



**ELEKTRONİK DEVRE ELEMANLARININ
EVRIŞİMLİ SINIR AĞI İLE SINIFLANDIRILMASI
VE FARKLI GÜRÜLTÜ SEVİYELERİNDE
PERFORMANS ANALİZİ**

**2024
YÜKSEK LİSANS TEZİ
MEKATRONİK MÜHENDİSLİĞİ**

Kadir AHMED DJAMA

**Tez Danışmanı
Dr. Öğr. Üyesi Şafak ALTAY AÇAR**

**ELEKTRONİK DEVRE ELEMANLARININ EVRİŞİMLİ SINIR AĞI İLE
SINIFLANDIRILMASI VE FARKLI GÜRÜLTÜ SEVİYELERİNDE
PERFORMANS ANALİZİ**

Kadir AHMED DJAMA

Tez Danışmanı

Dr. Öğr. Üyesi Şafak ALTAY AÇAR

T.C.

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Mekatronik Mühendisliği Anabilim Dalında

Yüksek Lisans Tezi

Olarak Hazırlanmıştır

KARABÜK

Ocak 2024

Kadir AHMED DJAMA tarafından hazırlanan “ELEKTRONİK DEVRE ELEMANLARININ EVRİŞİMLİ SİNİR AĞI İLE SINIFLANDIRILMASI VE FARKLI GÜRÜLTÜ SEVİYELERİNDE PERFORMANS ANALİZİ” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Dr. Öğr. Üyesi Şafak ALTAY AÇAR
Tez Danışmanı, Mekatronik Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Mekatronik Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 18/01/2024

Ünvanı, Adı SOYADI (Kurumu) İmzası

Başkan : Doç. Dr. Aytaç ALTAN (BEÜ)

Üye : Dr. Öğr. Üyesi Şafak ALTAY AÇAR (KBÜ)

Üye : Dr. Öğr. Üyesi Batıkan Erdem DEMİR (KBÜ)

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Yüksek Lisans derecesini onamıştır.

Doç. Dr. Zeynep ÖZCAN
Lisansüstü Eğitim Enstitüsü Müdürü

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

Kadir AHMED DJAMA

ÖZET

Yüksek Lisans Tezi

ELEKTRONİK DEVRE ELEMANLARININ EVRİŞİMLİ SINIR AĞI İLE SINIFLANDIRILMASI VE FARKLI GÜRÜLTÜ SEVİYELERİNDE PERFORMANS ANALİZİ

Kadir AHMED DJAMA

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Mekatronik Mühendisliği Anabilim Dalı

Tez Danışmanı:

Dr. Öğr. Üyesi Şafak ALTAY AÇAR

Ocak 2024, 52 sayfa

Bu tez çalışmasında yedi farklı elektronik devre elemanı sınıflandırılmıştır. Sınıflandırma işlemi hem orjinal elektronik devre elemanı görüntülerine hemde yapay olarak farklı seviyelerde Gauss gürültüsü eklenmiş elektronik devre elemanı görüntülerine uygulanmıştır. Kullanılan veri seti iki farklı elektronik devre elemanı veri seti birleştirilerek oluşturulmuştur. Veri setinde direnç, diyot, entegre, jumper, kondansatör, LED ve transistör görüntüleri bulunmaktadır. Sınıflandırıcı olarak bir evrişimli sinir ağı (ESA) tasarlanmıştır. Bu ağda üç adet evrişim, üç adet maksimum havuzlama ve bir tanesi çıkış olarak kullanılan iki adet tam bağlantı katmanı bulunmaktadır. Orjinal görüntülerin sınıflandırma işlemi sonucunda eğitim doğruluğu 0.9929, doğrulama doğruluğu 0.9226 ve test doğruluğu 0.9139 olarak elde edilmiştir. Gürültülü görüntülerden elde edilen değerler ise bu değerlerden bir miktar düşüktür. Elde edilen değerler gürültü seviyesinin etkisi göz önünde bulundurularak

değerlendirilmiştir. Ayrıca tasarlanan ESA veri setindeki orjinal görüntüler kullanılarak diğer modeller ile karşılaştırılmıştır. Karşılaştırma işlemi sonucunda tasarlanan ESA'nın diğer modellere göre en yüksek doğrulama ve test doğruluk değerlerine sahip olduğu görülmüştür. Web kamerası ile çekilen toplam yirmi adet direnç, entegre ve kondansatör görüntüleri tasarlanan ESA ile ayrı ayrı sınıflandırılmıştır. Sınıflandırma hem orjinal hemde gürültülü görüntülere veri setindeki orjinal görüntüler ile eğitilen ESA ile yapılmıştır. Orjinal görüntülerde %90 başarı oranı elde edilmiştir. Gürültülü görüntülerde ise gürültü seviyelerine göre %90, %75, %70 ve %75 başarı oranları elde edilmiştir.

Anahtar Sözcükler : Elektronik Devre Elemanı, Gauss Gürültüsü, Evrişimli Sinir Ağı, Sınıflandırma.

Bilim Kodu : 92906

ABSTRACT

M. Sc. Thesis

CLASSIFICATION OF ELECTRONIC CIRCUIT COMPONENTS WITH CONVOLUTIONAL NEURAL NETWORK AND PERFORMANCE ANALYSIS AT DIFFERENT NOISE LEVELS

Kadir AHMED DJAMA

Karabük University

Institute of Graduate Programs

Department of Mechatronics Engineering

Thesis Advisor:

Assist. Prof. Dr. Şafak ALTAY AÇAR

January 2024, 52 pages

In this thesis study, seven different electronic circuit components were classified. The classification process was applied to both original electronic circuit component images and electronic circuit component images with artificially added Gaussian noise at different levels. The data set used was created by combining two different electronic circuit component data sets. The data set includes resistor, diode, integrated circuit, jumper, capacitor, LED and transistor images. A convolutional neural network (CNN) was designed as a classifier. This network has three convolution layers, three maximum pooling layers, and two full connection layers, one of which is used as output. As a result of the classification process of the original images, the training accuracy was 0.9929, the validation accuracy was 0.9226 and the test accuracy was 0.9139. The values obtained from noisy images are slightly lower than these values. The obtained values were evaluated taking into account the effect of noise level. Also,

the designed CNN was compared with other models using the original images in the data set. As a result of the comparison process, it was seen that the designed CNN had the highest validation and test accuracy values compared to other models. Total of twenty resistor, integrated circuit and capacitor images taken with the webcam were classified separately by the designed CNN. Classification was done on both original and noisy images with CNN trained with the original images in the data set. 90% success rate was achieved on original images. In noisy images, success rates of 90%, 75%, 70% and 75% were achieved depending on the noise levels.

Key Word : Electronic Circuit Component, Gaussian Noise, Convolutional Neural Network, Classification.

Science Code : 92906

TEŞEKKÜR

Bu tez çalışmasının planlanması, araştırılması, yürütülmesi ve sonuçlandırılmasında ilgi ve desteğini esirgemeyen, tez çalışmamın başarılı bir şekilde tamamlanmasına katkıda bulunan herkese içten teşekkürlerimi sunarım. Bu yolculuk boyunca, beni destekleyen, rehberlik eden ve motive eden birçok değerli insan ve kurum oldu. Sizlerin desteği, bu başarıya ulaşmamı sağladı.

İlk olarak, sayın hocam Dr. Öğretim Üyesi Şafak Altay Açar'a özel bir teşekkür sunmak istiyorum. Sizin bilgeliğiniz, sabrınız ve samimiyetiniz, tez çalışmamın her aşamasında yol gösterici oldu. Sizinle çalışmak büyük bir onurdu ve sizin rehberliğiniz sayesinde kişisel ve akademik olarak büyüdüm.

Ayrıca, aileme, babam Ahmed Djama ve annem Tousmo Abdi'ye özel bir minnettarlık ifade etmek istiyorum. Sizlerin sevgi dolu destekleri, benim için her zaman en büyük motivasyon kaynağı oldu. Sizlerin manevi desteği olmadan bu zorlu süreci başarıyla tamamlamak mümkün olmazdı.

Son olarak, Karabük Üniversitesi'ne olan teşekkürlerimi sunmak istiyorum. Bu üniversite, beni sadece akademik olarak değil, aynı zamanda kişisel olarak da geliştirmeme olanak sağladı. Bu kurumun öğretim üyeleri, arkadaşlarım ve öğrenci topluluğuyla geçirdiğim zamanlar, hayatımın en değerli deneyimlerindendi.

Tüm bu kişilere ve kurumlara olan minnettarlığımı ifade etmek için yeterli kelimeler bulmak zor olsa da, sizin desteğiniz ve rehberliğiniz olmadan bu başarıya ulaşamazdım. Her birinize teşekkür ederim ve gelecekteki projelerimde de sizlerle çalışmayı dört gözle bekliyorum. Tüm kalbimle teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ	xiii
SİMGELER VE KISALTMALAR DİZİNİ	xiv
BÖLÜM 1	1
GİRİŞ	1
BÖLÜM 2	3
LİTERATÜR ARAŞTIRMASI	3
BÖLÜM 3	7
DERİN ÖĞRENME.....	7
3.1. MAKİNE ÖĞRENİMİ	8
3.2. YAPAY SİNİR AĞLARI.....	10
3.3. EVRİŞİMLİ SİNİR AĞI	12
3.3.1. Evrişim Katmanı	14
3.3.2. Havuzlama Katmanı	14
3.3.2.1. Maksimum Havuzlama	15
3.3.2.2. Ortalama Havuzlama	17
3.3.3. Düzleştirme Katmanı	18
3.3.4. Tam Bağlantı Katmanı.....	19
3.3.5. Aktivasyon Fonksiyonları.....	20
3.3.5.1. Sigmoid Fonksiyonu	20
3.3.5.2. Tanh Fonksiyonu	22

	<u>Sayfa</u>
3.3.5.3. ReLU Fonksiyonu	23
3.3.5.4. Softmax Fonksiyonu	24
3.4. EVRİŞİMLİ SİNİR AĞI MODELLERİ	25
3.4.1. LeNet-5	25
3.4.2. AlexNet.....	26
3.4.3. VGGNet.....	26
BÖLÜM 4	28
MATERYAL VE METOD	28
4.1. KULLANILAN VERİ SETİ	28
4.2. TASARLANAN EVRİŞİMLİ SİNİR AĞI	33
4.3. GAUSS GÜRÜLTÜSÜ VE VERİ SETİNDEKİ GÖRÜNTÜLERE GÜRÜLTÜ EKLENMESİ	33
4.4. KULLANILAN WEB KAMERA.....	35
BÖLÜM 5	37
DENEYSEL ÇALIŞMALAR	37
5.1. ORJİNAL VE GÜRÜLTÜLÜ ELEKTRONİK DEVRE ELEMANLARI GÖRÜNTÜLERİNİN SINIFLANDIRILMASI	37
5.2. TASARLANAN EVRİŞİMLİ SİNİR AĞININ DİĞER MODELLER İLE KARŞILAŞTIRILMASI	40
5.3. WEB KAMERASINDAN ELDE EDİLEN ELEKTRONİK DEVRE ELEMANLARI GÖRÜNTÜLERİNİN SINIFLANDIRILMASI	41
BÖLÜM 6	44
SONUÇLAR VE DEĞERLENDİRME	44
KAYNAKLAR	46
ÖZGEÇMİŞ	52

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 3.1. Derin sinir ağı	8
Şekil 3.2. Makine öğrenimi ve derin öğrenme	9
Şekil 3.3. Yapay sinir ağı modeli	11
Şekil 3.4. Evrişimli sinir ağı modeli.....	13
Şekil 3.5. Evrişim katmanı	14
Şekil 3.6. Havuzlama katmanı.	15
Şekil 3.7. Maksimum havuzlama.	16
Şekil 3.8. Ortalama havuzlama.	17
Şekil 3.9. Düzleştirme katmanı.	18
Şekil 3.10. Tam bağlantı katmanı	20
Şekil 3.11. Sigmoid fonksiyonu	21
Şekil 3.12. Tanh fonksiyonu	22
Şekil 3.13. ReLU fonksiyonu.....	23
Şekil 3.14. LeNet-5'in mimarisi	25
Şekil 3.15. AlexNet'in mimarisi	26
Şekil 3.16. VGG-11'in mimarisi.....	27
Şekil 3.17. VGG-16'nın mimarisi.....	27
Şekil 4.1. İlk veri setindeki elektronik devre elemanlarının örnek görüntüleri a) direnç, b) diyot, c) entegre, d) jumper, e) kondansatör, f) LED, g) transistör.	29
Şekil 4.2. Kullanılan yedi farklı arka plan a) beyaz kağıt, b) mavi kağıt, c) sarı kağıt, d) tahta, e) breadboard, f) bakır plaket, g) delikli plaket.	30
Şekil 4.3. Görüntü miktarını artırmak için uygulanan işlemler a) orijinal görüntü, b) 90° döndürülmüş hali, c) parlaklık seviyesinin artırılmış hali, d) parlaklık seviyesinin azaltılmış hali.	30
Şekil 4.4. İkinci veri setindeki elektronik devre elemanlarının örnek görüntüleri a) direnç, b) entegre, c) kondansatör, d) transistör	31
Şekil 4.5. Kullanılan veri setine ait bilgiler a) dosya boyutunun dağılımı, b) çözünürlük dağılımı.	32
Şekil 4.6. Tasarlanan evrişimli sinir ağı.....	33
Şekil 4.7. Farklı seviyelerde Gauss gürültüsüne sahip görüntüler a) $\mu=0$ $\sigma=0.5$, b) $\mu=0$ $\sigma=1.0$, c) $\mu=0$ $\sigma=1.5$, d) $\mu=0$ $\sigma=2.0$	35

