max Suppression) yöntemi kullanılır. Bu yöntemde kuşatan kutular üzerinden küme kesişim birleşim oranı (Intersection over Union; IoU) değeri hesaplanır ve bu değerin 0,5'ten büyük olduğu kuşatan kutular alınırken diğerleri baskılanır. Eğer değeri 0,5'ten fazla olan birden fazla kuşatan kutu tespit edilirse, en yüksek değerli olan alınır. IoU değeri, $IoU = \frac{Y \cap \bar{Y}}{Y \cup \bar{Y}}$ ifadesi ile hesaplanır.

R-CNN modeli ile bir görüntüdeki farklı nesneler belirlenebilmektedir, fakat bu algoritma çok fazla işlem yükü gerektirmektedir. Bu nedenle Fast R-CNN modeli geliştirilmiştir (Girshick, 2015). Bu modelde CNN, SVM ve regresyon modelleri birleştirilmiştir. Bu modelde, ana görüntü CNN ile işlenir ve öznitelik haritaları (feature map) elde edilir. Her bölge önerisi için gerekli öznitelikler toplanır ve bunlar, bölgesel önerilen öznitelik haritası (Region Proposal Feature Map) olarak adlandırılır. Ardından bunlar, CNN'de, ilgi alanı (Region of Interest; RoI) adı verilen maksimum havuzlama katmanı (max

pooling) ile belirlenmiş boyutlara indirgenir. Bu işlemten sonra bu öznitelik haritaları tek boyutlu vektör haline getirilir. Bu vektörler yapay sinir ağına girdi olarak verilir ve CNN’de softmax katmanı ile bölgedeki objeye ait sınıf, kuşatan kutu regresörü (bounding box regressor) ile de objenin kuşatan kutusu tespit edilir.


Fast R-CNN algoritması ile R-CNN modeline göre çalışma hızı yüksek oranda artmıştır. Faster R-CNN’de ise (Ren ve diğ., 2015) işlem yükü getiren seçici arama (Selective search) yerine bölgesel öneri ağı (Region Proposal Network; RPN) yaklaşımı kullanmıştır. Faster R-CNN algoritması iki aşamalıdır. İlk aşama olan bölgesel öneri ağı (RPN), bölge önermeye yarayan bir CNN’dir. RPN, girdi olarak herhangi bir boyutta girdiyi alır ve obje skoruna göre bir dizi nesnelere ait olabilecek dikdörtgen önerisi oluşturur. Bu öneri oluşturma işlemi, evrişimli katman tarafından oluşturulan öznitelik haritası üzerinde görece küçük bir ağı kaydırılması yoluyla yapılır. RPN tarafından üretilen bu sonuçlar Fast R-CNN mimarisine girdi olarak verilir ve bir sınıflandırıcı ile objenin sınıfı, regresör ile de kuşatan kutusu tahmin edilir. Böylece ana görüntü üzerindeki farklı nesneler, sınıfları ile birlikte tespit edilmiş olur.

4.5.1. Cam Alt Flanş Bölgesinde Faster R-CNN Uygulaması

Cam alt flanş bölgesinde Faster R-CNN uygulaması için eğitim amacıyla 87 adet, test amacıyla da 32 adet arka duvar ana görüntüsü kullanıldı. Eğitim amacıyla, her bir ana görüntü üzerindeki punta kaynak görüntülerinin kuşatan kutu verileri tespit edildi. Faster R-CNN modelinde ResNet50 CNN modeli kullanıldı. Eğitim sonucunda küçük-parti doğruluğu (Mini-batch Accuracy) değeri %92,3 olarak, RPN küçük-parti doğruluğu değeri de %98,2 olarak tespit edildi. Şekil 4.41’de, cam alt flanş bölgesinde yapılan eğitim sonrasında, eğitilen sisteme verilen görüntülerde sistemin yaptığı tespitler, sınıflandırmalar ve tespit oranları görülmektedir. Cam alt flanş bölgesinde punta kaynaklar, manuel uygulama ile üretilmektedir.

Şekil 4.41’deki 1. görüntüde, “uygun olmayan” sınıfına ait bir punta kaynak görüntüsünün aynı zamanda “uygun” olarak da sınıflandırıldığı görüldü. 2. Görüntüde, eğitim aşamasında bir benzeri “uygun olmayan” olarak sınıflandırılmış bir punta kaynak görüntüsünün 0,71 oranı ile “uygun” olarak sınıflandırıldığı görüldü. 3. Görüntüde alt bölgede, yine birbirine yakın piksel yeğlilik değerlerine sahip olan punta kaynak

görüntülerinden birinin 0,90 oranıyla “uygun olmayan” olarak, diğerinin 0,57 oranıyla “punta kaynak olmayan” olarak sınıflandırıldığı tespit edildi. Yapılan testlerde, “punta kaynak olmayan” sınıfına ait görüntülerin 0,90’ın üzerinde oranlarla doğru sınıflandırıldığı tespit edildi.




Şekil 4.41 Faster R-CNN uygulaması sonucu cam alt flanş bölgesi tespitleri

4.5.2. Arka Duvar Alt Bölgede Faster R-CNN Uygulaması

Arka duvar alt bölgede Faster R-CNN uygulaması için eğitim amacıyla 91 adet, test amacıyla da 51 adet arka duvar ana görüntüsü kullanıldı. Eğitim amacıyla, her bir ana görüntü üzerindeki punta kaynak görüntülerinin kuşatan kutu verileri tespit edildi. Faster R-CNN modelinde ResNet50 CNN modeli kullanıldı. Eğitim sonucunda küçük-parti doğruluğu değeri %82,7 olarak, RPN küçük-parti doğruluğu değeri de %92,9 olarak tespit edildi. Şekil 4.42’de, ark duvar alt kısımda yapılan eğitim sonrasında eğitilen sisteme verilen görüntülerde sistemin yaptığı tespitler, sınıflandırmalar ve tespit oranları görülmektedir. Arka duvar bölgesinde punta kaynaklar, robotik uygulama ile üretilmektedir. Bu nedenle kaynak görüntüleri yüksek oranda “uygun” sınıfına aittir ve uygun olmayan sınıfına ait kaynak görüntüsü oranı görece çok azdır. Bununla birlikte, eğitilen Faster R-CNN’de “uygun olmayan” olarak sınıflandırılmış bazı kaynak görüntülerindekilere benzer kaynak hatalarını içeren görüntülerin de “uygun” olarak sınıflandırıldığı görüldü. Ayrıca, sınıflandırma skoru açısından bakıldığında, yapılan

60'tan fazla denemede, en yüksek sınıflandırma skoru değerinin 0,70'ler civarında olduğu, yani sistemin en yüksek %70 civarında bir başarımla görüntüyü sınıflandırdığı görüldü.




Şekil 4.42 Faster R-CNN uygulaması sonucu arka duvar alt bölge tespitleri

4.5.3. A Sütunu Alt Bölgede Faster R-CNN Uygulaması

A Sütunu alt bölgede Faster R-CNN uygulaması için eğitim amacıyla 52 adet, test amacıyla da 12 ana görüntü kullanıldı. Eğitim amacıyla, her bir ana görüntü üzerindeki punta kaynak görüntülerinin kuşatan kutu verileri tespit edildi. Faster R-CNN modelinde ResNet50 CNN modeli kullanıldı. Eğitim sonucunda küçük-parti doğruluğu değeri %75,8 olarak, RPN küçük-parti doğruluğu değeri de %96,8 olarak tespit edildi. Şekil 4.43'te, A sütunu alt kısımda yapılan eğitim sonrasında eğitilen sisteme verilen görüntülerde sistemin yaptığı tespitler, sınıflandırmalar ve tespit oranları görülmektedir.

Yapılan denemelerde, 1. ve 4. görüntülerde görüldüğü gibi, aynı kaynak görüntüsünün birden fazla kez değerlendirildiği, 2. görüntüde görüldüğü gibi “uygun olmayan” sınıfına ait kaynak görüntüsünün “uygun” olarak da değerlendirildiği, “uygun” olarak sınıflandırılan kaynak görüntülerine ait skorların yaklaşık 0,7 olduğu görüldü.



Şekil 4.43 Faster R-CNN uygulaması sonucu A sütunu alt bölge tespitleri

4.6. Punta Kaynak Görüntülerinin Sayısal Verilerinin Yapay Sinir Ağı Haricindeki Yöntemler Kullanılarak Sınıflandırılması

Bu çalışmada, punta kaynak görüntülerinin yüksek başarımları ile sınıflandırılabilmesi amacıyla, punta kaynak görüntülerine ait istatistiksel özelliklerin yanında Harris köşe sayıları değişimi ve görüntü özdeğer (eigenvalue) sayıları değişimi verileri de kullanıldı. Bu sayısal değerler, veri sayısına bağlı olarak oluşturulan yapay sinir ağları kullanılarak sınıflandırıldı. Bu bölümde, verilerin sınıflandırılmasında farklı yöntemlerin kullanılması ve başarımları incelendi.


4.6.1 Verilerin Destek Vektör Makinesi Kullanılarak Sınıflandırılması

Punta kaynak görüntülerinden elde edilen istatistiksel veriler ile Tablo 3.5'te görülen temel parametreler matrisi oluşturulduğu daha önce belirtilmişti. Cam alt flanş bölgesinde yapılan çalışmada, bu veriler ile eğitilen ve eğiticili öğrenme sınıfında bulunan bir geri yayılım yapay sinir ağı kullanılarak elde edilen başarımları Şekil 4.44'te verildi. Burada yapay sinir ağının genel başarımlarının %95,1 olarak gerçekleştiği görüldü. Bu veri setinin destek vektör makinesi (Support Vector Machine, Türkçe DVM) kullanılarak yapılan eğitimlerinde ise validasyon sınıflandırma doğruluğu (accuracy) değerlerinin sırasıyla, ikinci derece (Quadratic) DVM için %91,6, doğrusal (Linear) DVM için %91,6, kübik (Cubic) DVM için %92,1, hassas seviye Gauss (Fine Gaussian) DVM için %81,8,

kaba seviye Gauss (Coarse Gaussian) DVM için %87,2 ve en yüksek değer olarak orta seviye Gauss (Medium Gaussian) DVM için %93,6 olarak tespit edildi. Şekil 4.45'te orta seviye Gauss DVM eğitiminin sonucunda elde edilen hata matrisi görülmektedir.