Sayfa

Şekil 4.8. Kullanılan web kamera.	36
Şekil 4.9. Web kamera ile çekilen elektronik devre elemanlarının görüntüleri a) direç, b) entegre, c) kondansatör.	36
Şekil 5.1. Orjinal görüntüler a) doğruluk-epok grafiği b) kayıp-epok grafiği.	38
Şekil 5.2. Gürültülü görüntüler ($\mu=0$ $\sigma=0.5$) a) doğruluk-epok grafiği b) kayıp-epok grafiği.	38
Şekil 5.3. Gürültülü görüntüler ($\mu=0$ $\sigma=1.0$) a) doğruluk-epok grafiği b) kayıp-epok grafiği.	39
Şekil 5.4. Gürültülü görüntüler ($\mu=0$ $\sigma=1.5$) a) doğruluk-epok grafiği b) kayıp-epok grafiği.	39
Şekil 5.5. Gürültülü görüntüler ($\mu=0$ $\sigma=2.0$) a) doğruluk-epok grafiği b) kayıp-epok grafiği.	39
Şekil 5.6. Orjinal görüntüler AlexNet a) doğruluk-epok grafiği b) kayıp-epok grafiği.	40
Şekil 5.7. Orjinal görüntüler VGG-11 a) doğruluk-epok grafiği b) kayıp-epok grafiği.	41

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 4.1. Kullanılan veri setindeki elektronik devre elemanlarının toplam sayısı.	31
Çizelge 4.2. Görüntülerin renklerine göre ortalama değerleri ve standart sapma değerleri.	32
Çizelge 5.1. Tasarlanan ESA'ın farklı gürültü seviyeleri için doğruluk değerleri.....	38
Çizelge 5.2. ESA modellerinin doğruluk değerleri.	40
Çizelge 5.3. ESA modellerinin toplam parametre sayıları ve ortama eğitim süreleri	41
Çizelge 5.4. Web kamerası ile elde edilen görüntülerin sınıflandırma sonuçları.	42

SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

w_i : Tahmin Edilen Olasılık

X : Giriş Vektörü

μ : Ortama

σ : Standart sapma

KISALTMALAR

CNN : Convolutional Neural Network (Evrışimli Sinir Ağı)

DSA : Derin Sinir Ağı

ESA : Evrışimli Sinir Ağı

GRU : Gated Recurrent Unit (Kapı Özyinelemeli Geçit)

LED : Light Emitting Diode (Işık Yayan Diyot)

LSTM : Long Short Term Memory (Uzun Kısa Süreli Bellek)

ReLU : Rectified Linear Unit (Rektifiye Lineer Birim)

YSA : Yapay Sinir Ağları

YZ : Yapay Zeka

BÖLÜM 1

GİRİŞ

Günümüzde temel olarak dijital görüntülerin işlenmesini ifade etmekte olan görüntü işleme, resim sayısallaştırma, kodlama, geliştirme, restorasyon, bölütleme ve açıklama gibi sorunlara yanıt olarak geliştirilmiştir [1].

Geniş ve yaygın bir çalışma alanı olan sınıflandırma ise görüntü işlemeden ziyade görüntü tanıma konusu ile daha ilişkilidir. Bir görüntüdeki karakteristik özellikleri, desenleri veya yapıları belirlemek ve bunları belirli bir sınıfa atamak görüntü özelinde sınıflandırmanın amacıdır. Ayrıca sınıflandırılan, görüntünün kendisi de olabilmektedir [2].

Nesne algılama, video ve metin işleme alanlarında çeşitli uygulamaları olan Evrişimli Sinir Ağı (ESA) görüntü sınıflandırma için de kullanılmaktadır. Evrişimli sinir ağlarının, neredeyse tüm sinir ağlarından daha başarılı olduğu belirtilmektedir [3].

Bu çalışma, orjinal ve gürültülü elektronik devre elemanlarının görüntülerinin sınıflandırılması, tasarlanan evrişimli sinir ağının diğer modeller ile karşılaştırılması ve web kamerasından elde edilen elektronik devre elemanları görüntülerinin sınıflandırılması olarak üç farklı deneysel çalışmayı kapsamaktadır. Orjinal ve gürültülü elektronik devre elemanlarının görüntülerinin tasarlanan bir evrişimli sinir ağı ile sınıflandırılmış ve sonuçlar değerlendirilmiştir. Ayrıca tasarlanan evrişimli sinir ağı orjinal görüntüler kullanılarak diğer modeller ile karşılaştırılmıştır. Web kamerasından elde edilen elektronik devre elemanları görüntüleride hem orjinal halleri ile hemde gürültü eklenmiş halleri ile sınıflandırılmış ve sonuçlar değerlendirilmiştir.

Bu yüksek lisans tez çalışması 6 bölümden oluşmaktadır. Bölüm 1’de, tez çalışması ile ilgili genel bilgiler ve tezin bölümleri hakkında bilgi verilmektedir. Bölüm 2’de,

elektronik devre elemanlarının görüntülerini sınıflandırma ve tanıma ile ilgili yapılan çalışmaları içeren literatür araştırması sunulmaktadır. Bölüm 3’de, derin öğrenme, makine öğrenimi, yapay sinir ağları, evrişimli sinir ağları ve evrişimli sinir ağı modelleri hakkında bilgi verilmektedir. Bölüm 4’de, tez çalışmasında kullanılan materyal ve metot anlatılmıştır. Kullanılan veri seti, tasarlanan ESA, Gauss gürültüsü ve veri setine gürültü eklenmesi ve kullanılan web kamera hakkında bilgi verilmektedir. Bölüm 5’de, orjinal ve gürültülü elektronik devre elemanlarının görüntülerinin sınıflandırılması, tasarlanan evrişimli sinir ağının diğer modeller ile karşılaştırılması ve web kamerasından elde edilen elektronik devre elemanları görüntülerinin sınıflandırılması olarak üç farklı deneysel çalışma sunulmaktadır. Bölüm 6’da tezin çalışmasının sonuçları değerlendirilmiştir.

BÖLÜM 2

LİTERATÜR ARAŞTIRMASI

Son yıllarda bilim ve teknolojinin hızlı ilerlemesiyle birlikte nesne tespiti ve sınıflandırması gibi konular araştırmacılar arasında önemli bir ilgi odağı haline gelmiştir. Elektronik devre elemanlarının tespiti, tanınması ve sınıflandırılması ile ilgili de yapılan bir çok çalışma bulunmaktadır. Bu çalışmalar genellikle görüntü işleme ve derin öğrenme tekniklerini içermektedir.

Van Dop ve Regtien [4] baskı devre kartlarındaki elektronik bileşenleri tanıyan bir multi-sensör sistem geliştirmişlerdir. Çalışmalarında menzil, renkli ve yüksek çözünürlüklü olmak üzere üç farklı kamera kullanmışlardır. Sonuç olarak %74 tanıma oranı elde etmişler. Lefkaditis ve Tsirigotis [5] çalışmalarında çok katmanlı algılayıcı (multilayer perceptron) kullanarak, elektronik bileşenler için bir akıllı optik sınıflandırma sistemi sunmuşlardır. %92.3 oranında başarılı tanıma gerçekleştirmişler. Salvador vd. [6] çeşitli derin evrişim sinir ağlarını kullanıp, karşılatırarak elektronik cihazları direnç, kapasitör, indüktör, transformatör, diyot veya entegre olarak sınıflandıran bir çalışma yapmışlardır. Sonuç olarak Inception-v3'ün elektronik bileşenlerin sınıflandırılmasında %94,64 ile en yüksek doğrulama doğruluğuna sahip olduğunu belirtmişler. Wang vd. [7] yüzeye montajlı devre elemanları için paket sınıflandırması yapan bir yapay sinir ağı sunmuşlardır. %95.8 sınıflandırma başarısı elde etmişler ve önerdikleri sistemin hızlı bir şekilde sınıflandırdığını belirtmişler. Maliński ve Okarma [8] elektronik tümleşik devre/entegre paketlerini sınıflandıran bir çalışma sunmuşlardır. Yöntem olarak şekil tanımlayıcılarını kullanmışlardır. Li vd. [9] çalışmalarında baskı devre kartlarındaki elektronik bileşenlerin tespiti için geliştirilmiş YOLO V3 algoritması kullanarak bir uygulama yapmışlardır. Hem gerçek hemde yapay baskı devre kartı görüntüleri kullanmışlar. Sonuç olarak %93.07 oranında bir ortalama kesinlik elde etmişler.

Huang vd. [10] çalışmalarında üç farklı kapasitör ve indüktör için bir tanıma yöntemi sunmuşlardır. Geliştirilmiş YOLO-V3 ağını kullanmışlardır. %95.21 oranında doğruluk ve 0.0794 s süre elde etmişler. Xu vd. [11] derin öğrenmeye dayalı bir elektronik bileşen tanıma algoritması geliştirmişlerdir. Çalışmalarında Faster SqueezeNet ağını kullanmışlardır. Direç, kapasitör ve indüktörün 22 alt kategorisini sınıflandırmışlardır. Hu vd. [12] çalışmalarında hiyerarşik evrişim sinir ağına dayalı yeni bir elektronik bileşen sınıflandırma algoritması sunmuşlardır. Entegre, kapasitör, direnç, endüktans, diyot, LED, hoparlör ve transistör olarak sekiz farklı devre elemanından oluşan bir veri seti kullanmışlardır. %94.26 oranında hassasiyet elde etmişler. Sun vd. [13] elektronik bileşenlerin tanınması için modifiye edilmiş bir single shot multi-box detector yöntemi sunmuşlardır. Çalışmaları için üç farklı kapasitör ve indüktörden oluşan bir veri seti oluşturmuşlardır. Yöntemin küçük veri setleri için çok uygun olduğunu belirtmişler. Lee ve Lee [14] yüzey montaj elemanları gibi minik elektronik parçalar için yeni bir tanıma ve poz tahmini çalışması yapmışlardır. Temel bileşen analizi ve Harris Corner özelliklerini kullanmışlardır. Önerdikleri algoritmanın aydınlatma değişikliklerinde bile keskinliğe ve sağlamlığa sahip olduğunu belirtmişlerdir. Gao vd. [15] baskı devre kartlarındaki mavi dirençleri uyarlanmış YOLOv3 ağını kullanarak tespit etmeye yönelik bir çalışma sunmuşlardır. Uyarlanmış YOLOv3 ağı daha az zaman harcayarak orjinal YOLOv3 ağına yakın sonuç elde ettiğini belirtmişler.

Sathiseelan vd. [16] baskı devre kartlarındaki kötü amaçlı, sahte, yeniden kullanılmış veya geri dönüştürülmüş bileşenleri tespit etmek amacıyla ECLAD-Net adını verdikleri bir ağ önermişlerdir. Sonuç olarak %87.2 oranında keskinlik ve %98.9 oranında duyarlılık elde etmişler. Günay [17] yaptığı yüksek lisans tez çalışmasında elle çizilen temel devre elemanlarının görüntülerini farklı evrişimli sinir ağları kullanarak sınıflandırmıştır ve elde ettiği sonuçları paylaşmıştır. Ayrıca Daha Hızlı Bölge Tabanlı ESA yöntemini kullanarak yine elle çizilmiş devreler üzerinde ki temel devre elemanlarını tespit etmiştir. Başarılı sonuçlar elde ettiğini belirtmiştir. Mordvintseva ve Belitsky [18] Haar Cascade sınıflandırıcı kullanarak elektronik bileşenlerin sınıflandırılması ve sıralanması üzerine bir çalışma yapmışlardır. Tanıma hızını artırmaya çalışmışlardır. Guo vd. [19] gerçek zamanlı elektronik bileşen tespiti yapan bir çalışma sunmuşlardır. Çalışmalarında geliştirilmiş bir YOLOv4-tiny ağı

kullanmışlardır. Sonuç olarak önerilen yöntemin orijinal algoritmanın doğruluğunu %93,74'ten %98,6'ya yükselttiğini belirtmişlerdir. Wu vd. [20] görüntü örneği üretmeye dayalı elektronik bileşen sınıflandırması yapan bir çalışma sunmuşlardır. Generative adversarial network ile ekstradan örnek görüntüler üretilmiş ve evrişimli sinir ağı ile sınıflandırılmıştır. Elektronik bileşenlerdeki kusur türleride sınıflandırılmıştır. Lu vd. [21] YOLO-V3 algoritmasını kullanarak, kullanım ömrü tamamlanmış baskı devre kartlarından ayrılan elektronik bileşenleri sınıflandıran bir çalışma sunmuşlardır. Sunulan modelin tüm elektronik devre elemanı türleri için başarılı sınıflandırma yaptığını belirtmişler.

Cheng vd. [22] Siaseme yani ikiz ağ kullanarak elektronik bileşenlerin sınıflandırılması için bir metot sunmuşlardır. Deneylelerden elde ettikleri sonuçlara göre önerilen yöntemin 15 eğitim örneğiyle 0,94 doğruluk elde edebildiğini söylemektedirler. Varna ve Abromavičius [23] konveyör bandında gerçek zamanlı kapasitör, direnç, diyot ve taransistör olmak üzere elektronik bileşen tespiti ve sınıflandırması yapan bir sistem önermişlerdir. SSD-MobileNet-v1 ve YOLO'nun farklı versiyonlarını kullanarak karşılaştırma yapmışlardır. Zhao vd. [24] 48 farklı türde konnektör için ön bilgiye dayanan bir görsel denetim sistemi geliştirmişlerdir. Önerilen yöntemin başarılı bir şekilde tanıma ve pozisyon belirleme gerçekleştirdiğini belirtmişlerdir. Zhao vd. [25] atık elektronik bileşenlerin sınıflandırması ve kullanılması ile ilgili bir çalışma yapmışlardır. Çalışmalarında triboelektrik nanojeneratörler kullanmışlardır. Atik [26] çalışmasında evrişimli sinir ağı kullanarak diyot, direnç ve kondansatör görüntülerini sınıflandırmıştır. Tasarladığı ESA modelini diğer modeller ile karşılaştırmıştır. Önerdiği modelin %98.99 doğruluk değeri ile diğer modellerden daha başarılı olduğunu belirtmiştir. Zhou ve Zhang [27] farklı arkaplanlar daki elektronik bileşenleri sınıflandırmak için yeni bir 13 katmanlı evrişim sinir ağı sunmuşlardır. Sundukları ağı farklı ağlar ile karşılaştırıp, yüksek doğruluk oranları elde ettiklerini belirtmişler.

Xia vd. [28] çok-sahneli elektronik bileşen tespiti üzerine bir çalışma yapmışlardır. Yeni bir veri seti oluşturmuşlardır. Sonrada k-means algoritmasına dayanan bir yöntem uygulamışlardır. Ortalama kesinlik değeri olarak %83,20 ve %98,59 elde etmişler. Kaya ve Akgül [29] elektronik devre elemanlarını Support Vector Machine,

Naive Bayes ve Random Forest algoritmaları ile sınıflandırarak, algoritmaların performanslarını değerlendirmişlerdir. Elde ettikleri sonuçlara göre Support Vector Machine %95.24, Naive Bayes %67.01 ve Random Forest % 90.14 başarı oranı göstermiş. Chen vd. [30] devre bileşenlerini sınıflandıran ve konumunu tespit eden bir çalışma sunmuşlardır. Çalışmalarında geliştirilmiş bir YOLOv5 algoritması kullanmışlardır. Geliştirdikleri YOLOv5 algoritmasının orijinaline göre %38 daha etkili olduğunu belirtmişler. Starodubov vd. [31] sınıflandırıcı olarak evrişimli sinir ağı kullanarak, optik ve x-ray görüntüleri birleştirerek baskı devre kartlarındaki elektronik bileşenleri sınıflandırma ile ilgili bir çalışma yapmışlardır. Optik ve x-ray görüntüleri ile ayrı ayrı elde ettikleri sonuçları, iki görüntüyü birleştirerek elde ettikleri sonuçlar ile karşılaştırmışlardır. Makwana vd. [32] PCBSegClassNet adında baskı devre kartlarındaki 25 farklı bileşeni bölütleme ve sınıflandırma için yeni bir ağ önermişlerdir. Önerdikleri ağ %95.2 doğruluk oranı elde etmiş. Hožyn [33] endüstriyel uygulamalar daki elektronik bileşenleri sınıflandırmak için çeşitli evrişim sinir ağı modelleri sunmuştur. Elde ettiği sonuçları karşılaştırıp değerlendirmiştir.

Bu çalışmanın literatüre katkısı aşağıdaki şekilde belirtilebilir:

- Farklı seviyelerde Gauss gürültüsüne sahip elektronik devre elemanları görüntüleri ayrı ayrı sınıflandırılarak gürültü seviyesinin sınıflandırma sonuçlarına etkisi tespit edilmiştir.
- Web kamerası ile çekilen elektronik devre elemanları görüntüleri Gauss gürültüsü eklendikten sonra, orjinal gürültüsüz görüntüler ile eğitilen evrişimli sinir ağı ile tek tek sınıflandırılmıştır. Böylelikle gürültü seviyesinin, sınıflandırıcının yani evrişimli sinir ağının tahmin doğruluğunu nasıl etkilediği tespit edilmiştir.


BÖLÜM 3

DERİN ÖĞRENME

Derin öğrenme makine öğreniminin, makine öğrenimi ise yapay zekanın (YZ) kapsamına girmektedir. Yapay zeka, verileri modellemek için kullanılan tüm makine öğrenimi tekniklerini başka bir deyişle matematiksel yaklaşımlara dayalı bir öğrenme biçimini ifade etmektedir. Bu teknikleri daha iyi anlamak için Alan Turing'in düşünebilen makinelerle ilgili, yapay zekanın kökenini oluşturan çalışmalarını incelemek gerekmektedir. Turing hem hesaplamalı mantığın kullanımını hemde makine öğrenimi üzerine çalışılması gerekliliğinden bahsetmektedir. Makine öğrenimi üzerine çalışmanın belli bir zaman dilimi içinde insani özelliklere sahip yapay zekanın geliştirilmesi için etkili olacaktır. "Child Machine" yani bebek gibi öğrenen bir makine hakkında yorumlar yaparak bir yapay zekanın nasıl geliştirilebileceği ile ilgili önerilerde bulunmuştur. Turing yapay zeka geliştirilmesi ile ilgili üç farklı yapay zeka türü önermektedir. Bunlardan ilk ikisi bazı sınırlamaları olduğunu belirttiği, programlama ve makine öğrenimi ile yapay zekadır. Ümit verici olarak değerlendirdiği ise mantık, olasılıklar ve arka plan bilgisi kullanan ve öğrenen yapay zekadır [34].

Basit ve sığ ağlar ile öğrenmeye kıyasla daha soyut bilgileri öğrenmek için derin mimariler meydana getirme yetkinliğine sahip olan derin öğrenme, bir görev için özel olarak geliştirilmiş algoritmaların aksine, öğrenme veri temsillerine dayanan geniş bir makine öğrenme yöntemlerine dahildir. Birden fazla temsil düzeyine sahip olan derin öğrenme yöntemleri, temsilleri daha üst düzeydeki temsillere dönüştürerek karmaşık işlevler öğrenebilir. Birer adet giriş ve çıkış katmanı bulunan ve birden fazla gizli katman bulunmayan basit yapıdaki ağlara dayanan geleneksel makine öğreniminin aksine derin öğrenme bir ağda giriş ve çıkış katmanları arasındaki gizli katmanların sayısı fazlaştıkça derinleşerek oluşmaktadır [35, 36].

Şekil 3.1’de giriş katmanı, gizli katmanlar ve çıkış katmanından oluşan örnek bir derin sinir ağı (DSA) gösterilmektedir.



Şekil 3.1. Derin sinir ağı [36].

3.1. MAKİNE ÖĞRENİMİ

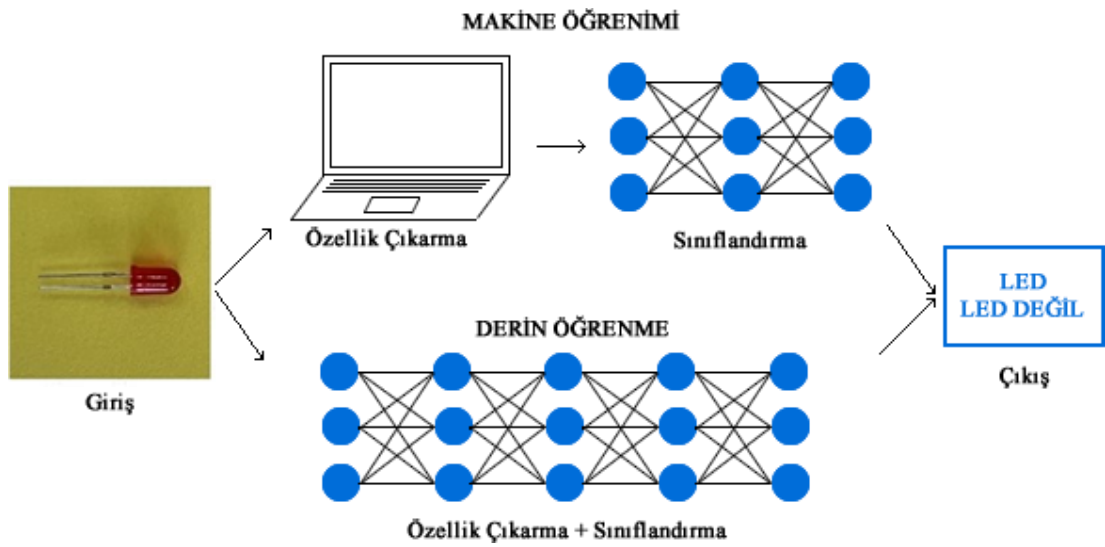
Makine öğrenimi veriler ve geçmiş deneyimlerle gelişen bilgisayar sistemleri oluşturma süreci olarak tanımlanabilir. Bu sistemler bir öğrenme süreci de uygulamaktadırlar. İnsanların kolay bir şekilde anlayabileceği basitlikte sınıflandırma tanımlamaları üretmeyi amaçlamaktadır. İnsan muhakemesini taklit ederek karara ilişkin değerlendirme yapabilmelidir. Makine öğrenimi teoriyi verilerden otomatik olarak, bir çıkarım süreci, model uydurma veya örneklerden öğrenme yoluyla öğrenmek olarak da tanımlanabilir. İstatistiksel yaklaşımlar gibi, geliştirmede arka plan bilgisinden faydalanılabilir, ancak işlem insan müdahalesi olmadan varsayılmaktadır [37].

Burada öğrenmeyi farklı şekillerde tanımlayabiliriz [37];

- Deneyim veya çalışma yoluyla bilgi, anlayış veya ustalık kazanmak veya bir şeyin bilgisini kazanmak veya bazı sanat veya uygulamalarda beceri kazanmak.
- Bir konuda deneyim veya yetenek veya beceri kazanmak.

- Bir şeyi ezberlemek, deneyim, örnek veya pratik yoluyla kazanmak.

Makine öğrenimi iyi olasılıksal modeller meydana getirerek bir veri kümesinden faydalı bilgilerin doğrudan çıkarılmasını sağlar. Mevcut bir teorinin bulunmadığı fazla miktarda verinin bulunduğu alanlar için uygundur [37]. İşlem süreci derin öğrenmeden biraz farklıdır. Makine öğreniminde özellik çıkarma ayrı bir adım olarak uygulanırken derin öğrenmede sınıflandırma ile birlikte yapılmaktadır. Şekil 3.2’de makine öğrenimi ve derin öğrenmenin işlem adımları gösterilmektedir.



Şekil 3.2. Makine öğrenimi ve derin öğrenme.

Makine öğrenimi pek çok alana uygulanmakta ve çeşitli uygulamalarda kullanılmaktadır [38];


- Konuşma tanıma: konuşma tanımaya yönelik mevcut ticari sistemlerin tümü, sistemi konuşmayı tanıyacak şekilde eğitmek için makine öğrenimini kullanmaktadır.
- Bilgisayarlı görme: bir çok bilgisayarlı görme ve görüntü işleme uygulamaları, yüz tanıma ve mikroskop görüntüleri inceleme gibi, makine öğrenimi ile yapılmaktadır.
- Biyolojik gözetim: hastalıkların yayılımını tespit etme ve takip etme de artık makine öğrenimi kullanılmaktadır.

- Robot kontrolü: makine öğrenimi yöntemleri çeşitli robot sistemlerinde başarıyla kullanılmaktadır.
- Deneysel bilimleri hızlandırmak: fazla veri kullanan bilimlerin çoğu artık bilimsel çalışma sürecine fayda sağlamak için makine öğrenimi yöntemlerinden yararlanmaktadır.

3.2. YAPAY SİNİR AĞLARI

Yapay Sinir Ağları (YSA) makine öğreniminin bir alt dalıdır ve insan biyolojik sinir sisteminden esinlenerek tasarlanmış matematiksel modellemelerdir [39]. Yapay sinir ağları, bilgisayarların büyük miktarda veriyi işleme, desenleri algılama, tahmin yapma ve karar verme gibi karmaşık görevleri gerçekleştirebilmesini sağlar. Yapay sinir ağları, birbirine bağlı yapay nöronlardan (düğüm) oluşur. Her bir yapay nöron, girdi verilerini alır, bu verileri bir dizi matematiksel işlemden geçirir ve çıktı üretir. Yapay sinir ağları (YSA), bir giriş katmanı, bir çıkış katmanı ve bir veya birden fazla gizli katman içermektedir. Bu katmanlar düğümlerden oluşmaktadır. Her düğüm veya yapay nöron diğerine bağlanır ve ilişkili bir ağırlığa ve eşiğe sahiptir. Yapay nöronlar arasındaki bağlantılar bu ağırlıklar ve eşik değerler tarafından kontrol edilir. Ağırlıklar, girdi verilerinin önemini belirlerken, eşik değerler, yapay nöronun etkinleşme düzeyini belirler. Herhangi bir yapay nöromum çıkışı belirlenen eşik değerinden fazlaysa, o nöron etkinleştirilir ve ağına bir sonraki katmanına veri gönderilir. Ters durumda ağına bir sonraki katmanına hiçbir veri aktarılmaz [40].