All Confusion Matrix				
Output Class	1	2	3	
	23 11.3%	2 1.0%	0 0.0%	92.0% 8.0%
	7 3.4%	98 48.3%	1 0.5%	92.5% 7.5%
	0 0.0%	0 0.0%	72 35.5%	100% 0.0%
				Target Class
				1 2 3

Şekil 4.44. Cam alt flanş bölgesi istatistiksel veri seti NN eğitimi sonucu hata matrisi



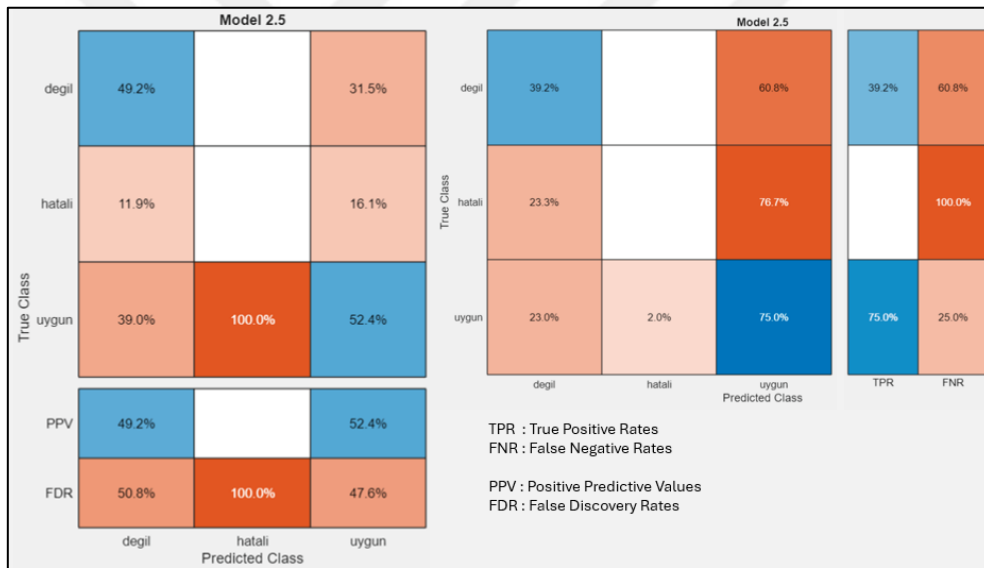
Şekil 4.45. Cam alt flanş bölgesi istatistiksel veri setinin orta seviye Gauss DVM eğitimi sonucu hata matrisi

Görüntünün bir diğer sayısal verisi olan özdeğer değişimi (MEF) veri setinin NN ile eğitim sonucunda elde edilen hata matrisi Şekil 4.46'da görüldüğü gibidir. Bu veri setinin DVM kullanılarak yapılan eğitimlerinde ise validasyon sınıflandırma doğruluğu değerlerinin sırasıyla, ikinci derece SVM için %47,5, doğrusal DVM için %45,6, kübik DVM için %41,2, hassas seviye Gauss DVM için %46,4, kaba seviye Gauss DVM için %49,0 ve en yüksek değer olarak orta seviye Gauss DVM için %51,0 olarak tespit edildi.

Şekil 4.47’de MEF verileri için orta seviye Gauss DVM eğitiminin sonucunda elde edilen hata matrisi görülmektedir.

All Confusion Matrix				
Output Class	1	2	3	
	21 10.3%	6 3.0%	0 0.0%	77.8% 22.2%
	9 4.4%	93 45.8%	5 2.5%	86.9% 13.1%
	0 0.0%	1 0.5%	68 33.5%	98.6% 1.4%
				Target Class
				1 2 3

Şekil 4.46 Cam alt flanş bölgesi MEF verileri NN eğitimi sonucu hata matrisi



Şekil 4.47. Cam alt flanş bölgesi MEF verileri orta seviye Gauss DVM eğitimi sonucu hata matrisi

MEF Verilerinin NN ile yapılan eğitim sonucunun, DVM ile elde edilen sonuçlara göre daha yüksek başarımla seviyesine sahip olduğu görüldü.


Görüntüye ait Harris köşe sayılarının değişimi ile elde edilen veri seti ile eğitilen NN sonucuna ait başarımla değerleri ve hata matrisi Şekil 4.48’de görülmektedir.

Bu veri setinin DVM kullanılarak yapılan eğitimlerinde ise validasyon sınıflandırma doğruluğu (accuracy) değerlerinin sırasıyla, ikinci derece DVM için %45,6, doğrusal

DVM için %46,6, kübik DVM için %46,1, hassas seviye Gauss DVM için %47,5, orta seviye Gauss DVM için %48,5 ve en yüksek değer olarak kaba seviye Gauss DVM için %49,0 olarak tespit edildi. Şekil 4.49’da Harris köşe sayıları verileri için kaba seviye Gauss DVM eğitiminin sonucunda elde edilen hata matrisi görülmektedir.

All Confusion Matrix				
Output Class	1	2	3	
	22 10.8%	3 1.5%	0 0.0%	88.0% 12.0%
	8 3.9%	92 45.3%	4 2.0%	88.5% 11.5%
	0 0.0%	5 2.5%	69 34.0%	93.2% 6.8%
				Target Class
				1 2 3

Şekil 4.48. Cam alt flanş bölgesi Harris köşe sayıları verisi NN eğitimi sonucu hata matrisi



Şekil 4.49. Cam alt flanş bölgesi Harris köşe sayıları verileri kaba seviye Gauss DVM eğitimi sonucu hata matrisi

Görüntünün histogram verileri ile eğitilen NN sonucuna ait başarımlar ve hata matrisi Şekil 4.50’de görülmektedir.

Histogram veri setinin DVM kullanılarak yapılan eğitimlerinde ise sınıflandırma doğruluğu değerlerinin sırasıyla, ikinci derece DVM için %42,2, doğrusal DVM için %47,1, kübik DVM için %42,6, hassas seviye Gauss DVM için %49,5, kaba seviye Gauss

DVM için %49,0 ve en yüksek değer olarak orta seviye Gauss DVM için %52,0 olarak tespit edildi. Şekil 4.51’de histogram verileri için orta seviye Gauss DVM eğitiminin sonucunda elde edilen hata matrisi görülmektedir

All Confusion Matrix				
Output Class	1	2	3	
	18 8.9%	2 1.0%	0 0.0%	90.0% 10.0%
	12 5.9%	98 48.3%	2 1.0%	87.5% 12.5%
	0 0.0%	0 0.0%	71 35.0%	100% 0.0%
Target Class				
	1	2	3	
	60.0% 40.0%	98.0% 2.0%	97.3% 2.7%	92.1% 7.9%

Şekil 4.50. Cam alt flanş bölgesi histogram verisi NN eğitimi sonucu hata matrisi

Model 2.5				
True Class	degil	hatali	uygun	
	51.0%	9.8%	39.2%	
	35.1%	16.7%	20.0%	
	31.8%	15.9%	52.3%	
Predicted Class				
	degil	hatali	uygun	
PPV	51.0%	50.0%	52.3%	
FDR	49.0%	50.0%	47.7%	
Model 2.5				
True Class	degil	hatali	uygun	
	35.1%	3.3%	79.0%	
	64.9%	80.0%	79.0%	
	35.1%	3.3%	79.0%	
Predicted Class				
	degil	hatali	uygun	
TPR	35.1%	3.3%	79.0%	
FNR	64.9%	96.7%	21.0%	

Şekil 4.51. Cam alt flanş bölgesi histogram verileri orta seviye Gauss DVM eğitimi sonucu hata matrisi

4.7. Şimdiye Kadar Yapılan Çalışmaların Işığında Bulguların Değerlendirilmesi ve Tartışma

Elektriksel direnç nokta kaynaklarının kalite seviyelerinin tespit edilmesine yönelik yapılan çalışmalarda, evrimsel yapay sinir ağlarının kullanımı genellikle tercih edilen bir yöntem olduğu görüldü. Bu çalışmalarda %98’in üzerinde sınıflandırma başarısı elde edildiği ifade edilmiştir. (Guo ve diğ, 2017). Ancak çalışmalar incelendiğinde, punta

kaynak görüntülerinin kamera açısı ve aydınlatma seviyesi gibi mutlaka belirli şartlar altında alınması gerektiği belirtilmişti. Bu gerekliliklerin, seri üretim şartları altında her zaman istenildiği şekilde ve ideal olarak sağlanamadığı, seri üretim şartlarında yapılan çok sayıda deneme sırasında görüldü.

Ayrıca, CNN uygulamalarında punta kaynak genişliğini parametre olarak kullanan farklı yaklaşımlar da olmuştur (Hwang ve diğ., 2018; Alghannam ve diğ., 2019). Bu yöntemlerde punta kaynak genişliğinden yola çıkılarak kaynak kalitesi değerlendirilmiştir. Ancak buradaki şart, punta kaynak yapısının mutlaka çember şeklinde olması gerekliliği olmuştur. Bu gereklilik, yöntemlerin seri üretim şartlarında uygulanmasını çok zor hale getirmiştir. Yapılan çalışmada, özellikle manuel yöntemlerle üretilen punta kaynaklarda kaynak makinesi çenelerinin yan basmaları veya uçlukların simetrik aşınmamaları gibi nedenlerle, punta kaynakların dairesel formda oluşmadıkları tespit edildi. Bu nedenle çalışma geliştirilmiş, dairesel formda olmayan punta kaynak görüntülerinin de tespit edilebilmesi geometrik yöntemler kullanılarak sağlanmıştır (Younes ve diğ., 2020).

Punta kaynak görüntüleri üzerinde yapılan bir diğer çalışmada, kaynak ısı izi görüntüsü üzerinde durulmuştur (Choi ve diğ., 2019). Fakat, yüzey ısı izi görüntüsünün fotoğraflanması sürecinde, kameranın odağı veya ışıklandırma gibi görüntüyü etkileyen durumlar oluştuğunda, kaynak kalite seviyesini belirleme süreci olumsuz veya hatalı sonuçlar verecek şekilde sonuçlanabilir. Bu uygulamanın yüksek oranda ortam şartlarına bağlı olduğu görülmüştür.