Yapay sinir ağları, öğrenmek ve belli bir zamandaki doğruluk oranlarını geliştirmek için eğitim verilerine güvenmektedir. Ayrıca, bu sinir ağları doğruluk için ince ayar yapıldıktan sonra, bilgisayar bilimi ve yapay zeka alanında verileri yüksek hızda işlememize olanak tanıyan güçlü araçlar haline gelmektedirler. Konuşma tanıma ve görüntü tanıma gibi görevler, insan uzmanların manuel tanımlamasıyla karşılaştırıldığında çok daha kısa zamanda tamamlanabilmektedir [40]. Şekil 3.3'de bir yapay sinir ağı modeli gösterilmektedir.



Şekil 3.3. Yapay sinir ağı modeli [39].

İleri beslemeli bir sinir ağı mimarisi giriş katmanı, gizli katman, çıkış katmanı ve ağırlıklardan oluşmaktadır [41]:

Giriş katmanı: Bu katman, girdileri alan ve bunları diğer katmanlara aktaran nöronlardan oluşmaktadır. Giriş katmanındaki nöronların sayısı veri setindeki özelliklerle aynı olmalıdır.

Gizli katman: Giriş ve çıkış katmanları arasında bulunan gizli katmanlar çok sayıda nöron içerir. Ağ eğitildikçe ağırlıklar daha iy tahmin yapabilecek şekilde güncellenir.

Çıkış katmanı: Çıkış katmanı oluşturduğunuz modelin türüne göre tahmin edilen özelliktir.

Nöron ağırlıkları: Nöronların arasındaki bağlantının gücünü veya genliğini ifade etmektedirler.

YSA kullanmanın temel avantajları ve dezavantajları [42]:

Avantajları:

- Bilginin ağı tamamında saklanması: Birkaç bilginin tek bir yerde kaybolması ağı çalışmasını engellemez çünkü geleneksel programlama gibi bilgiler bir veritabanında değil ağı tamamında depolanır.
- Eksik bilgiyle çalışabilme yeteneği: YSA eğitimi sonrasında veriler eksik bilgiyle bile çıktı üretebilmektedir. Eksik bilginin önemine göre performans kaybı gerçekleşebilir.

- Hata toleransına sahip olmak: YSA'nın herhangi bir veya iki hücresinin bozulması, onun sonuç vermesini engellemez. Bu özellik ile ağlar hataya dayanıklı hale gelir.
- Dağıtılmış hafızaya sahip olmak: Seçilen örnekler ağın başarısını doğrudan etkiler ve eğer olay ağa tüm yönleriyle gösterilemezse ağ yanlış çıktılar üretebilir, ağın başarısı için seçilen örnekler önemlidir.

Dezavantajları:


- Donanım bağımlılığı: YSA yapıları gereği paralel işlem yapabilen işlemcilerle ihtiyaç duyar. Bu nedenle başarı donanıma bağlıdır.
- Ağın açıklanamayan davranışı: YSA'nın en önemli sorunu bir probleme çözüm bulduğunda neden ve nasıl olduğu ile ilgili bir bilgi vermez. Bu durumda ağa olan güven azalır.
- Uygun ağ yapısının belirlenmesi: Yapay sinir ağlarında uygun ağ yapısına deneyim ve deneme yanılmayoluyla ulaşılır, yapının belirlenmesine yönelik belirli bir kural yoktur.
- Sorunu ağa göstermenin zorluğu: Problemlerin YSA'na sunulmadan önce sayısal değerlere çevrilmesi gerekmektedir çünkü YSA sadece sayısal bilgilerle çalışabilir.

3.3. EVRİŞİMLİ SİNİR AĞI

Evrışimli sinir ağı (ESA) canlıların doğal görsel algılamalarından ilham alan bir derin öğrenme mimarisidir. Fukushima 1980 yılında yaptığı çalışma [43] ile ESA'nın temelini atmış, 1998 yılında LeCun ve ark. yaptıkları çalışmada [44] ise ilk temel ESA modellerinden birini sunmuşlardır. Derin öğrenme alanının en temsili sinir ağlarından biri haline gelen evrışimli sinir ağı bir çok alanda başarı ile uygulanmaktadır. Evrışimli sinir ağları ile geleneksel yapay sinir ağları arasındaki dikkat çeken fark, evrışimli sinir ağlarının daha çok görüntü işleme, örüntü tanıma ve bilgisayar görüşü alanında kullanılmasıdır. ESA'ya dayalı bilgisayar görüşü çalışmaları, yüz tanıma, otonom araçlar, self-servis süpermarketler ve akıllı tıbbi tedaviler gibi son birkaç yüzyılda imkansız olduğu düşünülen şeylerin başarılmasına olanak sağladı. Görüntüye özgü

özellikleri mimariye kodlamamıza olanak tanıyarak evrişimli sinir ağları girişi görüntü olan görevler için daha elverişli hale gelirken, modeli ayarlamak için gereken parametre sayısını da azaltmaktadır [45,46].

Bir evrişimli sinir ağı temel olarak evrişim katmanı, havuzlama katmanı ve tam bağlantı katmanından oluşmaktadır. Evrişim ve havuzlama katmanında özellik çıkarma işlemi gerçekleştirilirken, tam bağlantı katmanında çıkarılan özellikleri sınıflandırma gibi işlemler yapılmaktadır. Şekil 3.4’de temel bir evrişimli sinir ağı modeli gösterilmektedir.



Şekil 3.4. Evrişimli sinir ağı modeli [47].

ESA kullanmanın avantajları ve dezavantajları [46,48]:

Avantajları:


- Özellik çıkarımı başka bir işleme gerek duyulmadan ESA ile otomatik olarak gerçekleştiğini için işlem zamanı düşmektedir.
- Yerel bağlantılar ve ağırlık paylaşımı ile parametre sayısı düşmektedir.
- Havuzlama ile boyut azaltma parametre sayısını düşürmektedir.
- Farklı aydınlatma, karmaşık arka plan, görüntülerin boyutu ile yönü ve farklı çözünürlük gibi zorlu koşullar altında bile oldukça başarılıdır.

Dezavantajları:

- Eğitim bazen uzun zaman alır.
- Büyük veri setleri gerektirir.
- Modellerin karmaşıklığı nedeniyle optimizasyon sorunları ve donanım kısıtlamaları olabilir.
- Uzaysal bilgi kaybı olmaktadır.

3.3.1. Evrişim Katmanı

Evrişim katmanı evrişimli sinir ağının çalışmasında önemli bir rol oynamaktadır. Evrişim katmanı girdi olarak bir görüntüyü alır ve her bir filtre ile konvolüsyonunu hesaplar. Bu filtreler uzamsal boyut açısından küçüktür ancak girdi derinliğinin tamamı boyunca yayılır. Veriler evrişim katmanına ulaştığında katman filtreyi girişin uzamsal boyutu boyunca evrişir. Belirli bir görüntü için oluşturulan piksel matrisini, bu görüntü için özellik haritaları oluşturmak amacıyla evrişir [45, 49]. Evrişim katmanları, evrişimli sinir ağlarında genellikle birkaç tane ve ardışık havuzlama katmanları ile kullanılmaktadır. Şekil 3.5’de evrişim katmanı gösterilmektedir.

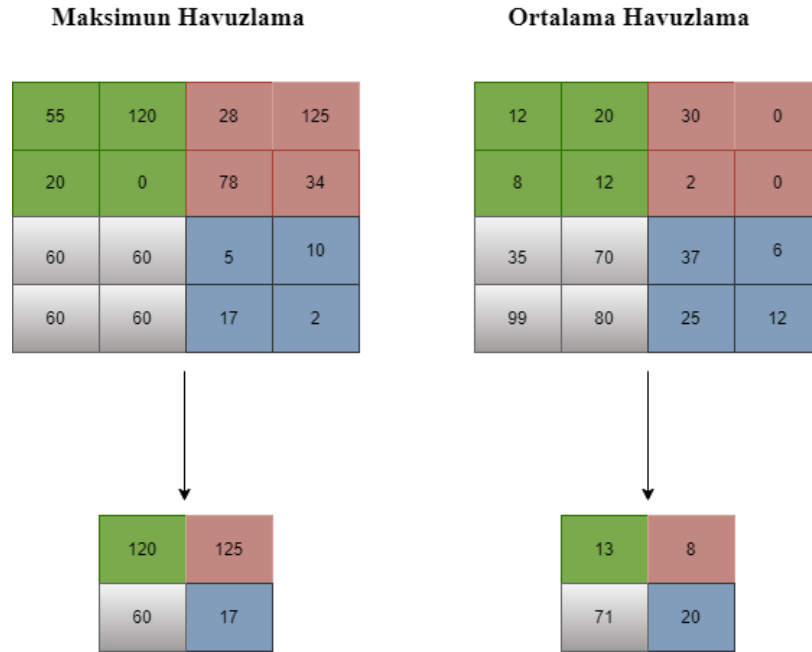


Şekil 3.5. Evrişim katmanı [45].

3.3.2. Havuzlama Katmanı

Havuzlama katmanı genellikle iki evrişimli katmanı arasına yerleştirilir. Girdi olarak birkaç özellik haritası alır ve bunların her birine havuzlama işlemini uygular. Havuzlamanın amacı önemli bilgileri koruyup ilgisiz ayrıntıları atarak, ortak özellik

gösterimini daha kullanışlı hale dönüştürmektir. Havuzlama katmanı bir indirgeme katmanı olarak işlev görür. Girdilerdeki bozulmalara karşı değişmezliği artırmak için havuzlama katmanında özellik haritalarının çözünürlüğü önceki katmanın özellik haritaları üzerindeki yerel komşulukların havuzlanmasıyla azaltılır. Havuzlama işlemi bir görüntüye uygulandıysa işlem sonunda görüntünün boyutunda küçülme meydana gelmektedir. Evrişimli sinir ağlarında havuzlama katmanının kullanılması, bir çok dış koşuldaki değişikliklere karşı değişmezliği, iyi temsili ve dağınıklığa karşı sağlamlığı sağlamayı amaçlamaktadır [50]. Evrişimli sinir ağı modellerinde genellikle en çok kullanılan iki türü maksimum havuzlama ve ortalama havuzlamadır. Şekil 3.6'da havuzlama katmanı gösterilmektedir.



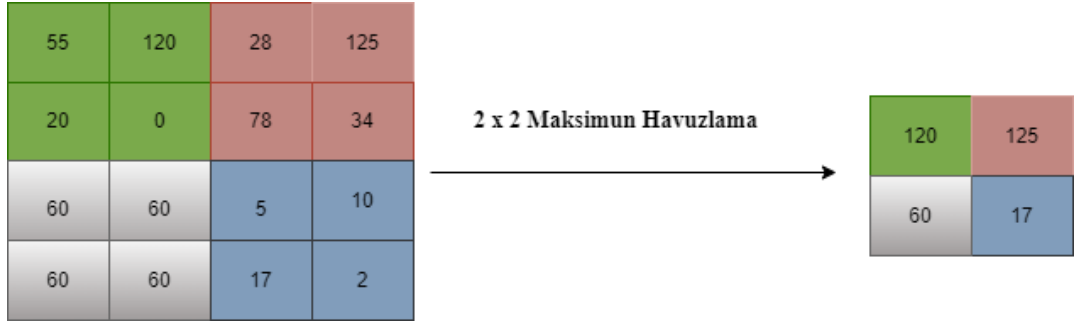
Şekil 3.6. Havuzlama katmanı.

3.3.2.1. Maksimum Havuzlama

Maksimum havuzlama evrişimli sinir ağlarında sıklıkla kullanılan bir havuzlama yöntemidir. Havuzlama özellik haritalarının altörneklenmesi için kullanılmaktadır. Altörnekleme hem özellik haritalarının uzaysal çözünürlüğünü azaltır hemde çözünürlük azaltıldığı için kullanılan bellek gibi faktörlerde azalacaktır. Sınıflandırma yapan ağlarda birkaç kez kullanılmaktadır [51]. Genellikle görüntü işleme ve derin öğrenme uygulamalarında yaygın olarak kullanılmaktadır. Görüntünün belirli

büyükteki bir kısımdan en büyük değeri alarak uygulanan matematiksel bir işlemdir [52].

Genellikle 2x2 filtreler kullanılarak maksimum havuzlama gerçekleştirilir. Bu filtreler, özellik haritasını 2x2 boyutunda bölgelere ayırır ve her bölgedeki en yüksek değeri seçer. Böylece, çıktı matrisi, giriş matrisine göre boyutunu yarıya indirir. Şekil 3.7’de maksimum havuzlama işlemi gösterilmektedir.