CNN ile yapılan benzer bir diğer uygulamada da punta kaynakların, kaynak işlemi sonrasında kızıl ötesi ışımaları incelenmiş ve bu ışıma görüntüsü kullanılarak bir sınıflandırma yapılmıştır (Veitía ve diğ., 2020). Bu yöntemin uygulanması, ancak robotik uygulamalarda ve belirli sınırlar dahilinde mümkün olacağından, önerilen yöntem farklı seri üretim şartları için uygun bulunmamıştır.

Bir diğer yaklaşımda ise punta kaynak parametreleri olan dışarı çıkma oluşumu, girinti derinliği ve çekme kesme mukavemeti üzerinde durularak, bir lojistik regresyon modeli geliştirilmiştir (Kim ve diğ., 2021). Bu çalışmada üzerinde durulan parametreler, %85 ile %94 arasında başarımlar oranlarıyla tahmin edilebilmiştir.

Yapay sinir ağlarının tahmin edebilme kabiliyetinin incelendiği farklı bir çalışmada ise çok katmanlı algılayıcı (multi layer perceptron) ve punta kaynak süreç göstergeleri (akım, gerilim, direnç) kullanılarak sınıflandırma yapılmıştır (El-Sari ve diğ., 2021). Çalışma sonucunda tahmin edilen punta kaynak çaplarının %90'ının, gerçekleşen punta kaynaklara göre %10'dan daha az sapma gösterdiği tespit edilmiştir. Bu çalışmanın sonucunda, punta kaynak büyüklüğü ile ilgili kesin bir sayısal değer tahmin edilemediği ve mutlaka bir sapma bulunduğu görülmektedir. Önerilen sistem, kaynak kalitesini punta kaynak büyüklüğü üzerinden değerlendirmiştir.

Punta kaynak ısı izi görüntüsü üzerinde yapılan bir diğer çalışmada ise CNN olarak yeni bir yapay sinir ağı geliştirilmemiş, bunun yerine MobileNetV3 CNN yapısı görüntü özelliklerine göre tekrar şekillendirilerek kullanılmıştır (Piriyabunjerd ve diğ., 2021). Bu çalışmada %94,3 F1 puanı elde edildiği belirtilmiştir.

Diğerlerinden farklı olarak bir diğer yöntemde, kaynak bağlantı kalitesi için proses parametrelerinin çevrimiçi tahminini ve kendi kendine optimizasyonunu sağlamak amacıyla bir kaos oyunu optimizasyon algoritması önerilmiştir (He ve diğ., 2022). Bu çalışmada punta kaynakların merkez çapları ve çekme kayma yükleri tahmin edilmiştir.

Çoklu sinyal füzyonu ve düğme çapı verilerinin kullanıldığı bir diğer çalışmada ise bir geri yayılım yapay sinir ağı, sinüs-kaotik haritayla geliştirilmiş serçe arama algoritması (SSA) kullanılarak optimize edilerek kullanılmıştır (Hu ve diğ.,2022).

Yine kaynak makinesi parametrelerinin incelendiği ve bu verilere göre punta kaynak kalitesinin belirlendiği bir diğer çalışmada (Chang ve diğ., 2023), sistemin kaynak akım, gerilim ve direnç değerlerini okuyabilmesi için punta kaynak makinelerine bağlanması gerekliliği oluşmuştur.

Yapılan bir diğer çalışmada, kaynak parametreleri olarak kaynakta çapak oluşumu, akım, gerilim, direnç, kaynak makinesi kollarındaki baskı kuvveti, kaynak süresi, kullanılan ürün (kaynakla birleştirilen metallerin özellikleri) gibi veriler kullanılmıştır (Bayır ve diğ., 2023). Bu verilere ilişkin en küçük ve en büyük değerlerin yanında standart sapma değeri de parametre olarak alınmıştır. Çapak oluşumunun bağımsız değişken olarak değerlendirildiği çalışmada, lojistik regresyon ve destek vektör makinesi gibi çeşitli

yöntemler kullanılmış, tanımlanan parametrelerin önerilen yöntemler ile öğrenilmesi sağlanmaya çalışılmıştır. Bu çalışmada elde edilen en yüksek F1 değeri 0,95 olarak bulunmuştur. Çalışmanın uygulama zorluğu, çok sayıda verinin punta kaynak makine ve sistemlerinden toplanabilmesi için geliştirilen sistemin doğrudan bu makinelere bağlanma zorunluluğu olmasıdır.

Kaynak parametreleri kullanılarak yapılan farklı bir çalışmada (Halim ve diğ., 2023), SS304 çeliği kullanılarak yapılan punta kaynak prosesinde, kaynak işleminin çevrim süresi, kaynak akımı, kaynak makinesi çenelerinin baskı kuvveti ve kaynağın çekme kesme dayanım kuvveti parametre olarak kullanılmış, bu veriler ile klasik bir geri yayılım yapay sinir ağı eğitilip, veriler “iyi”, “kötü” ve “en kötü” olarak sınıflandırılmıştır. Eğitim sonucunda elde edilen başarımların %82 ile %93 arasında olduğu belirtilmiştir. Bu çalışmanın uygulanması için kaynak makinesine bağlantı yapıp gerekli parametrelerin toplanması gerektiği görülmektedir. Bu durum uygulama maliyetinin artmasına neden olmaktadır. Çalışma, bu parametrelerin basitçe yapay sinir ağı ile sınıflandırılmasını içermekte, hatta sonuç sınıflarının kaynağın çekme kesme dayanım kuvveti değerlerine bağlandığı görülmüştür. Bu durum, endüstriyel uygulamalarda, hatalı olmasına rağmen yüksek mukavemet gösteren kaynakların yanlış sınıflandırılmasına neden olacaktır.

Diğer bir çalışmada, reaktans sinyalinin kaynak süresince dinamik değişimine odaklanılmış ve bu veri radar diyagramı yöntemi kullanılarak incelenmiştir (Fu ve diğ.,2024). Elektronik komponentlerin kaynaklanması, daha doğrusu lehimlenmesi prosesinde alüminyum bileşikleri içeren malzemelerin kaynaklanmasındaki ısı sorunu bilinmektedir. Yapılan bir çalışmada, bu sorun incelenmiş, alüminyum lehim görüntüsü, dalgacık (wavelet) yöntemi, bir boyutlu Mallet dekompozisyonu ve iki boyutlu Mallet dalgacık dekompozisyon algoritması kullanılarak incelenmiştir (Wang, 2024). Diğer bir çalışmada, karoseri yüzeyindeki punta kaynakların titreşime verdiği tepki LGHGNN (Local-Global Hierarchical Graph Neural Network) kullanılarak incelenmiş, sistemin başarımları, araç karoserisi sağ ön kapı üzerinde yapılan uygulamada çok bölgeli paralel anormallik tespitinde %97,5 olarak elde edilmiştir (Xi ve diğ.,2024).

Punta kaynağın direnç eğrilerine dayanan bir diğer çalışmada (Geng ve diğ., 2024) punta kaynak makinesine yapılan bağlantı ile elde edilen akım ve gerilim değerlerinden

hesaplanan direnç eğrilerinin, önce GAN (Generative Adversarial Network) yapay sinir ağı sistemi kullanılarak sahte (fake) benzerleri oluşturulmuş, ardından bu üretilen sahte eğriler ile gerçek eğriler birleştirilip nihai eğriler elde edilmiş ve direnç değeri değişkenliği ile oluşturulan bu eğriler, bir CNN kullanılarak sınıflandırılmıştır. Bu çalışmada, kaynakta bir uygunsuzluk olup olmadığını tespit etme açısından başarı oranının %98,4 olduğu belirtilmiştir ve çalışma, direnç değeri eğrilerini kullanan daha önce yapılan benzer çalışmalara göre daha yüksek başarı değeri elde etmiştir. Fakat bununla birlikte, bu çalışmanın herhangi bir punta kaynak üretim sürecine uygulanması için sistemin punta kaynak makinesinden akım ve gerilim değerlerini okuması gerekmektedir. Bu gereklilik kolay uygulanabilirlik açısından engel oluşturmakta, uygulama için yatırım gerektirmektedir. Ayrıca bu çalışmada punta kaynaklar, kaynak yanması, yetersiz kaynak ve kaynak sıçraması olmak üzere 3 adet kaynak kusuru sınıfı ve 1 adet normal kaynak sınıfı olmak üzere 4 kategoride sınıflandırılmıştır. Normal kaynağın tespit edilme başarısı %100 olarak verilmiştir. Fakat yetersiz kaynak tespit başarısı %30,95 olarak, kaynak sıçraması tespit başarısı ise %90,32 olarak verilmiştir. Direnç değeri eğrilerindeki gürültünün GAN uygulaması ile bastırılması, bu sınıflara ait direnç değeri eğrilerindeki karakteristik değişkenlikleri de bastırmakta ve eğriler arasındaki benzerlikleri arttırmaktadır. Birbirine yüksek benzerlik içeren verilerin sınıflandırılmasında ise CNN başarımı yüksek olmamaktadır.

Yapılan bu farklı çalışmaların tümünde gözlemlenen uygulama zorlukları, geliştirilen sistemlerin girdi olarak kullandıkları verilere ulaşabilmeleri için kaynak makinelerine bağlanma zorunluluğu olması, görüntü üzerinde çalışan sistemlerin ise kaynak görüntüsünü alabilmeleri için özel ortam şartlarının sağlanması gerekliliğidir. Bu temel nedenlerle, farklı çalışmalarda geliştirilen bu sistemlerin seri üretim şartlarında uygulanabilmesi, ticari işletmelerde mevcut şartlara ek olarak aydınlatma, makine ve sistemler arasında veri akışının sağlanması, ilave sensörlerin kullanılması gibi belirli bir yatırımın yapılmasını zorunlu kılmaktadır. Bazı çalışmaların, belirli bir ışık şiddetiyle ortam aydınlatması gerektirmesi gibi ek özellikler ise seri üretim şartlarında uygulama sırasında, olası ortam değişikliklerinde sistemlerin beklenmeyen sonuçlar üretebilmesine neden olacaktır.

Bu çalışmada geliştirilen algoritmada, hem kaynak görüntüleri hem de kaynak

görüntülerinin merkezinde bulunan kaynak etki alanındaki piksel yeğlilik değerlerinden oluşturulan ortalama, standart sapma, mod, medyan, varyans katsayısı ve histogram değerleri gibi parametreler kullanıldı. Bu değerler, temel istatistik verileri olduğu için punta kaynak görüntüsü hakkında bir değerlendirme yapılabilmesini sağladı. Bununla birlikte, ağırlıklı piksel yeğlilik değerleri düşük değerlerde (0 – 125 aralığında) olan veya yüksek değerlerde (126 – 255 aralığında) olan görüntülerde de standart sapma veya varyans katsayısı gibi değerlerin birbirine çok yaklaşık değerler olarak elde edilebileceği tespit edildi. Bu durumu dengelemek ve görüntünün sınıflandırılmasında ayırt edici bir özellik oluşturabilmek amacıyla, görüntünün histogramı da görüntü parametrelerinden biri olarak kullanıldı. Ayrıca, histogramın en yüksek 1. ve 2. değerleri ve bu değerlerin histogram grafiğinde birbirlerine olan uzaklığının oranı da kullanılan parametrelerden biri oldu.

Bunlara ek olarak, şimdiye kadar yapılan diğer çalışmalarda kullanımı ve uygulaması görülmemiş olan, punta kaynak görüntüsünün Harris köşeleri sayısı ve en küçük öz değer sayısı öz niteliği, yani MEF (minimum eigenvalue features) sayısı da parametre olarak alındı ve görüntü sınıflandırmada ayırt edici özellik olarak kullanıldı. Bunların yanında diğer bir yeni parametre olarak, görüntüdeki Harris köşeleri ve MEF sayılarının tespitinde, algoritmadaki eşik değerinin değiştirilmesi ve bu yöntem ile elde edilen 100'er adet köşe sayıları değişken değerleri de görüntü parametresi olarak kullanıldı.

Geliştirilen sistem 5 adet yapay sinir ağı eğitimi ve 1 adet CNN eğitimi ile desteklendi ve her punta kaynak için kendisine özgü tanımlayıcı veriler ile bu yapay sinir ağları eğitildi. Uygulama aşamasında, bu yapay sinir ağlarından elde edilen sonuçlar, bir değerlendirme algoritmasından geçirilerek, punta kaynağın sınıflandırma sonucu belirlendi. Sistem, kameradan alınan görüntülerin sürekli analiz edilmesi ve bir sonuç üretilmesi şeklinde tasarlandı. Görüntünün değişmemesi ve aynı görüntünün ard arda alınması durumunda, görüntünün değişip değişmediği kontrol edildi. Değişme yok ise ilk görüntüde tespit edilen punta kaynak koordinatlarında, tespit edilen tüm punta kaynak sonuçlarının aynı punta kaynağa ait olmasından hareketle, bir punta kaynağa ait ard arda alınan sınıflandırma sonuçlarının ağırlıklı dağılımı alınarak nihai sınıflandırma sonucu oluşturuldu. Bu algoritma sayesinde, ekranda sürekli değişken bir sınıflandırma görüntüsü değil, birkaç işlem döngüsü içerisinde sınıflandırma sonucu sabitlenen bir

kaynak görüntüsü elde edildi.

Bu çalışmayı diğerlerinden ayıran diğer bir önemli özellik ise sistemin, kabin yüzeyinde benzer özellik gösteren punta kaynakları için ayrı bölümlerin, alanların tanımlanması sayesinde her bir punta kaynak grubu için ayrı şekilde eğitilebilmesidir. Bu sayede birbirine çok benzeyen, fakat robotik veya manuel gibi farklı üretim prosesleri ile üretildikleri için farklı kalite seviyesi sınıflarına ayrılan kaynakların yapay sinir ağı ve CNN ile sınıflandırılmasındaki zorluğun aşılmış olmasıdır. Bu zorluk, şimdiye kadar özellikle görüntüler için CNN ve parametrelerin sınıflandırılmasında yapay sinir ağı kullanılan uygulamalarda da mevcuttur. Fakat detaylı incelendiğinde, yapılan diğer çalışmaların aynı kaynak makinesinden elde edilmiş olan veya belirli iki metal türünün kaynaklanması ile elde edilen tek tip punta kaynaklar üzerinde uygulandığı görülmektedir. Bu çalışmada geliştirilen sistem ise kaynak prosesinden, kaynak makinelerinden, kaynaklanan parçalardan ve ortam şartlarında bağımsız olarak, her tür seri üretim şartında uygulanabilir şekilde tasarlandı.

Bu çalışmada, ana görüntülerden punta kaynak görüntülerinin elde edilmesi sürecinden başlamak üzere, ana görüntünün kendisini doğrudan işleyip punta kaynak görüntülerini tespit ederek işlem adımlarını azaltabilecek yöntemler de punta kaynak görüntülerinin sınıflandırılması amacıyla incelendi. Bu amaçla YOLO v5 ve Faster R-CNN nesne tanıma algoritmaları uygulandı.

YOLO v5 uygulamasında, cam alt flanş bölgesinde yapılan eğitimde, mAP50 değerinin 0,993 olarak tespit edilmesine rağmen, özellikle “uygun olmayan” sınıfına ait kaynak görüntülerinde sınıflandırma başarımının görece daha düşük olduğu tespit edildi. Bu “uygun olmayan” sınıfındaki kaynak görüntülerinin yüksek bir doğrulukla sınıflandırılmaması durumu, Şekil 4.25’te hatırlama güven seviyesi grafiğinde “nok_spot_weld” sınıf adı ile tanımlanan “uygun olmayan” sınıfına ait eğrinin, 0,4 güven seviyesi (confidence) değeri civarında hatırlama (recall) değerinin keskin bir düşüş yapmasıyla da görülmektedir.

Arka duvar alt bölgesinde yapılan YOLOv5 eğitim sonuçlarında da yüksek başarımlı değerleri görüldü. Bu bölgede mAP50 değeri 0,932 olarak tespit edildi. Fakat bu çalışmada da Şekil 4.30’daki duyarlılık güven seviyesi grafiğinde “uygun olmayan”

sınıfına ait eğride, güven seviyesinin artmasına rağmen duyarlılık değerinin beklenen seviyeye ulaşmaması durumu görüldü. Bu değer, güven seviyesinin 0,9 seviyesine gelmesi sonrasında artması, “uygun olmayan” sınıfına ait kaynak görüntülerinin sınıflandırılmasında yerli seviyeye ulaşamadığını göstermektedir. Öte yandan, Şekil 4.34’teki 4 no’lu görüntüde görülen, kaynak görüntülerinin tespit edilememesi durumu, bu veya buna benzer R-CNN gibi bir sistemin kullanılmasının uygun olmadığını göstermektedir. Burada sistemin, daha önce tanıtımı yapılan kaynak görüntülerinden daha farklı piksel yeğlilik değerlerine sahip bir kaynak görüntüsünü tespit edemediği görüldü. Punta kaynak proseslerinin, çok farklı piksel yeğlilik değerlerine sahip kaynak görüntüleri oluşturabileceği daha önceki bölümlerde açıklandı. YOLO veya benzeri bir sistemin çalışma yapısı göz önüne alındığında, bu farklılıklardan en az oranda etkilenme için 1000 adetler gibi görece yüksek sayıda kaynak görüntüsü ile eğitilmesi gerekliliği de değerlendirildi. Fakat, bu çalışmaların başlangıç aşamalarında, uyumlandırılmış AlexNet CNN ile doğrudan kaynak görüntüleri kullanılarak yapılan eğitim çalışmalarında, kabin yüzeyinin çeşitli bölgelerinden elde edilen 3.000 adet punta kaynak görüntüsü kullanıldı ve eğitim başarımlarının en fazla %35-%45 seviyelerinde olduğu tespit edildi. Bu durumun, farklı sınıflara ait kaynak görüntüleri arasındaki görece çok küçük piksel yeğlilik değeri farklılıklarının CNN tarafından ayırt edilememesinden kaynaklandığı görüldü. Bu nedenle, geliştirilen sistemde, punta kaynak görüntüsünün en az %90 gibi yüksek bir doğrulukla sınıflandırılması hedeflendiği için sistem tek bir CNN ile değil, 5 farklı yapay sinir ağıyla da desteklendi.

Bunlara ek olarak, A sütunu alt bölgesindeki kaynaklar da YOLOv5 ile incelendi. Bu bölgede de başarımlarının görece yüksek çıktığı görüldü. Tüm bunlarla birlikte bir genel değerlendirme olarak; robotik punta kaynak prosesleri ile üretilen punta kaynaklarda (arka duvar alt ve A sütunu altı), sınıflandırma başarımlarının yüksek olduğu, manuel yöntemler ile üretilen punta kaynaklarda sınıflandırma başarımlarının ise görece daha düşük olduğu görüldü. Şekil 4.28’de de görüldüğü üzere, hatalı sınıflandırılan punta kaynaklar olduğu ve doğru sınıflandırılanların da sınıflandırma başarımlarının %90’ın altında olduğu tespit edildi. Bu tespitler doğrultusunda, YOLO nesne tespit sisteminin punta kaynak görüntüleri gibi piksel yeğlilik değerleri açısından birbirlerine çok yakın olup, sürekli yeni ve farklılıklar içeren görüntülerin olduğu bir sistemde, görüntüleri sınıflandırmak amacıyla tek başına kullanımı ile

yüksek başarı değerleri elde edilemediği, mutlaka farklı verilerle de desteklenmesi gerektiği görüldü.