Şekil 3.7. Maksimum havuzlama.

Maksimum havuzlama işleminin bazı avantajları ve dezavantajları şunlardır [53]:

Avantajlar:


- Basit sınıflandırıcılar ve seyrek kodlar ile kullanıldığında daha etkili performans gösterir. Burada seyrek kodlama, verileri verimli bir şekilde temsil etmek için aşırı tamamlanmış taban kümelerini öğrenmeye yönelik denetimsiz yöntemler sınıfıdır.
- İstatistiksel özelliklerinden dolayı seyrek temsilleri tamamlar.
- No maximal öğelerin ortadan kaldırılması, üst katmanlar için hesaplama hızının performansını artırabilir.

Dezavantajlar:

- Havuzlama bölgesindeki öğelerin çoğunluğu önemli büyüklükte mevcut olduğunda ayırt edici özellikler ortadan kalkar ve deterministiktir.

3.3.2.2. Ortalama Havuzlama

Ortalama Havuzlama da maksimum havuzlama gibi evrişimli sınır ağlarında sıklıkla kullanılan bir havuzlama yöntemidir. Genellikle görüntü işleme ve derin öğrenme uygulamalarında yaygın olarak kullanılmaktadır. Görüntünün belirli bir boyuta sahip bir bölümünün ortalama değerini alarak uygulanan matematiksel bir işlemdir [52]. Ortalama havuzlama da genellikle 2x2 filtreler kullanılarak gerçekleştirilir. Bu filtreler, özellik haritasını 2x2 boyutunda bölgelere ayırır ve her bölgedeki değerlerin ortalaması hesaplanıp, kullanılır. Böylece, çıktı matrisi, giriş matrisine göre boyutunu yarıya indirir. Şekil 3.8’de ortalama havuzlama işlemi gösterilmektedir.



Şekil 3.8. Ortalama havuzlama.

Ortalama havuzlama işleminin bazı avantajları ve dezavantajları şunlardır [53]:

Avantajlar:

- Kolay anlaşılır.
- Uygulama kolaydır.

Dezavantajlar:

- Küçük büyüklükler dikkate alınırsa kontrast azalır ve forthcomingdir.

3.3.3. Düzleştirme Katmanı

Evrişimli sinir ağlarında kullanılan bir diğer katman düzleştirme katmanıdır. Düzleştirme katmanında iki boyutlu olan özellik haritaları tek boyutlu hale getirilmektedir. Düzleştirme katmanından sonra oluşan çıkış tam bağlantı katmanında giriş olarak kullanılmaktadır. Düzleştirme katmanının amacı evrişimli katmanlardan tam bağlantı katmanına geçişi sağlamak, tam bağlantı katmanı için verileri basitleştirme ve boyutu azaltarak modelin karmaşıklığını azaltmaktır [54]. Şekil 3.9’da düzleştirme katmanı gösterilmektedir.



Şekil 3.9. Düzleştirme katmanı.

Düzleştirme katmanının avantajları ve dezavantajları şu şekildedir [54]:

Avantajlar:


- Evrişimli ve tam bağlantılı katmanlar arasındaki geçişi sağlar: Verileri tam bağlantı katmanında işlenebilecek hale çevirir.
- Veri işlemeyi basitleştirir: Veriyi manuel olarak değiştirme ihtiyacını ortadan kaldırarak kullanımı kolay hale getirmektedir.
- Model karmaşıklığını azaltır: Parametre sayısını azaltarak model karmaşıklığını azaltır.
- Uyumludur: Bir çok derin öğrenme kütüphanesinde bulunmasından dolayı uygulanması kolaydır.

Dezavantajlar:

- Uzaysal bilgi kaybı: Düzleştirme katmanı kullanıldığında orijinal veride bulunan uzaysal veya zamansal yapıyı kaybedilir.
- Sıralı bilgi kaybı: Veriyi düzleştirmek sıralı bilginin kaybolmasına neden olabilmektedir.
- Artan model karmaşıklığı: Modele başka bir katman eklemek bazı durumlarda uzun eğitim sürelerine ve artan hesaplama gereksinimlerine neden olabilmektedir.
- Her zaman gerekli değildir: Bazı uygulamalarda düzleştirme katmanını kullanmak zorunlu değildir.

3.3.4. Tam Bağlantı Katmanı

Tam bağlantı katmanı evrişimli sinir ağlarında sınıflandırma işleminin yapıldığı katmandır. Tam bağlantı katmanı birkaç katmandan oluşabilir ve sonunda evrişimli sinir ağının sonu olan çıktı katmanı bulunur. Genellikle veri nöronlara aktarılmadan önce düzleştirilir. Bu katman da uzaysal bilgi saklanmaz ve her nöron, önceki katmandaki tüm nöronlarla bağlantılıdır. Her nöronun çıkışı için değişken ağırlıkta çok sayıda gizli katmanın bulunması nedeniyle bu noktadan sonra verileri takip etmek zordur [49]. Karmaşık ilişkileri modelleyebilen ve özellikler arasındaki ilgiyi anlayabilen evrişimli sinir ağında tam bağlantı katmanında küme sayısı ile aynı sayıda çıkış nöronu bulunmaktadır. Yani yapılan sınıflandırma işleminde kaç farklı sınıf varsa çıkış nöron sayısı da o miktarda olacaktır. Tüm katmanlar tamamen bağlandıktan sonra öğrenimin yapılıp sonuçların üretilmesi için doğrusal olmayan bir aktivasyon fonksiyonu uygulanır [55]. Katmandaki parametre sayısı nöron sayısı ile doğru orantılıdır. Ne kadar fazla sayıda kullanılırsa karmaşıklık ve hesaplama süresi de o kadar artar. Şekil 3.10'da tam bağlantı katmanı gösterilmektedir.



Şekil 3.10. Tam bağlantı katmanı [55].

3.3.5. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları gelen sinyalin aktivasyon seviyesini belirleyen ve çıktı değerini hesaplayan matematiksel fonksiyonlardır. Aktivasyon fonksiyonları ağı daha doğrusal olmayan bir hale gelmesini ve daha karmaşık ve esnek modelleri öğrenmesini sağlamaktadır. Derin öğrenme çalışmalarında uygun bir aktivasyon fonksiyonu bulmaya özen gösterilmektedir. Farklı aktivasyon fonksiyonları modelin doğrusal olmayan uyum yetenekleri üzerinde farklı etkilere sahiptir. Genel olarak aktivasyon fonksiyonlarının doğrusal olmama, türevlenebilirlik, basit, doyma, monoton ve az parametreye sahip olma gibi özelliklere sahip olması beklenmektedir [56]. Yaygın olarak kullanılan aktivasyon fonksiyonları sigmoid, tanh, ReLU ve softmax'dir.


3.3.5.1. Sigmoid Fonksiyonu

Sigmoid fonksiyonu aktivasyon fonksiyonlarının en yaygın biçimlerinden biridir. Sigmoid fonksiyonu her noktada türevlenebilir, her yerde farklılaşabilir ve düzgün bir S şeklinde fonksiyondur. Sigmoid fonksiyonunun sifira göre simetrik olmaması nöronların tüm çıkış değerlerinin işaretlerinin aynı olmasına neden olmaktadır. Bu durum ölçeklendirme ile çözülebilmektedir [57, 58].

Sigmoid fonksiyonu, giriş gerçek bir sayı çıkış $[0,1]$ aralığında olacak şekilde Eşitlik 3.1'deki gibi tanımlanmaktadır [59].

$$f(x) = \frac{1}{1+e^{-x}} \quad (3.1)$$

Sigmoid fonksiyonunun grafiği Şekil 3.11'de gösterilmektedir.



Şekil 3.11. Sigmoid fonksiyonu [59].

Sigmoid fonksiyonunun avantajları ve dezavantajları şunlardır [60]:

Avantajları:

- Sonuç fonksiyonu 0 ile 1 arasında bir değer aldığıında sigmoid fonksiyonu etkili çalışmaktadır.

Dezavantajları:

- Doymuş nöronlar gradyanları kullanılmaz hale getirir.
- Sigmoid fonksiyonunun sonucu 0'a odaklanmaz.
- Yüksek hesaplama maliyetine sahiptir.
- LSTM (Long Short Term Memory) veya GRU (Gated Recurrent Unit) gibi tekrarlayan mimari kullanılırsa gradyanlar kullanılmayan bir hale gelir.
- Eğimin kaybolma eğilimi vardır.


3.3.5.2. Tanh Fonksiyonu

Tanh fonksiyonu sigmoid fonksiyonuna benzer ancak orijin etrafında simetriktir ve tanh fonksiyonunun eğimi daha diktir. Ayrıca sigmoid fonksiyonuna göre daha geniş bir çıkış aralığına sahiptir. Sürekli ve monotonik bir fonksiyondur ve her yerde türevlenebilir [57, 58].

Tanh fonksiyonu çıkış $[-1,+1]$ aralığında olacak şekilde Eşitlik 3.2'deki gibi tanımlanmaktadır [59].

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.2)$$

Tanh fonksiyonunun grafiği Şekil 3.12'de gösterilmektedir.



Şekil 3.12. Tanh fonksiyonu [59].

Tanh fonksiyonunun avantajları ve dezavantajları şunlardır [60]:

Avantajlar:

- Türevi daha fazla değer kazanır.
- Daha hızlı öğrenme için daha geniş bir aralığa sahiptir.

Dezavantajlar:

- Kaybolan gradyanlar oluşmaktadır.


3.3.5.3. ReLU Fonksiyonu

ReLU (Rectified Linear Unit) fonksiyonu yaygın olarak kullanılan bir aktivasyon fonksiyonudur. Pozitif giriş değerlerini deęiřtirmeden aktarırken, negatif deęerleri sıfıra eřitleyerek lineer olmayan bir etkiye sahiptir. Tüm nöronların aynı anda etkinleřtirilmemesi ReLU'nun avantajlarından biridir. Yani bir nöron yalnızca doğrusal dönüşümün çıktısı sıfır olduğunda devre dıřı bırakılmaktadır [58].

ReLU fonksiyonu eşik deęer sıfır da olduğunda her türlü negatif deęeri ortadan kaldırır ve Eşitlik 3.3'deki gibi tanımlanmaktadır [59].

$$f(x) = \max(0, x) \quad (3.3)$$

ReLU fonksiyonunun grafięi Şekil 3.13'de gösterilmektedir.



Şekil 3.13. ReLU fonksiyonu [59].

ReLU fonksiyonunun avantajları ve dezavantajları şunlardır [60]:

Avantajları:

- Zaman ve mekan karmaşıklığı azdır ve daha uzun süren üstel hesaplamaya ihtiyaç duymaz.
- Kaybolan gradyan sorununu çözer.
- Pozitif tarafı doyurmaz.

- Hesaplama açısından çok verimlidir.
- Pratikte sigmoid ve tanh'dan daha hızlı yakınsar.

Dezavantajları:

- Sonuç 0'a eşit bir media'ya sahip değildir.
- Negatif değerler olumsuz bir durumu belirtmektedir.
- ReLU patlayan gradyan sorununu çözemez.

3.3.5.4. Softmax Fonksiyonu

Softmax fonksiyonu bir giriş vektöründeki elemanların değerlerini olasılık dağılımına dönüştüren bir matematiksel fonksiyondur. Genellikle çok sınıflı sınıflandırma problemlerinde kullanılır. Birden fazla sigmoid fonksiyonunun birleşimidir. Sigmoid fonksiyonunun 0 ile 1 aralığındaki çıktı değerleri belirli bir sınıfın veri noktalarının olasılıkları olarak kabul edilebilmektedir [58].

Ayrık bir olasılık dağılım vektörü üreten softmax fonksiyonu Eşitlik 3.4'deki gibi tanımlanmaktadır. X giriş vektörünü ve w_i , $y=j$ 'nin tahmin edilen olasılığını temsil etmektedir [59].

$$P(y = j|X) = \frac{e^{x^T w_j}}{\sum_{k=1}^K e^{x^T w_k}} \quad (3.4)$$

Softmax fonksiyonunun avantajları ve dezavantajları aşağıda listelenmiştir [60]:

Avantajları:

- Sınıflandırma yapan derin öğrenme modellerinin çıktı katmanında tercih edilir.
- Eğitimi ve tahmin süresi hızlıdır.


Dezavantajları:

- Verileriniz doğrusal olarak ayrılamıyorsa uygulanamaz.
- Boş reddi desteklemez.

3.4. EVRİŞİMLİ SİNİR AĞI MODELLERİ

3.4.1. LeNet-5

1998 yılında LeCun ve ark. tarafından geliştirilen LeNet-5 [44] el yazısı rakamların tanınması amacı ile kullanılmıştır. Genellikle görüntü sınıflandırma uygulamalarında kullanılan bir evrişimli sinir ağıdır. Şekil 3.14’de LeNet-5’in mimarisi gösterilmektedir.




Şekil 3.14. LeNet-5’in mimarisi [44].