Bunların yanında, kabin yüzeyinden alınan ana görüntü üzerindeki punta kaynak alt görüntülerinin tespit edilip sınıflandırılması amacıyla Faster R-CNN algoritması da uygulandı. Çalışmanın bu aşamasında Faster R-CNN'in, manuel kaynak prosesleri ile elde edilen ve piksel yeşinlik değerleri açısından birbirlerinden görece daha fazla farklılık gösteren kaynak görüntülerinin sınıflandırılmasında, robotik uygulamalar ile elde edilen ve piksel yeşinlik değerleri açısından birbirlerine daha yakın olan kaynak görüntülerinin sınıflandırılmasına göre daha yüksek sınıflandırma başarısı gösterdiği tespit edildi. Bununla birlikte, Şekil 4.41'de de görüldüğü üzere, cam alt flanş bölgesine ait punta kaynakların sınıflandırılmasında bir punta kaynak görüntüsüne denk gelen birbirine yakın bölgelerin farklı şekilde sınıflandırılabilirdiği görüldü. Ayrıca, kabin arka duvar alt bölgesi ve A sütunu alt bölgesindeki uygulamaları içeren Şekil 4.42 ve Şekil 4.43'te de görüldüğü üzere, genel sınıflandırma başarımlarının 0,7 civarında olduğu tespit edildi. Test aşamasındaki punta kaynak görüntüsünün piksel yeşinlik değerlerinin eğitim aşamasında kullanılan punta kaynak görüntüsü piksel yeşinlik değerlerine benzerlik göstermesi durumunda, sınıflandırma başarımlarının daha yüksek olduğu tespit edildi. Fakat punta kaynak görüntüleri piksel yeşinlik değerlerinin hiçbir zaman birbirinin aynı olmadığı daha önceki bölümlerde de belirtildi ve bu nedenle Faster R-CNN yöntemi ile elde edilen sınıflandırma başarımlarının genel olarak %90'lar seviyelerine ulaşamadığı görüldü. Bunların yanında, R-CNN algoritmasının görüntüyü bölgelere ayırmasının bir sonucu olarak, ana görüntüdeki punta kaynak görüntülerinin her uygulamada hatasız tespit edilemediği, bir punta kaynak görüntüsünü içeren birden fazla alt bölgenin tespit edilip bu bölgelerin farklı sınıflandırıldığı da görüldü. Bu durumun, bir kaynak görüntüsünün hem “uygun” hem de “uygun olmayan” sınıfına dahil edilmesi sonucunu verdiği tespit edildi.

Tüm bunların yanında, punta kaynak görüntülerinin sınıflandırılmasında nihai başarımlarının artırılması amacıyla görüntüden elde edilen sayısal verilerin de yapay sinir ağları (NN) kullanılarak sınıflandırıldığı ve nihai başarımda bu sonuçların da kullanıldığı önceki bölümlerde açıklandı. Çalışmada, bu sayısal verilerin NN harici farklı bir yöntem kullanılarak sınıflandırılması üzerinde de çalışıldı. Bu amaçla destek vektör makinesi

kullanıldı.

Yapılan çalışmalarda, sadece 12 adet veri içeren punta kaynak görüntüsü istatistiksel veri setinde orta seviye Gauss DVM ile yapılan eğitimde %95'in üzerinde genel validasyon başarımları elde edildi. Bu veri setinin NN başarımları da %95,1 olarak elde edildi. Takiben, MEF veri seti NN eğitiminde %89,7, SVM eğitiminde %51,0, Harris veri seti NN eğitiminde %90,1, DVM eğitiminde %49,0 ve histogram veri seti NN eğitiminde %92,1, SVM eğitiminde %52,0 başarımları değerleri elde edildi.

Çalışmanın bu aşamasında, punta kaynak görüntülerine ait sayısal veriler ile NN eğitimi ile elde edilen başarımlar seviyesinin, DVM kullanılarak yapılan eğitimde elde edilen başarımlar seviyesine göre çok daha yüksek ve kabul edilebilir seviyelerde olduğu görüldü. Bu nedenle çalışmada, sayısal veriler ile yapılan sınıflandırmalarda DVM değil, geri yayılım yapay sinir ağları kullanıldı.

Bu çalışmada üç hipotez üzerinde duruldu. Bunlardan birincisi; karmaşık hesaplama yüküne girmeden görece hızlı çalışan ve çeşitli üretim süreçlerine kolay uyumlandırılabilen bir sistem elde etmek şeklinde tanımlandı. Geliştirilen yazılım ile sistemin görece hızlı çalıştığı, sistemin bir punta kaynak görüntüsünü, sadece görüntünün sınıflandırma aşaması değil, tüm ön hazırlık işlemleri de dahil olmak üzere toplamda 300 milisaniye altında bir sürede analiz edebildiği tespit edildi. Ayrıca sistem, doğrudan görüntü üzerinde işlem yapılması nedeniyle, tüm punta kaynak proseslerine uyarlanabilecek şekilde geliştirildi. Yapılan çalışmalarda bu durum ispat edilebildi.

İkinci hipotez olan, değişken eşik değeri ile elde edilen Harris köşeleri ve en küçük özdeğer özneliği (minimum eigenvalue features; MEF) yöntemiyle elde edilen köşe sayıları değişimlerinin görüntünün ayırt edici bir özelliği olarak kullanabilmesi, elde edilen veriler ile eğitilen yapay sinir ağlarında %70 - %90 aralığında başarımlar elde edilmesi ile ispat edildi. Bununla birlikte, bu yöntemin tek başına, tüm punta kaynak görüntülerinde hedeflenen %90 başarımlar oranını sağlayamadığı da görüldü. Fakat bu yaklaşımın, punta kaynak görüntülerinin sınıflandırılmasında, diğer parametreler ile birlikte kullanımında toplam başarı seviyesini hedeflenen değerin üzerine taşımada etkili olduğu tespit edildi.

Üçüncü hipotez olarak tanımlanan bu durum, karoseri yüzeyinde bazı bölümlerde, bazı yapay sinir ağlarında düşük başarımlı eğitim sonuçları elde edilse de nihai değerlendirmenin, bu bölgelerde elde edilen yüksek başarımlı ağlardan gelen sonuçların doğru şekilde değerlendirilmesi ile %90 olan hedeflenen değere ulaşıp üzerine de çıkılarak ispat edildi. Böylece bir punta kaynak görüntüsünü tek bir parametre grubu ile değil, çoklu analiz ile değerlendirmenin, sistemin başarılı sınıflandırma kabiliyetini arttırdığı gösterildi.



5. SONUÇLAR VE ÖNERİLER

Bu çalışmada geliştirilen sistemin özel uygulama şartları gerektirmeden her tür punta kaynak prosesine ve seri üretim şartlarına uygulanabilmesi, bu çalışmanın en büyük özelliklerinden biridir. Geliştirilen sistem, punta kaynak görüntülerini sınıflandırmada sadece görüntüyü sınıflandıran bir CNN yapısını değil, punta kaynak görüntülerinden elde edilen tanımlayıcı sayısal veriler ile eğitilen yapay sinir ağlarını da kullanmaktadır. Yapılan çalışmalarda, sadece görüntüyü sınıflandıran tek bir CNN uygulamasının süreklilik gösterecek şekilde ve her farklı üretim prosesi ile elde edilen kaynak görüntülerini sınıflandırmada, hedeflenen yüksek başarı oranlarını vermediği, bu yapının mutlaka, bu çalışmada geliştirilen ek yöntemler ile desteklenmesi gerektiği görüldü.

Ayrıca ana görüntünün, YOLO ve Faster R-CNN yöntemleri ile doğrudan işlenmesi ve punta kaynakların tespit edilip sınıflandırılması çalışmaları da yapıldı. Fakat bu çalışmalarda, beklenen yüksek başarımların elde edilemediği görüldü. Yapılan çalışmaların karşılaştırılması, Tablo 5.1’de görülmektedir.

Özellikle, piksel yeğnlik değerlerinin, eğitim aşamasında kullanılan görüntülere göre farklı olduğu fakat aynı sınıfa ait olan görüntülerin sınıflandırılmasında, sınıflandırma başarımlarının %70’ler seviyelerinde kaldığı görüldü. Robotik uygulamalardan elde edilen ve farklı sınıflara ait olmalarına rağmen piksel yeğnlik değerleri açısından birbirlerine benzerlik gösteren punta kaynak görüntülerinin sınıflandırılmasında ise bu algoritmaların, Şekil 4.42’de görüldüğü gibi %68-%70 civarında, görece düşük başarımlar verdiğini ve bazı durumlarda aynı kaynak görüntüsünü farklı sınıflara dahil ettikleri görüldü.

Punta kaynak görüntüsü dışında, görüntünün kendisinden elde edilen tanımlayıcı veriler için yapay sinir ağları ile sınıflandırmanın yanında DVM yöntemi ile sınıflandırma işlemi de uygulandı. DVM’in farklı modellerinin uygulandığı çalışmada, sınıflandırma başarımlarının, yapay sinir ağları ile yapılan uygulamalardaki yüksek başarımlar seviyelerine ulaşmadığı, özellikle sayıca çok veri içeren Harris köşe sayıları, en küçük özdeğer öznitelikleri sayıları ve histogram verilerinin sınıflandırılmasında en yüksek başarımlar seviyesinin Şekil 4.51’de de görüldüğü şekilde %50,0-%51,2 aralığında değiştiği görüldü.

Tablo 5.1. Geliştirilen sistem ile YOLO v5 ve Faster R-CNN uygulamalarının karşılaştırılması

Karoseri Üzerindeki Bölgeler	YOLO v5	Faster R-CNN	Geliştirilen Sistem: Yeniden Düzenlenen AlexNet CNN ve 5 Yapay Sinir Ağı Bileşik Modeli
Cam Alt Flanş	mAP50 = 0,993	Mini-batch Accuracy = %92,3	
	Fakat, uygun kaynak görüntülerinin %40'ının, uygun olmayan kaynak görüntülerinin %20'sinin ve kaynak olmayan görüntülerin de %40'ının arka plan (background) olarak sınıflandırıldığı, ayrıca "uygun olmayan" kaynak görüntülerinin %50'sinin "uygun" olarak sınıflandırıldığı görüldü.	Fakat, "uygun olmayan" sınıfına ait bir görüntü aynı zamanda "uygun" olarak da sınıflandırıldı. Eğitim aşamasında "uygun olmayan" olarak sınıflandırılan görüntülere piksel yeşinlikleri benzer olan görüntüler, test aşamasında "uygun" olarak sınıflandırıldı.	CNN Eğitim başarımlı seviyesi = %91,67 Sistemin sınıflandırma başarımlı = %95,1
Arka Duvar	mAP50 = 0,932	Mini-batch Accuracy = %82,7	
	Fakat, "uygun" kaynak görüntülerinin %9 oranında "uygun olmayan" kaynak olarak tespit edildiği, aynı zamanda arka plan (background) olarak tespit edilen görüntülerin de "uygun olmayan" olarak sınıflandırıldığı görüldü.	"Uygun olmayan" olarak sınıflandırılmış görüntülerdekilere benzer kaynak hatalarını içeren görüntülerin "uygun" olarak sınıflandırıldığı görüldü. En yüksek sınıflandırma başarımlı %70 olduğu tespit edildi.	CNN Eğitim başarımlı seviyesi = %94,25 Sistemin sınıflandırma başarımlı = %98,3
A Sütunu Altı	mAP50 = 0,941	Mini-batch Accuracy = %75,8	
	Fakat, arka plan (background) görüntülerinin %50'sinin "uygun" ve diğer %50'sinin "uygun olmayan" olarak sınıflandırıldığı, ayrıca "uygun olmayan" sınıfına ait görüntülerin %15'inin "uygun" olarak sınıflandırıldığı da görüldü.	"Uygun olmayan" sınıfına ait kaynak görüntüsü "uygun" olarak da sınıflandırıldı. "Uygun" olarak sınıflandırılan kaynak görüntülerine ait başarımlı seviyesi yaklaşık %70 seviyesinde kaldı.	CNN Eğitim başarımlı seviyesi = %100 Sistemin sınıflandırma başarımlı = %94,4
Değerlendirme	1) Aynı kaynak görüntüsünü iki kez sınıflandırdı (%69 ve %27 oranları ile "uygun" olarak). 2) Piksel yeşinlik değeri açısından çok açık şekilde "uygun olmayan" sınıfına ait olan ve benzerleri eğitim aşamasında "uygun olmayan" olarak etiketlenen 2 adet punta kaynak görüntüsünü %73 ve %61 başarımlı oranlarıyla "uygun" olarak sınıflandırdı. 3) Eğitim hazırlık aşamasında ana görüntü içinde punta kaynak alt görüntülerinin seçimi ve bölgelerin belirlenmesi işlemi, bu çalışmada geliştirilen sistemin eğitim sürecine göre çok daha uzun zaman aldı. 4) CNN eğitim süresi, AlexNet üzerinden geliştirilen CNN'e göre daha uzun devam etti; Yolo v5 ile eğitim süresi yaklaşık 45 dakika sürdü. 5) Bu yöntem, ana görüntü üzerinde punta kaynak görüntülerinin tespit edilmesi işlemi içermektedir. Bu aşamada, punta kaynak olmayan ve eğitim aşamasında tanımlanmamış farklı alt görüntü parçaları da tespit edildi.	1) Bazı kaynak görüntülerini hem "uygun" hem "uygun olmayan" sınıflarına dahil etti (Örnek; %69 ile "uygun" sınıfına, %59 ile "uygun olmayan" sınıfına). Bu durum görüntünün hangi sınıfa ait olacağı ile ilgili karar vermede zorluk oluşturdu. 2) Arka plan görüntülerini de "uygun" veya "uygun olmayan" olarak sınıflandırdı. 3) Eğitim hazırlık aşamasında ana görüntü içinde punta kaynak alt görüntülerinin seçimi ve bölgelerin belirlenmesi işlemi, bu çalışmada geliştirilen sistemin eğitim sürecine göre çok daha uzun zaman aldı. 4) CNN eğitim süresi, AlexNet üzerinden geliştirilen CNN'e göre çok daha uzun devam etti. Faster R-CNN ile eğitim süresi yaklaşık 150 dakika sürdü. 5) Ana görüntü üzerinde, punta kaynak olmayan ve eğitim aşamasında tanımlanmamış farklı alt görüntü parçaları da tespit edildi. 6) Araç karoserisi üzerinde bazı bölgelerde sınıflandırma başarımlı %70 seviyelerinde kaldı.	1) Yeniden düzenlenene AlexNet CNN'de sadece CNN'e verilen punta kaynak görüntüleri sınıflandırıldı. Dolayısıyla CNN'de, kaynak görüntüsünün aynı anda iki farklı gruba dahil edilmesi durumu görülmedi. 2) Değerlendirilecek görüntü, önceki süreçlerde hazırlanarak yeniden düzenlenmiş AlexNet CNN'e verildi. Hazırlık aşaması ön süreçlerde yapıldığı için ana görüntü üzerinde bölge belirleme süreçlerine gerek olmadı, doğrudan eğitime geçildi. 3) Eğitim süresi, YOLO V5 ve Faster R-CNN'e göre çok kısadır. Ön sınıflandırma sonrasında tüm sistemin eğitim işlemi, örnekleme yapılan karoseri bölgesine göre ortalama 10 dakikada tamamlandı. Uygun sonuç vermeyen eğitim süreçleri hızlıca tekrarlanabilir. 4) CNN başarımlı seviyesi, punta kaynakların manuel üretildiği alanlarda dahi %90 seviyesinde elde edildi. 5) CNN sonuçları, punta kaynak görüntülerinin istatistiksel verilerine ek olarak Harris köşe sayıları değişimleri ve görüntünün özdeğer sayıları değişimleri ile eğitilen sinir ağıları verileri ile desteklendi. Bu şekilde oluşturulan sistem ile hedeflenen yüksek başarımlı seviyeleri elde edildi.
Sonuç	Punta kaynak görüntülerinin sınıflandırılması amacıyla sadece YOLO v5 kullanımının uygun olmadığı görüldü.	Punta kaynak görüntülerinin sınıflandırılması amacıyla sadece Faster R-CNN kullanımının uygun olmadığı görüldü.	Punta kaynak görüntülerinin sınıflandırılması amacıyla sadece AlexNet benzeri bir CNN kullanımının, hedeflenen yüksek başarımlı seviyesinin elde edilmesinde yeterli olmadığı görüldü. Uygulamanın, farklı yöntemler ile desteklenmesi, punta kaynakların sınıflandırılmasında yüksek doğruluk oranlarına erişmeyi sağladı.

Bu sonuçlar altında, punta kaynak görüntülerinin sınıflandırılması amacıyla tek başlarına YOLO v5 veya Faster R-CNN yöntemlerinin kullanılmasının uygun olmadığı tespit edildi. Punta kaynak görüntülerinin kendilerinin bir evrimsel yapay sinir ağı kullanılarak sınıflandırılması işleminin, görüntünün sınıflandırma başarımında YOLO v5'e ve Faster R-CNN'e göre daha yüksek başarımlar elde edilmesini sağladığı görüldü. Bununla birlikte, tek başına evrimsel yapay sinir ağı ile görüntü sınıflandırmanın da seri üretim şartlarında karşılaşılan punta kaynak görüntülerini sınıflandırmada en az %95 doğru sınıflandırma seviyesi gibi bir hedefe ulaşmada yeterli olmadığı belirlendi. Evrimsel yapay sinir ağı ile görüntü sınıflandırma sürecini farklı yöntemler ile desteklemek ve başarımlar oranını yükseltmek amacıyla, punta kaynak görüntülerine ait istatistiksel belirleyici verilerin yanında, bu çalışmada önerilen hipotez olan punta kaynak görüntüsü Harris köşe sayılarının ve görüntü özdeğer sayılarının değişimlerinin görüntüye ait bir belirleyici veri olması ve bunların kullanımıyla sınıflandırma başarımının artırılması üzerinde çalışıldı.

Bu çalışmada, ana görüntüden punta kaynak alt görüntülerinin elde edilmesi işlemi Hough dönüşümü uygulanarak gerçekleştirildi ve her bir punta kaynak için ayrı görüntü elde edildi. Bu görüntüler uyumlandırılmış AlexNet'in, 70×70 piksel olan punta kaynak görüntüsüne uyumlandırılması ile elde edilen CNN ağına girdi olarak verildi ve sınıflandırma sonucu, punta kaynak görüntülerinden elde edilen istatistiksel tanımlayıcı verilerin yanında yine punta kaynak görüntülerinden elde edilen Harris köşe sayılarının değişimi ve en küçük özdeğer öznitelikleri sayılarının değişimi veri kümeleri ile eğitilen yapay sinir ağları ile desteklendi. Böylece bir punta kaynağının sınıflandırılması işlemi hem doğrudan kendi görüntüsü üzerinden yapıldı hem de biri CNN olan bir derin yapay sinir ağı olmak üzere toplam 6 adet yapay sinir ağından elde edilen sonuçlar ile gerçekleştirildi. Punta kaynağının sınıfına ait nihai sonucun elde edilmesi işlemi ise sürekli alınan yüzey görüntüsünün son 5 değerlendirme sonucunda ağırlıklı olarak elde edilen sonucun alınması yöntemiyle yapıldı. Sonuçlar kullanıcıya yüzeyden alınan ana görüntü üzerinde, punta kaynak alt görüntülerinin üzerine yerleştirilen ve kaynağın sınıfına göre farklı renk içeren daireler ile görselleştirildi ve kullanıcının kaynak sınıfını görsel olarak fark edebilmesi de sağlandı. Tüm bu algoritma ile çeşitli seri üretim şartlarına kolaylıkla uyumlandırılabilen ve kolay kullanımlı bir sistem elde edildi.

Bu sistem kullanılarak, kabin arka duvar alt bölümdeki punta kaynakların sınıflandırılmasında başarımları oranı %90,6 ile %98,3 arasında, F1 puanları 0,92 ile 0,98 arasında tespit edildi. Cam alt flanş bölgesindeki punta kaynakların sınıflandırılmasında başarımları oranı %93,6 ile %95,1 arasında, F1 puanları 0,80 ile 0,97 arasında tespit edildi. A direği altında bulunan kaynakların sınıflandırılmasında ise başarımları oranı %94,4 ve F1 puanı 0,97 ile 1,00 arasında tespit edildi.