LeNet-5’in mimarisini incelediğimizde giriş olarak 32x32 piksel boyutlarındaki bir görüntüyü kabul etmektedir. İki tane evrişim katmanına sahiptir. Bunlardan ilkinde 6, ikincisinde 16 tane filtre kullanılmıştır. Burada kullanılan filtrelerin boyutları 5x5’dir. Aktivasyon fonksiyonu olarak da tanh kullanılmıştır. Her evrişim katmanından sonra alt örnekleme olarak havuzlama katmanı gelmektedir. İki havuzlama katmanında da 2x2’lik ortalama havuzlama işlemi yapılmıştır. Üç tane tam bağlantı katmanı bulunmaktadır. Bunlardan ilkinde 120, ikincisinde 84 ve üçüncüsünde 10 tane nöron bulunmaktadır. Aktivasyon fonksiyonu olarak da ilk iki tam bağlantı katmanında tanh, sonuncusunda ise softmax kullanılmaktadır [44].

3.4.2. AlexNet

Krizhevsky ve ark. tarafından geliştirilen bir evrişimli sinir ağı olan AlexNet [61], 2012 yılında düzenlenen düzenlenen ImageNet Large Scale Visual Recognition Challenge (ILSVRC) yarışmasında sınıflandırma hata oranını büyük miktarda düşürerek önemli bir sonuç almıştır. Şekil 3.15’de AlexNet’in mimarisi gösterilmektedir.




Şekil 3.15. AlexNet’in mimarisi [61].

AlexNet giriş olarak 227x227 piksel boyutlarındaki bir görüntüyü almaktadır. Beş tane evrişim katmanına sahiptir. Bunlardan ilkinde 11x11 boyutlarında 96 tane filtre kullanılmıştır. İkincisinde 5x5 boyutlarında 256 tane filtre kullanılmıştır. Üçüncü ve dördüncü evrişim katmanlarında 3x3 boyutlarında 384 tane filtre kullanılmıştır. Son evrişim katmanında da 3x3 boyutlarında 256 tane filtre kullanılmıştır. Aktivasyon fonksiyonu olarak da ReLU kullanılmıştır. Birinci, ikinci ve beşinci evrişim katmanından sonra havuzlama katmanı bulunmaktadır. Havuzlama katmanlarında 3x3’lük maksimum havuzlama yapılmaktadır. Üç tane tam bağlantı katmanı bulunmaktadır. Bunlardan ilkinde 4096, ikincisinde 4096 ve üçüncüsünde 1000 tane nöron bulunmaktadır. Aktivasyon fonksiyonu olarak da ilk iki tam bağlantı katmanında ReLU, sonuncusunda ise softmax kullanılmaktadır [61].


3.4.3. VGGNet

Simonyan ve Zisserman tarafından geliştirilen VGGNet [62], genelde görüntü sınıflandırma problemlerinde kullanılan bir diğer evrişimli sinir ağıdır. VGGNet’in

farklı katman sayılarına sahip değişik versiyonları vardır. Bunlardan VGG-11'in mimarisi Şekil 3.16'da ve VGG-16'nın mimarisi de Şekil 3.17'de gösterilmektedir.



Şekil 3.16. VGG-11'in mimarisi [62].



Şekil 3.17. VGG-16'nın mimarisi [62].

VGG-11'de sekiz adet evrişim katmanı bulunmaktadır. Evrişim katmanlarında sırasıyla 64, 128, 256, 256, 512, 512, 512 ve 512 adet 3x3 boyutlarında filtre bulunmaktadır. Aktivasyon fonksiyonu olarak ReLU kullanılmıştır. Birinci, ikinci, dördüncü, altıncı ve sekizinci evrişim katmanından sonra havuzlama katmanı bulunmaktadır. Havuzlama katmanlarında 2x2'lik maksimum havuzlama yapılmaktadır. Üç tane tam bağlantı katmanı bulunmaktadır. Bunlardan ilkinde 4096, ikincisinde 4096 ve üçüncüsünde 1000 tane nöron bulunmaktadır. Aktivasyon fonksiyonu olarak da ilk iki tam bağlantı katmanında ReLU, sonuncusunda ise softmax kullanılmaktadır. VGG-16'da onüç adet evrişim katmanı bulunmaktadır. Evrişim katmanlarında sırasıyla 64, 64, 128, 128, 256, 256, 256, 512, 512, 512, 512, 512 ve 512 adet 3x3 boyutlarında filtre bulunmaktadır. Aktivasyon fonksiyonu olarak ReLU kullanılmıştır. İkinci, dördüncü, yedinci, onuncu ve onüçüncü evrişim katmanından sonra havuzlama katmanı bulunmaktadır. Havuzlama katmanlarında 2x2'lik maksimum havuzlama yapılmaktadır. Üç tane tam bağlantı katmanı bulunmaktadır. Bunlardan ilkinde 4096, ikincisinde 4096 ve üçüncüsünde 1000 tane nöron bulunmaktadır. Aktivasyon fonksiyonu olarak da ilk iki tam bağlantı katmanında ReLU, sonuncusunda ise softmax kullanılmaktadır [62].

BÖLÜM 4

MATERYAL VE METOD


Bir çalışmada temel yöntemlerin ve kullanılan materyallerin ayrıntılı bir şekilde tanıtılması önem arz etmektedir. Bu bölümde çalışma da kullanılan elektronik devre elemanlarının görüntülerinden oluşan veri seti kaç çeşit devre elemanı içerdiği ve toplam kaç adet görüntü içerdiği gibi ayrıntılar verilerek anlatılmıştır. Ayrıca tasarlanan ESA'nın genel yapısı ve katmanlarının özellikleri belirtilmiştir. Gauss gürültüsü ve veri setindeki görüntülere uygulanarak yeni veri setleri oluşturulması detaylandırılmıştır.

4.1. KULLANILAN VERİ SETİ

Elektronik devre elemanları, elektronik devreleri oluşturmak için kullanılan bileşenlerdir. Bu bileşenlerin farklı farklı özellikleri ve görevleri vardır. Üzerindeki renk bantları ile değeri anlaşılabilen direç, devredeki akımı sınırlandırmak için kullanılır. Kondansatör filtre, osilatör ve zamanlama devrelerinde enerji depolamak için kullanılır. Silisyum, germanyum, schottky vb. türleri bulunan diyot, sadece bir yönde akım geçiren bir devre elemanıdır. LED (light emitting diode) elektrik enerjisini ışığa dönüştürür. Elektrik sinyallerini kuvvetlendirici veya anahtar olarak da transistör kullanılır [63]. Entegre, birçok devre elemanının bir araya getirilerek karmaşık işlevlerin gerçekleştirildiği bileşenlerdir. Jumper'lar, belirli bağlantıların geçici olarak yapılması gerektiğinde kullanılmaktadır.


Bu çalışmada kullanılan ve çeşitli elektronik devre elemanlarının görüntülerinden oluşan veri seti iki veri setinin birleştirilmesi ile oluşturulmuştur. İlk veri seti için 10 adet direnç, 5 adet diyot, 4 adet entegre, 6 adet jumper, 10 adet kondansatör, 6 adet LED ve 4 adet transistörün resmi yedi farklı arka planda bir mobil telefon kullanılarak çekilmiştir. Daha sonra çekilen görüntüler 500x500 piksel boyutunda ve elektronik

devre elemanını içerecek şekilde kırılmıştır. Beyaz arka planda çekilen elektronik devre elemanlarından örnek görüntüler Şekil 4.1'de gösterilmiştir.




Şekil 4.1. İlk veri setindeki elektronik devre elemanlarının örnek görüntüleri a) direnç, b) diyot, c) entegre, d) jumper, e) kondansatör, f) LED, g) transistör.

Elektronik devre elemanlarının görüntülerini farklı arka planlarda çekerek görüntü çeşitliliği elde edilmeye çalışılmıştır. Farklı arka planlarda ve koşullarda elektronik devre elemanlarının nasıl görüldüğü yansıtılmak istenmiştir. Yedi farklı arka plan kullanılmıştır. Bunlar beyaz kağıt, mavi kağıt, sarı kağıt, tahta, breadboard, bakır plakette ve delikli plakettir. Şekil 4.2’de bir direncin farklı arka planlarda elde edilen görüntüleri gösterilmektedir.




Şekil 4.2. Kullanılan yedi farklı arka plan a) beyaz kağıt, b) mavi kağıt, c) sarı kağıt, d) tahta, e) breadboard, f) bakır plaketa, g) delikli plaketa.

Kullanılan yedi farklı arka plan ile 70 adet direnç, 35 adet diyot, 28 adet entegre, 42 adet jumper, 70 adet kondansatör, 42 adet LED ve 28 adet transistör görüntüsü elde edilmiştir. Toplam görüntü miktarını artırmak için Shorten ve Khoshgoftaar'ın çalışmalarında [64] belirtilen geometrik dönüşümler ile veri artırma yöntemlerine benzer şekilde görüntüler 90° döndürülerek, parlaklık seviyeleri %50 artırılarak ve parlaklık seviyeleri %50 azaltılarak yeni görüntüler oluşturulmuştur. Şekil 4.3'te görüntü miktarını artırmak için uygulanan işlemler sonucu elde edilen görüntüler gösterilmiştir. Bu işlemden sonra ilk veri setinde toplam 280 adet direnç, 140 adet diyot, 112 adet entegre, 168 adet jumper, 280 adet kondansatör, 168 adet LED ve 112 adet transistör görüntüsü oluşmuştur.



Şekil 4.3. Görüntü miktarını artırmak için uygulanan işlemler a) orijinal görüntü, b) 90° döndürülmüş hali, c) parlaklık seviyesinin artırılmış hali, d) parlaklık seviyesinin azaltılmış hali.

Kullanılan ikinci veri seti Neto [65] tarafından sunulmuştur. Bu veri seti direnç, entegre, kondansatör ve transistör görüntülerinden oluşmaktadır. Bu veri setinden [65] 1000'er adet direnç, entegre, kondansatör ve transistör görüntüsü alınarak kullanılmıştır. Şekil 4.4'de bu veri setine ait örnek görüntüler gösterilmektedir.




Şekil 4.4. İkinci veri setindeki elektronik devre elemanlarının örnek görüntüleri a) direnç, b) entegre, c) kondansatör, d) transistör [65].


İki veri setinin birleştirilmesi sonucunda toplamda 5260 adet elektronik devre elemanı görüntüsü elde edilmiştir. Bu görüntülerin tamamı sınıflandırma işleminde tek bir veri seti olarak kullanılmıştır. Toplam 5260 görüntü içerisinde elektronik devre elemanlarının dağılımı Çizelge 4.1'de belirtildiği gibidir. Veri setine ait istatistiksel bilgilerde Şekil 4.5'de ve Çizelge 4.2'de verilmektedir. Tasarlanan ESA kullanılarak yapılan sınıflandırma işlemlerinde bu görüntülerin %70'i eğitim, %15'i doğrulama ve %15'i test için kullanılmıştır.

Çizelge 4.1. Kullanılan veri setindeki elektronik devre elemanlarının toplam sayısı.

	Direnç	Diyot	Entegre	Jumper	Kondansatör	LED	Transistor
Toplam adet	1280	140	1112	168	1280	168	1112



(a)



(b)

Şekil 4.5. Kullanılan veri setine ait bilgiler a) dosya boyutunun dağılımı, b) çözünürlük dağılımı.


Çizelge 4.2. Görüntülerin renklerine göre ortalama değerleri ve standart sapma değerleri.

	Kırmızı (R)	Yeşil (G)	Mavi (B)
Ortalama (μ)	0.7467	0.7610	0.7522
Standart sapma (σ)	0.3425	0.3190	0.3295

Ayrıca kullanılan veri setindeki görüntülere Bölüm 4.3 de anlatıldığı gibi farklı seviyelerde gürültü eklenerek 4 adet yeni veri seti oluşturulmuş ve bu veri setlerine de sınıflandırma işlemi uygulanmıştır.

4.2. TASARLANAN EVRİŞİMLİ SİNİR AĞI

Bu çalışmada elektronik devre elemanlarının görüntülerini sınıflandırmak için bir evrişimli sinir ağı tasarlanmıştır. Tasarlanan ESA'nın giriş parametreleri 200x200 piksel boyutunda bir görüntüye göre ayarlanmıştır. Genel olarak 3 adet evrişim (convolution), 3 adet maksimum havuzlama (max pooling) ve 2 adet tam bağlantı katmanından (dense) oluşmaktadır. İlk evrişim katmanında 3x3 boyutlarında 8 filtre kullanılmıştır. İkinci evrişim katmanında 3x3 boyutlarında 16 filtre kullanılmıştır. Üçüncü evrişim katmanında da yine 3x3 boyutlarında 16 filtre kullanılmıştır. Evrişim katmanlarının tamamında aktivasyon fonksiyonu olarak ReLU kullanılmıştır. Her evrişim katmanından sonra 2x2 boyutlarında filtre ile maksimum havuzlama işlemi uygulanmıştır. Son maksimum havuzlama katmanından sonra düzleştirme yapılmıştır. İlk tam bağlantı katmanından önce 0.5 olasılıklı bir düşürme (dropout) katmanı bulunmaktadır. İlk tam bağlantı katmanında 32 adet nöron bulunmaktadır. Çıkış olan ikinci tam bağlantı katmanında ise 7 adet nöron bulunmaktadır. Direnç, diyot, entegre, jumper, kondansatör, LED, transistör olarak 7 çeşit sınıf olduğu için çıkış katmanında 7 adet nöron bulunmaktadır. Ayrıca çıkış katmanında aktivasyon fonksiyonu olarak softmax kullanılmıştır. Tasarlanan ESA Şekil 4.6'de gösterilmektedir.



Şekil 4.6. Tasarlanan evrişimli sinir ağı.

4.3. GAUSS GÜRÜLTÜSÜ VE VERİ SETİNDEKİ GÖRÜNTÜLERE GÜRÜLTÜ EKLENMESİ

İstatistiksel bir gürültü türü olan Gauss gürültüsü, adını istatistik ve olasılık teorisi alanlarına önemli katkılarda bulunan Alman matematikçi ve fizikçi Carl Friedrich Gauss'tan almıştır. Normal dağılım veya Gauss dağılımı olarak bilinen bir olasılık dağılımına karşılık gelen Gauss gürültü modelleri uzaysal ve frekans alanındaki


matematiksel izlenebilirliđi nedeniyle sıklıkla kullanılmakta ve uygun analitik özellikleri nedeniyle karar teorisinde, örüntü tanımada ve genel olarak istatistikte önemli bir rol oynamaktadır. Gauss gürültüsü görüntülerde aydınlatma azlığından yada yüksek sıcaklıktan dolayı oluşan sensör gürültüsünden ve elektronik devre gürültüsünden oluşmaktadır [66,67].

Gauss gürültüsünün hesaplanmasında kullanılan olasılık yoğunluk fonksiyonu [68] Eşitlik 4.1 gösterilmektedir. Eşitlikteki μ ortalamayı, σ ise standart sapmayı ifade etmektedir.

$$f_x(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (4.1)$$

Gauss gürültüsü bir görüntüye uygulandığında piksel değerleri deđişikliğe uğrar ve gürültü dediğimiz renk deđişiklikleri oluşur. Standart sapma ve ortalama deđerlerinin deđişmesi görüntünün piksel deđerlerinin deđişmesini etkilemektedir. Piksel deđerlerinin pozitif ve negatif yönde daha fazla deđişmesini standart sapmanın artması etkilerken ortalamanın artması bütün piksel deđerlerinin aynı düzeyde artmasına neden olmaktadır [69].

Gürültü seviyesinin sınıflandırmaya etkisini ölçebilmek için kullanılan veri setindeki görüntülere Gauss gürültüsü eklenerek 4 adet yeni veri seti oluşturulmuştur. Bu 4 veri setinin birbirinden farkı farklı seviyelerde gürültüye sahip görüntülerden oluşmalarıdır. Bu veri setleri oluşturulurken gürültü ortalama deđer (μ) hepsi için 0 kabul edilmiştir ancak standart sapma deđer (σ) her biri için ayrı olarak 0.5, 1.0, 1.5 ve 2.0 kabul edilmiştir. Şekil 4.7'de veri setlerinde bulunan farklı seviyelerde gürültülere sahip görüntüler gösterilmektedir.



Şekil 4.7. Farklı seviyelerde Gauss gürültüsüne sahip görüntüler a) $\mu=0$ $\sigma=0.5$, b) $\mu=0$ $\sigma=1.0$, c) $\mu=0$ $\sigma=1.5$, d) $\mu=0$ $\sigma=2.0$.

4.4. KULLANILAN WEB KAMERA

Web kamera terimi çoğunlukla bilgisayarlar ile kullanılan bir video kamerasını ifade eder. Web kamerası genellikle bir bilgisayara veya dizüstü bilgisayarın üst kısmına takılan, USB (universal serial bus) vb. bir bağlantı noktası ile bilgisayara bağlanan küçük bir cihazdır. Bu kameralar video görüşmeleri yapmak, video kaydetmek veya çevrimiçi konferanslara katılmak gibi çeşitli amaçlarla kullanılırlar. Web kameraları profesyonel güvenlik kameralarından daha ucuz ve kullanımı daha kolaydır fakat çözünürlüğü daha düşüktür. Küçük gözetleme sistemleri, insan-robot etkileşimi ve akıllı evler gibi uygulamalar için idealdirler [70].

Hem kamera uygulamalarının hemde çevrimiçi bilgi paylaşımının bir uzantısı olarak görülebilecek olan web kameraları bilginin ağ ortamında dağıtımı ile coğrafi sabitliği

birleřtirir. Televizyon ile video daha uzun sredir kullanılmak da ve web kameralar bunlara gre daha yeni bir teknolojidir fakat hızlı ilerleme kaydetmiřtir [71, 72].

Bu alıřmada Őekil 4.8’de gsterilen 5.0 mega piksel USB 2.0 zellikli web kamerası kullanılarak 20 adet elektronik devre eleamnının grnts ekilmiřtir. ekilen bu grntlerin orjinallerinin ve grlt eklenmiř hallerinin hangi sınıfa ait olduėu yani grnt zerinde hangi devre elemanı olduėu tahmin edilmiřtir. Web kamerası ile ekilen rnek orjinal grntler Őekil 4.9’da gsterilmektedir. Dřk znrlkl bir web kamerasının tercih edilme nedeni tasarlanan ESA’nın dřk znrlkl grntlerdeki performansını test etmek iindir.



Őekil 4.8. Kullanılan web kamera.



(a)

(b)

(c)

Őekil 4.9. Web kamera ile ekilen elektronik devre elemanlarının grntleri a) dire, b) entegre, c) kondansatr.

BÖLÜM 5

DENEYSEL ÇALIŞMALAR

Bu çalışmada elektronik devre elemanlarının görüntüleri tasarlanan ESA ile sınıflandırılmıştır. Sınıflandırma işlemi hem orijinal görüntülere hemde gürültülü görüntülere uygulanmış ve sonuçlar değerlendirilmiştir. Tasarlanan ESA diğer modeller ile hem elde edilen doğruluk değerlerine göre hemde eğitim sürelerine göre karşılaştırılmıştır. Ayrıca web kamerası ile çekilen elektronik devre elemanlarının görüntüleri tasarlanan ESA ile sınıflandırılmış ve tasarlanan ESA'nın performansı değerlendirilmiştir. Bütün deneyler i7 2.80 GHz işlemci ve 16 GB RAM'e sahip bir bilgisayarda gerçekleştirilmiştir. İlgili kodlar Python dili ile yazılmış ve TensorFlow ile Keras kütüphaneleri kullanılmıştır.

5.1. ORJİNAL VE GÜRÜLTÜLÜ ELEKTRONİK DEVRE ELEMANLARI GÖRÜNTÜLERİNİN SINIFLANDIRILMASI


Deneysel çalışmaların ilkinde, Bölüm 4.3' de tasarım ayrıntıları verilen evrişimli sinir ağı kullanılarak orijinal ve gürültülü elektronik devre elemanları görüntüleri sınıflandırılmıştır. Giriş görüntü boyutu 200x200 piksel, çıkış sayısı 7, epok sayısı 20 ve epok başına adım sayısı 120 olarak kabul edilmiştir. Veri setindeki görüntülerin %70'i eğitim, %15'i doğrulama ve %15'i test için kullanılmıştır. Bu ayırım yazılım yardımıyla görüntüleri rastgele seçerek yapılmıştır. Elde edilen doğruluk değerleri Çizelge 5.1'de gösterilmektedir. Eğitim (train) ve doğrulama (validation) işlemlerine ait doğruluk-epok (accuracy-epoch) grafikleri ve kayıp-epok (loss-epoch) grafikleri de Şekil 5.1, Şekil 5.2, Şekil 5.3, Şekil 5.4, Şekil 5.5 gösterilmektedir.

Elde edilen doğruluk değerleri incelendiğinde hem orijinal görüntülerde hemde gürültülü görüntülerde eğitim doğruluğu, doğrulama doğruluğu ve test doğruluğundan daha fazladır. Doğrulama doğruluğu da test doğruluğundan daha fazladır. Ayrıca,


Gauss gürültüsünün standart sapma (σ) değeri arttıkça eğitim doğruluk değerinin düştüğü görülmektedir. Standart sapma (σ) değeri 1.0 ve üzeri olduğunda doğrulama ve test doğruluk değerleri benzer sonuçlar vermektedir.

Çizelge 5.1. Tasarlanan ESA'nın farklı gürültü seviyeleri için doğruluk değerleri

	Orijinal	$\mu=0$ $\sigma=0.5$	$\mu=0$ $\sigma=1.0$	$\mu=0$ $\sigma=1.5$	$\mu=0$ $\sigma=2.0$
Eğitim doğruluğu	0.9929	0.9896	0.9853	0.9717	0.9684
Doğrulama doğruluğu	0.9226	0.9074	0.8580	0.8491	0.8542
Test doğruluğu	0.9139	0.8898	0.8354	0.8430	0.8329




(a)




(b)

Şekil 5.1. Orjinal görüntüler a) doğruluk-epok grafiği b) kayıp-epok grafiği.




(a)




(b)

Şekil 5.2. Gürültülü görüntüler ($\mu=0$ $\sigma=0.5$) a) doğruluk-epok grafiği b) kayıp-epok grafiği.




(a)




(b)

Şekil 5.3. Gürültülü görüntüler ($\mu=0$ $\sigma=1.0$) a) doğruluk-epok grafiği b) kayıp-epok grafiği.




(a)




(b)

Şekil 5.4. Gürültülü görüntüler ($\mu=0$ $\sigma=1.5$) a) doğruluk-epok grafiği b) kayıp-epok grafiği.



(a)



(b)

Şekil 5.5. Gürültülü görüntüler ($\mu=0$ $\sigma=2.0$) a) doğruluk-epok grafiği b) kayıp-epok grafiği.


5.2. TASARLANAN EVRİŞİMLİ SİNİR AĞININ DİĞER MODELLER İLE KARŞILAŞTIRILMASI

Tasarlanan ESA, orijinal elektronik devre elemanları görüntüleri kullanılarak AlexNet [61] ve VGG-11 [62] ile karşılaştırılmıştır. Deney giriş, çıkış ve epok değerleri Bölüm 5.1 deki deneyle aynı olacak şekilde belirlenmiştir. Elde edilen doğruluk değerleri Çizelge 5.2’de gösterilmektedir. AlexNet [61] ve VGG-11 [62]’in doğruluk-epok grafikleri ve kayıp-epok grafikleri de Şekil 5.6 ve Şekil 5.7 gösterilmektedir.


Elde edilen doğruluk değerleri incelendiğinde bütün modeller için eğitim doğruluğu, doğrulama doğruluğu ve test doğruluğundan daha fazladır. Doğrulama doğruluğu da test doğruluğundan daha fazladır. En düşük doğruluk değerlerine AlexNet [61]’in sahip olduğu görülmektedir. VGG-11 [62] en yüksek eğitim doğruluk değerine sahiptir ve tasarlanan ESA en yüksek doğrulama ve test doğruluk değerlerine sahiptir.

Çizelge 5.2. ESA modellerinin doğruluk değerleri.

	Tasarlanan ESA	AlexNet [61]	VGG-11 [62]
Eğitim doğruluğu	0.9929	0.8465	0.9964
Doğrulama doğruluğu	0.9226	0.8276	0.9163
Test doğruluğu	0.9139	0.8253	0.9088




(a)



(b)

Şekil 5.6. Orijinal görüntüler AlexNet [61] a) doğruluk-epok grafiği b) kayıp-epok grafiği.



Şekil 5.7. Orjinal görüntüler VGG-11 [62] a) doğruluk-epok grafiği b) kayıp-epok grafiği.

Çizelge 5.3’de tasarlanan ESA, AlexNet [61] ve VGG-11 [62]’in toplam parametre sayıları, ortalama eğitim süreleri ve tek bir görüntü için hesaplanan test süresi verilmektedir. Bir ESA’da katmanlardaki filtre sayısı arttıkça toplam parametre sayısı da artmaktadır. Toplam parametre sayısı arttıkça da eğitim ve test süresi artmaktadır. Tasarlanan ESA’nın toplam parametre sayısı, ortalama eğitim süresi ve tek bir görüntü için hesaplanan test süresi diğer modellere göre daha düşüktür.

Çizelge 5.3. ESA modellerinin toplam parametre sayıları ve ortama eğitim süreleri

	Toplam parametre sayısı	Ortalama eğitim süresi (dk)	Bir görüntünün test süresi (sn)
Tasarlanan ESA	274,823	10	0.15
AlexNet [61]	46,781,191	50	0.25
VGG-11 [62]	101,532,039	250	0.64

5.3. WEB KAMERASINDAN ELDE EDİLEN ELEKTRONİK DEVRE ELEMANLARI GÖRÜNTÜLERİNİN SINIFLANDIRILMASI

Bir web kamerasından elde edilen yirmi adet görüntü tasarlanan ESA kullanılarak sınıflandırılmıştır. Görüntülerden on tanesi direnç, beş tanesi entegre ve beş tanesi de kondansatör görüntüsüdür. Sınıflandırma işlemi hem orjinal görüntülere hemde sonradan gürültü eklenen görüntülere ayrı ayrı uygulanmıştır. Sınıflandırma işleminde kullanılan ESA orjinal görüntüler ile eğitilmiştir. Sınıflandırma sonuçları Çizelge

5.4'de gösterilmektedir. Orjinal görüntülerde tasarlanan ESA 18 tane görüntüyü doğru sınıflandırıp, 2 tane direnç görüntüsünü kondansatör olarak yanlış sınıflandırmıştır. Bu durumda orjinal görüntüler için elde edilen başarı oranı %90'dır.