Bu çalışmada, robotik prosesler ile üretilen punta kaynakların sınıflandırılmasında, bir çalışanın kullandığı punta kaynak makinesi ile üretilen kaynakların sınıflandırılmasına göre daha yüksek başarımları seviyeleri elde edildi. Kabin arka duvar alt bölümü ile A sütunu altındaki bölümde bulunan kaynakların sınıflandırılmasında yüksek başarımları elde edilmesinin temel nedeninin bu olduğu, bu bölgelerdeki punta kaynakların ve buna bağlı olarak punta kaynak görüntülerinin, el ile üretilen kaynaklara göre daha az piksel yağınlik değeri değışkenliği gösterdiği görüldü.

Tüm çalışmalarda olduğu gibi gereken tek şart, kameranın sabit kalması, görüntü alımı sırasında titrememesi ve görüntünün bulanık olmaması gerektiği tespit edildi. Ayrıca, alınan görüntüler, sistemin uygulandığı kabin yüzeyi alanında görece küçük bir alanı içerdığı ve uygulamanın devamı için kameranın hareket ettirilmesi gerekliliği nedeniyle, uygulamanın mevcut durumunda kameranın ve sistemin kullanımı için bir çalışanın gerekliliği görüldü.

Ancak bu gereklilik, işbirlikçi (collaborative) robot kullanılmasıyla ortadan kaldırılabilir. Seri üretim şartlarında, kayan bant yöntemiyle çalışan bir işletmede, araç karoserisinin belirlenen bir istasyonda bir takt süresi boyunca sabitlenmesini takiben aktive edilecek bir işbirlikçi robot, üzerine monte edilmiş bir kamera yardımıyla, geliştirilen bu sistemin yönlendirmesiyle, gereken görüntüleri alabilir, bu görüntüler analiz edilip sınıflandırılır ve punta kaynak sınıflandırma sonuçları, geliştirilen bu sistemde de olduğu gibi, gerçek zamanlı olarak bir ekranda kullanıcıya gösterilebilir.

İşbirlikçi (collaborative) robot ve bu çalışmada geliştirilen sistemin birlikte kullanımıyla, seri üretim şartlarında ürünlerdeki tüm punta kaynakların tespiti ve analiz edilerek sınıflandırılması süreci dakikalar ile ölçülecek düzeyde, görece kısa bir sürede ve etkili şekilde tamamlanabilir. Bu da sistemin seri üretimde kullanılmasını kolaylaştıracaktır.

Tüm bunların yanında, endüstriyel üretimin dijitalleşmesi ve endüstri 4.0 yolunda ilerlemek amacıyla yapılan çalışmalara bir katkı olarak, punta kaynak kalitesi gerçek zamanlı izlenebilecek, olası bir uygunsuzluk durumunda uygun olmayan ürünün üretimi hemen durdurulabilecek ve uygun olmayan punta kaynaklar hemen fark edilerek gerekli önlemler alınabilecektir. Geliştirilen sistemin, işletmedeki diğer makine ve sistemler ile iletişim kurabilmesi, çalışan müdahalesini en aza indirecek ve üretim yönetim sistemine de çok önemli bir destekleyici katkı sağlayacaktır.

Geliştirme potansiyeli olarak görülen bir husus ise sistemin, nihai sonucu oluşturma aşamasında verileri bir veri bankasına değil, -ki burada Microsoft Excel veya SQL gibi ortamlar kullanılabilir- doğrudan hafıza bilgisayar RAM bellekte tutulmasıdır. Bu değişim, sistemin çalışma hızını yükseltecektir. Ancak SQL gibi bir veri tabanı kullanılması sayesinde de geçmiş veriler erişilebilir olacağından, çeşitli istatistiksel analizlerin yapılması mümkün olacaktır.

Bir diğer geliştirme potansiyeli de sistemin kullanımı sırasında farklı yüzeyler arasındaki geçişlerin yapılması aşamasıdır. Mevcut durumda yüzey bölgelerinin seçimi, çalışan tarafından menüden seçim yapılması ile mümkündür. Ancak her yüzey için bir bar kod oluşturulması ve kameranın bu kodu görerek sistemin işleme başlayacağı yüzeyi otomatik seçmesi sağlanabilir. Ayrıca, gelecekte kameranın pozisyonlanması için robot kol kullanılması durumunda, robotun üç boyutlu uzaydaki hareketleri önceden programlı olacağı için kolun belirli pozisyonlardaki hareketi sayesinde üzerinde işlem yapılacak yüzey otomatik olarak seçilebilir.

Sistemde kullanılan yöntemlerin seçilebilir olması ve belirli yüzeylerde yüksek başarı elde edilemeyen yapay sinir ağlarının seçilerek işlem dışı bırakılabilme kabiliyeti eklenmesi, sistemin bir diğer geliştirme potansiyelidir. Böylece yüksek başarı elde edilememiş yapay sinir ağlarının nihai sonuç hesaplarında işlem dışı bırakılması ve işlem yükünün azaltılması mümkün hale gelecektir.

KAYNAKLAR

- Alghannam, E., Lu, H., Ma, M., Cheng, Q., Gonzalez, A. A., Zang, Y., Li, S. (2019). A novel method of using vision system and fuzzy logic for quality estimation of resistance spot welding. *Symmetry*, 11(8). <https://doi.org/10.3390/sym11080990>
- Ballard, D. H. (1981). Generalizing The Hough Transform To Detect Arbitrary Shapes. *Pattern Recognition*, 13(2), 111-122.
- Bayır, M., Yücel, E., Kaya, T., Yıldırım, N. (2023). Spot Welding Parameter Tuning for Weld Defect Prevention in Automotive Production Lines: An ML-Based Approach. *Information*, 14(50). <https://doi.org/10.3390/info14010050>
- Breitenbach, J., Dauser, T., Illenberger, H., Traub M., Buettner, R. (2021). A Systematic Literature Review On Machine Learning Approaches For Quality Monitoring And Control Systems For Welding Processes. *IEEE International Conference on Big Data*, Orlando, Florida, ABD, 2019-2025.
- Chang, F., Zhou, G., Ding, K., Li, J., Jing, Y., Hui, J., Zhang, C. (2023). A CNN-LSTM and Attention-Mechanism-Based Resistance Spot Welding Quality Online Detection Method for Automotive Bodies. *Mathematics*, 11(22), 4570. <https://doi.org/10.3390/math11224570>
- Cho, Y., Rhee, S. (2004). Quality Estimation of Resistance Spot Welding by Using Pattern Recognition With Neural Networks. *IEEE Transactions on Instrumentation and Measurement*, 53(2), 330–334. <https://doi.org/10.1109/TIM.2003.822713>
- Choi, S. G., Hwang, I., Kim, Y. M., Kang, B., Kang, M. (2019). Prediction Of The Weld Qualities Using Surface Appearance Image In Resistance Spot Welding. *Metals*, 9(8). <https://doi.org/10.3390/met9080831>
- Ciganek, L. (1940). Resistance Of The Spot Weld. *Electrical Engineering*, 59(12), 997-1001. DOI: 10.1109/EE.1940.6435272.
- Dalal, N., Triggs, B. (2005). Histograms Of Oriented Gradients For Human Detection, *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, San Diego, Kaliforniya, ABD, 20-25 Haziran 2005.
- Dilthey, U., Dickersbach, J. (1999). Application Of Neural Networks For Quality Evaluation Of Resistance Spot Welds. *ISIJ International*, 39(10), 1061-1066.
- Dong, J., Hu, J., Luo, Z. (2023). Quality Monitoring Of Resistance Spot Welding Based On A Digital Twin. *Metals*, 13(4). <https://doi.org/10.3390/met13040697>
- El-Sari, B., Biegler, M., Rethmeier, M. (2021). Investigation Of The Extrapolation Capability Of An Artificial Neural Network Algorithm In Combination With Process Signals In Resistance Spot Welding Of Advanced High-Strength Steels. *Metals*, 11(11). <https://doi.org/10.3390/met11111874>

- Fu, Y., Gao, P., Gao, X., Zhang, Y. (2024). Quality Evaluation Of Resistance Spot Welding Based On Dynamic Reactance Signal And Rader Diagram Method. *IEEE Sensors Journal*, 6666-6676.
- Geng, C., Buyun, S., Gaocai, F., Xiangxiang, C., & Guangde, Z. (2024). A GAN-Based Method For Diagnosing Bodywork Spot Welding Defects In Response To Small Sample Condition. *Applied Soft Computing*, 157. <https://doi.org/10.1016/j.asoc.2024.111544>
- Girshick R., Donahue J., Darrell T., Malik J. (2014). Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation. *IEEE Conference on Computer Vision and Pattern Recognition*, Columbus, Ohio, ABD, 2014, 580-587. DOI: 10.1109/CVPR.2014.81.
- Girshick, R. (2015). Fast R-CNN. *IEEE International Conference on Computer Vision (ICCV)*, Santiago, Şili, 2015, 1440-1448. DOI: 10.1109/ICCV.2015.169.
- Guo, D., Du, W., Peng, H., Zhao, C., Wang, P., Chen, X., (2021). Research On Prognostics Technology Of Spot-Welding System In Automotive Manufacturing Based On Statistical Process Control. *China Automation Congress (CAC)*, Pekin, Çin, 2021, 4025-4029.
- Guo, Zhiye & Ye, Shaofeng & Wang, Yiju & Lin, Chun. (2017). Resistance Welding Spot Defect Detection with Convolutional Neural Networks. *11th International Conference, ICVS 2017*, Şenzen, Çin, 10-13 Temmuz 2017, 169-174.
- Halim, S. A., Manurung, Y. H. P., Raziq, M. A., Low, C. Y., Rohmad, M. S., Dizon, J. R. C., Kachinskyi, V. S. (2023). Quality Prediction And Classification Of Resistance Spot Weld Using Artificial Neural Network With Open-Sourced, Self-Executable And GUI-Based Application Tool Q-Check. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-29906-0>
- Harris C., Stephens M., A Combined Corner Edge Detector, *Proceedings of the 4th Alvey Vision Conference*, 1988, 147-151.
- He, Y., Yang, K., Wang, X., Huang, H., Chen, J. (2022). Quality Prediction And Parameter Optimisation Of Resistance Spot Welding Using Machine Learning. *Applied Sciences*, Basel, İsviçre. <https://doi.org/10.3390/app12199625>
- Hornor, H. A. (1918). Electric Welding - A New Industry. *Proceedings of the American Institute of Electrical Engineers*, 37(10), 1185-1195.
- Hu, J., Bi, J., Liu, H., Li, Y., Ao, S., Luo, Z. (2022). Prediction of Resistance Spot Welding Quality Based on BPNN Optimized by Improved Sparrow Search Algorithm. *Materials*, 15(20). <https://doi.org/10.3390/ma15207323>