Standart sapma değeri 0.5 olan gürültülü görüntülerden 18 tane görüntüyü doğru sınıflandırıp, 2 tane entegre görüntüsünü diyot olarak yanlış sınıflandırmıştır. Bu durumda standart sapma değeri 0.5 olan gürültülü görüntüler için elde edilen başarı oranı %90'dır.

Standart sapma değeri 1.0 olan gürültülü görüntülerden 15 tane görüntüyü doğru sınıflandırıp, 1 tane entegre görüntüsünü diyot ve 4 tane entegre görüntüsünü kondansatör olarak yanlış sınıflandırmıştır. Bu durumda standart sapma değeri 1.0 olan gürültülü görüntüler için elde edilen başarı oranı %75'dir.

Standart sapma değeri 1.5 olan gürültülü görüntülerden 14 tane görüntüyü doğru sınıflandırıp, 1 tane direnç görüntüsünü ve 5 tane entegre görüntüsünü kondansatör olarak yanlış sınıflandırmıştır. Bu durumda standart sapma değeri 1.5 olan gürültülü görüntüler için elde edilen başarı oranı %70'dir.

Standart sapma değeri 2.0 olan gürültülü görüntülerden 15 tane görüntüyü doğru sınıflandırıp, 5 tane entegre görüntüsünü kondansatör olarak yanlış sınıflandırmıştır. Bu durumda standart sapma değeri 2.0 olan gürültülü görüntüler için elde edilen başarı oranı %75'dir.

Çizelge 5.4. Web kamerası ile elde edilen görüntülerin sınıflandırma sonuçları.

	Direnç					Entegre					Kondansatör					Başarı Oranı					
	1	2	3	4	5	6	7	8	9	10	1	2	3	4	5		1	2	3	4	5
Orjinal	D	D	D	D	D	Y	D	Y	D	D	D	D	D	D	D	D	D	D	D	D	%90
$\mu=0$ $\sigma=0.5$	D	D	D	D	D	D	D	D	D	D	D	Y	Y	Y	D	D	D	D	D	D	%90
$\mu=0$ $\sigma=1.0$	D	D	D	D	D	D	D	D	D	D	Y	Y	Y	Y	Y	D	D	D	D	D	%75
$\mu=0$ $\sigma=1.5$	D	D	D	D	D	D	D	Y	D	D	Y	Y	Y	Y	Y	D	D	D	D	D	%70
$\mu=0$ $\sigma=2.0$	D	D	D	D	D	D	D	D	D	D	Y	Y	Y	Y	Y	D	D	D	D	D	%75

Tasarlanan ESA orjinal görüntüler ile eğitilmiş ve gürültülü görüntüler üzerinde de test edilmiştir. Standart sapma değeri 1.0, 1.5 ve 2.0 olan gürültülü entegre görüntülerinin tamamında yanlış sınıflandırma yapılmıştır yani gürültü seviyesi fazlaştığında entegre görüntülerinden elde edilen sonuçlar olumsuz etkilenmiştir.

BÖLÜM 6

SONUÇLAR VE DEĞERLENDİRME

Bu çalışmada elektronik devre elemanları sınıflandırılmıştır. Bunun için hem orjinal hemde yapay olarak gürültü eklenmiş görüntüler kullanılmıştır. Tasarlanan ESA ile yapılan sınıflandırma sonuçları hem orjinal hemde gürültülü görüntüler için ayrı ayrı değerlendirilmiştir. Orijinal görüntüler kullanılarak yapılan sınıflandırma işleminde eğitim doğruluğu 0.9929 olarak hesaplanmıştır. Bu doğruluk değeri gürültü seviyesi arttıkça bir miktar azalmaktadır. Ayrıca standart sapma değeri 1.0 ve üzeri olan gürültülü görüntülerden elde edilen doğrulama ve test doğruluk değerleri birbirlerine yakın çıkmıştır ancak orjinal görüntülerden elde edilen değerlerden bir miktar azdır. Gürültü seviyesinin sınıflandırma sonuçlarını olumsuz etkilediği anlaşılmaktadır.

Tasarlanan ESA, önceden geliştirilmiş AlexNet [61] ve VGG-11 [62] evrişimli sinir ağı modelleri ile karşılaştırılmıştır. Karşılaştırma işlemi için orjinal görüntüler kullanılmıştır. Karşılaştırma sonuçları incelendiğinde AlexNet [61]'un en düşük doğruluk değerlerine sahip olduğu görülmektedir. VGG-11 [62] en yüksek eğitim doğruluk değerine ve tasarlanan ESA da en yüksek doğrulama ve test doğruluk değerlerine sahiptir ancak bu iki modelin doğruluk değerleri birbirlerine yakındır. VGG-11 [62]'in eğitim süresi ve tek bir görüntü için hesaplanan test süresi ise tasarlanan ESA dan daha fazladır. Bu durum tasarlanan ESA'nın tercih edilebilirliğini artırmaktadır.

Ayrıca bir web kamerası ile çekilen yirmi adet elektronik devre elemanı görüntüsü tasarlanan ESA ile sınıflandırılmıştır. Sınıflandırma işlemi hem orijinal hemde gürültü eklenmiş görüntülere uygulanmıştır. Orijinal görüntülerden elde edilen başarı oranı %90, farklı seviyelerde gürültü içeren görüntülerden elde edilen başarı oranları %90, %75, %70 ve %75 olmuştur. Sınıflandırma işleminde kullanılan ESA orjinal

görüntüler ile eğitilmesine rağmen gürültülü görüntüleri de sınıflandırmada başarılı olmuştur.

Gelecek çalışmalarda elektronik devre elemanlarının çeşitliliği ve görüntü miktarı artırılarak daha kapsamlı çalışmalar yapılabilir. Farklı gürültü çeşitleri görüntülere uygulanarak sınıflandırma işlemine etkisi değerlendirilebilir.

KAYNAKLAR

1. Petrou, M. and Petrou, C., “Image processing: the fundamentals, 2nd ed.”, **Wiley John Wiley & Sons Ltd.**, Singapore, 1 (2010).
2. Solomon, C. and Breckon, T., “Fundamentals of digital image processing”, **Wiley Blackwell John Wiley & Sons Ltd.**, 291 (2011).
3. Aggarwal, C. C., “Neural networks and deep learning: a textbook”, **Springer International Publishing AG**, Cham, 363 (2018).
4. Van Dop, E. R. and Regtien, P. P. L., “Multi-sensor recognition of electronic components”, **Machine Vision And Applications**, 12: 213–222 (2001).
5. Lefkaditis, D. and Tsirigotis, G., “Intelligent optical classification system for electronic components”, **Elektronika ir Elektrotechnika**, 2 (98): 10-14 (2010).
6. Salvador, R. C., Bandala, A. A., Javel, I. M., Bedruz, R. A. R., Dadios E. P. and Vicerra, R. R. P., “DeepTronic: an electronic device classification model using deep convolutional neural networks”, **IEEE 10th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM)**, Baguio City, Philippines, 1-5 (2018).
7. Wang, Y. J., Chen, Y. T., Jiang, Y. S. F., Horng, M. F., Shieh, C. S. and Wang, H. Y., “An artificial neural network to support package classification for smt components”, **3rd International Conference on Computer and Communication Systems**, Nagoya, Japan, 130-134 (2018).
8. Maliński, K. and Okarma, K., “A simplified classification of electronic integrated circuits packages based on shape descriptors”, **11th International Conference on Image Processing and Communications**, Bydgoszcz, Poland, (2019).
9. Li, J., Gu, J., Huang, Z. and Wen, J., “Application research of improved YOLO V3 algorithm in PCB electronic component detection”, **Applied Sciences**, 9 (18): 3750 (2019).
10. Huang, R., Gu, J., Sun, X., Hou, Y. and Uddin, S., “A rapid recognition method for electronic components based on the improved YOLO-V3 network”, **Electronics**, 8 (8): 825 (2019).
11. Xu, Y., Yang, G., Luo, J. and He, J., “An electronic component recognition algorithm based on deep learning with a faster SqueezeNet”, **Mathematical Problems in Engineering**, (2020).

12. Hu, X., Xu, J. and Wu, J., “A novel electronic component classification algorithm based on hierarchical convolution neural network”, *IOP Conf. Series: Earth and Environmental Science*, (2020).
13. Sun, X., Gu, J. and Huang, R., “A modified SSD method for electronic components fast recognition”, *Optik*, 205 (2020).
14. Lee, J. and Lee, W., “A new recognition and pose estimation of tiny electronic parts using principal component analysis and harris corner features”, *Journal of Electrical Engineering & Technology*, 15: 43-51 (2020).
15. Gao, S., Qiu, T., Huang, A., Wang, G. and Yu, J., “Electronic components detection for PCBA based on a tailored YOLOv3 network with image preprocessing”, *IEEE 17th International Conference on Automation Science and Engineering (CASE)*, Lyon, France, 1435-1440 (2021).
16. Sathiaselvan, M. A. M., Paradis, O. P., Taheri, S. and Asadizanjani, N., “Why is deep learning challenging for printed circuit board (PCB) component recognition and how can we address it?”, *Cryptography*, 5 (1): 9 (2021).
17. Günay, M., “Görüntü işleme yöntemleriyle temel devre elemanlarının sınıflandırılması”, Yüksek Lisans Tezi, *İnönü Üniversitesi Fen Bilimleri Enstitüsü*, Malatya, (2021).
18. Mordvintseva, Y. A. and Belitsky, A. A., “Training the haar cascade classifier in sorting radio-electronic components. automating the collection of images for teaching”, *IEEE Conference Of Russian Young Researchers in Electrical and Electronic Engineering (ElConRus)*, Moscow, Russia, 1019-1022 (2021).
19. Guo, C., Lv, X., Zhang, Y. and Zhang, M., “Improved YOLOv4-tiny network for real-time electronic component detection”, *Scientific Reports*, 11: 22744 (2021).
20. Wu, H., Lv, Q., Yang, J., Yan, X. and Xu, X., “Electronic component detection based on image sample generation”, *Soldering & Surface Mount Technology*, 34 (1): 1-7 (2022).
21. Lu, Y., Yang, B., Gao, Y. and Xu, Z., “An automatic sorting system for electronic components detached from waste printed circuit boards”, *Waste Management*, 137: 1-8 (2022).
22. Cheng, Y., Wang, A. and Wu, L., “A classification method for electronic components based on siamese network”, *Sensors*, 22(17): 6478 (2022).
23. Varna, D. and Abromavičius, V., “A system for a real-time electronic component detection and classification on a conveyor belt”, *Applied Sciences*, 12 (11): 5608 (2022).
24. Zhao, D., Xue, D., Wang, X. and Du, F., “Adaptive vision inspection for multi-type electronic products based on prior knowledge”, *Journal of Industrial Information Integration*, 27 (2022).

25. Zhao, E., Jiang, K., Li, B., Liu, X., Zeng, F., Chen, L., Zhang, H. and Zhu, Z., “Classification and utilization of waste electronic components based on triboelectric nanogenerator”, *Nanotechnology*, 33 (49) (2022).
26. Atik, I., “Classification of electronic components based on convolutional neural network architecture”, *Energies*, 15(7): 2347 (2022).
27. Zhou, L. and Zhang, L., “A novel convolutional neural network for electronic component classification with diverse backgrounds”, *International Journal of Modeling, Simulation, and Scientific Computing*, 13 (1) (2022).
28. Xia, Z., Gu, J., Zhang, K., Wang, W. and Li, J., “Research on multi-scene electronic component detection algorithm with anchor assignment based on k-means”, *Electronics*, 11 (4): 514 (2022).
29. Kaya, V. and Akgül, İ., “Classification of electronic circuit elements by machine learning based methods”, *6th International Conference on Advances in Natural & Applied Science Engineering*, Ağrı, Turkey, 136-140 (2022).
30. Chen, J., Bao, E. and Pan, J., “Classification and positioning of circuit board components based on improved YOLOv5 ”, *Procedia Computer Science*, 208: 613–626 (2022).
31. Starodubov, D., Danishvar, S., Ott, R., Abu Ebayyeh, A. A. R. M., Cummings, N. and Mousavi, A. “Printed circuit board inspection: fusion of optical and x-ray images (FOXi) for electronic components classification”, **IEEE Physical Assurance and Inspection of Electronics (PAINE)**, Huntsville, AL, USA, (2022).
32. Makwana, D., Sai Chandra Teja R. and Mittal, S., “PCBSegClassNet — a light-weight network for segmentation and classification of PCB component”, *Expert Systems with Applications*, 225 (2023).
33. Hozyń, S., “Convolutional neural networks for classifying electronic components in industrial applications”, *Energies*, 16(2): 887 (2023).
34. Muggleton, S., “Alan