- Hwang, I., Yun, H., Yoon, J., Kang, M., Kim, D., Kim Y. M., (2018). Prediction of Resistance Spot Weld Quality Of 780 MPa Grade Steel Using Adaptive Resonance Theory Artificial Neural Networks. *Metals*, 8(6), 453.
- Junno, H., Laurinen, P., Haapalainen, E., Tuovinen, L., Roning, J. (2005). Resistance Spot Welding Process Identification Using An Extended k-NN Method. *Proceedings of the IEEE International Symposium on Industrial Electronics, ISIE 2005*. Dubrovnik, Hırvatistan, 7-12, DOI: 10.1109/ISIE.2005.1528880.
- Karloff, A. C., Chertov, A. M., Maev, R. G., (2009). Enhancing Real-Time Ultrasound Signatures Of Molten Nugget Growth For Quality Evaluation Of Resistance Spot Welds. *IEEE International Ultrasonics Symposium*, Roma, İtalya, 1533-1536.
- Kastner, L., Ahmadi, S., Jonietz, F., Jung, P., Caire, G., Ziegler, M., Lambrecht, J., (2021). Classification Of Spot-Welded Joints In Laser Thermography Data Using Convolutional Neural Networks. *IEEE Access*, 9, 48303-48312.
- Kim, S., Hwang, I., Kim, D. Y., Kim, Y. M., Kang, M., Yu, J. (2021). Weld-quality prediction algorithm based on multiple models using process signals in resistance spot welding. *Metals*, 11(9). <https://doi.org/10.3390/met11091459>
- Krizhevsky, A., Sutskever I., Hinton G. E., ImageNet Classification with Deep Convolutional Neural Networks, *Proceedings of the 25th International Conference on Neural Information Processing Systems*, 2012, 1097-1105.
- Lee, S. R., Choo, Y. J., Lee, T. Y., Han, C. W., Kim, M. H., (2000). Neuro-Fuzzy Algorithm For Quality Assurance Of Resistance Spot Welding. *IEEE Industry Applications Conference. Thirty-Fifth IAS Annual Meeting and World Conference on Industrial Applications of Electrical Energy*, 2, Roma, İtalya, 1210-1216.
- Lowe, D. G., (2004). Distinctive Image Features from Scale-Invariant Keypoints. *International Journal of Computer Vision*, 60, 91-110.
- Lin, Z., Zhang, Y., Chen, G., Li, Y. (2004). Study On Real-Time Measurement of Nugget Diameter For Resistance Spot Welding Using A Neuro-Fuzzy Algorithm. *21st IEEE Instrumentation and Measurement Technology Conference*, Komo, İtalya, 2004, 2230-2233, DOI: 10.1109/IMTC.2004.1351535.
- Lin, J., Lu, J., Xu, J., Li, D. (2021). Welding Quality Analysis and Prediction Based on Deep Learning. *4th World Conference on Mechanical Engineering and Intelligent Manufacturing (WCMEIM)*, Şangay, Çin, 173-177. DOI: 10.1109/WCMEIM54377.2021.00045.
- Peng, S., (2021). A GBDT Based Quality Prediction Method For The Resistance Spot Welding. *International Conference on Security, Pattern Analysis, and Cybernetics*, Çengdu, Çin, 451-455.

- Piriyabunjerd, W., Janya-Anurak, C. (2021). Classification of the Resistance Spot Weld Failure Mode Using Convolutional Neural Network. *2nd International Symposium on Instrumentation, Control, Artificial Intelligence, and Robotics, ICA-SYMP 2021*. <https://doi.org/10.1109/ICA-SYMP50206.2021.9358428>
- Redmon J., Divvala S., Girshick R. ve Farhadi A., (2016). You Only Look Once: Unified, Real-Time Object Detection, *IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, ABD, 2016, 779-788. DOI: 10.1109/CVPR.2016.91.
- Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39. DOI: 10.1109/TPAMI.2016.2577031.
- Ruisz, J., Biber, J., Loipetsberger, M., (2007). Quality Evaluation In Resistance Spot Welding By Analysing The Weld Fingerprint On Metal Bands By Computer Vision. *International Journal of Advanced Manufacturing Technology*, 33. DOI: 952-960. 10.1007/s00170-006-0522-6.
- Shao, J., Yan, Y. (2006). Automated Inspection of Micro Laser Spot Weld Quality Using Optical Sensing and Neural Network Techniques. *IEEE Instrumentation and Measurement Technology Conference Proceedings*, Sorrento, İtalya, 2006, 606-610. DOI: 10.1109/IMTC.2006.328632.
- Shi, J., Tomasi, C. (1994). Good Features To Track. *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, Seattle, ABD, 1994, 593-600. DOI: 10.1109/CVPR.1994.323794.
- Sobel, I. (1970). Camera Models And Machine Perception, Doktora Tezi, Stanford Üniversitesi, Kaliforniya, ABD.
- Ulbrich, D., Psuj, G., Wypych, A., Bartkowski, D., Bartkowska, A., Stachowiak, A., Kowalczyk, J., (2023). Inspection Of Spot Welded Joints With The Use Of The Ultrasonic Surface Wave. *Materials*. 16(21), 7029.
- Veitía, B. D. R., Hernández, A. E., Villarinho, L. O., Orozco, M. S., Roca, A. S., Fals, H. C., Macias, E. J. (2020). Deep Learning For Quality Prediction In Dissimilar Spot Welding DP600-AISI304, Using A Convolutional Neural Network And Infrared Image Processing. *32nd European Modeling and Simulation Symposium*, Kasım 2020, 393–399. <https://doi.org/10.46354/i3m.2020.emss.057>
- Wang, W., (2024). Research On Optimization Of Welding Process Parameters Of Cast Aluminum Based On Feature Extraction. *Asia-Pacific Conference on Software Engineering, Social Network Analysis and Intelligent Computing*, Yeni Delhi, Hindistan, 2024, 677-680. DOI: 10.1109/SSAIC61213.2024.00138.
- Xi Z., Zhou J., Yang B., Zhang Y., Zhang Z., Li D., (2024). An Intelligent Inspection Method For Body-In-White Weld Quality Based On Vibration Excitation Response Signals. *Measurement*, 229. <https://doi.org/10.1016/j.measurement.2024.114482>.

- Xinmin, L., Xiaoyun, Z., Yansong, Z., Guanlong, C., (2007). Weld Quality Inspection Based On Online Measured Indentation From Servo Encoder In Resistance Spot Welding. *IEEE Transactions on Instrumentation and Measurement*, 56(4), 1501-1505.
- Younes, D., Alghannam, E., Tan, Y., Lu, H. (2020). Enhancement In Quality Estimation Of Resistance Spot Welding Using Vision System And Fuzzy Support Vector Machine. *Symmetry*, 12(8). <https://doi.org/10.3390/SYM12081380>
- Zhanfeng, H., Wu, P., Jing, X., Jingyu, H., (2010). Application Of Fractal Theory In Examination Of Resistance Spot Welding Quality. *International Conference on Advanced Technology of Design and Manufacture*, Pekin, Çin, 2010, 422-424, DOI: 10.1049/cp.2010.1336.



KİŞİSEL YAYIN VE ESERLER

- Dinçer H., **Otmanbölük, H.** (1996). Genel Amaçlı İki Boyutlu Yüzey Modelleme Ve Yüzeyin Backpropagation Yapay Sinir Ağı İle Benzetimi. 4. *Bilgisayar-Haberleşme Sempozyumu*. Bursa, Türkiye, 11-15 Aralık 1996.
- Otmanbölük, H.**, Dinçer, H. (1997). Bulanık Mantık Kontrollü Yaklaşım Alarmı. *Savunma Sanayiindeki Teknolojik Gelişmeler Sempozyumu*. Kara Harp Okulu, Ankara, Türkiye, 5-6 Haziran 1997.
- Otmanbölük, H.**, Ertürk, S., (2024). A Different Approach To Determining The Quality Level Of Electrical Resistance Spot Welds In The Industrial Serial Production. *International Congress on Human-Computer Interaction, Optimization and Robotic Applications (ICHORA)*, İstanbul, Türkiye.
- Otmanbölük, H.**, Nalçacı, C. (1996). Bilgisayar Kontrollü DCS Sistem Tasarımı. 9. *Mühendislik Sempozyumu*. Süleyman Demirel Üniversitesi, Isparta, Türkiye, 23-25 Eylül 1996.

ÖZGEÇMİŞ

İlk, orta ve lise öğrenimini İzmir’de tamamladı. 1989 yılında girdiği Yıldız Üniversitesi Kocaeli Mühendislik Fakültesi Elektronik ve Haberleşme Mühendisliği Bölümü’nden 1994 yılında Elektronik ve Haberleşme Mühendisi olarak mezun oldu. Aynı yıl, 1992 yılında Kocaeli Üniversitesi olan okulunda, Fen Bilimleri Enstitüsü’nde Elektronik ve Haberleşme Mühendisliği Anabilim Dalı’nda yüksek lisans eğitime başladı ve 1997 yılında eğitimini tamamladı. 1995 – 1996 yılları arasında Kocaeli Üniversitesi Fen Bilimleri Enstitüsü’nde Araştırma Görevlisi, 1996 – 1998 yılları arasında ise Kocaeli Üniversitesi Elektronik ve Haberleşme Sistemleri Araştırma ve Uygulama Merkezi’nde (EHSAM) Araştırma Görevlisi olarak çalıştı. 1998 yılında özel sektörde çalışmaya başladı. 2001 yılından beri, Aksaray ilinde bulunan Mercedes-Benz Türk A. Ş. Aksaray Kamyon Fabrikası’nda çalışmaktadır.

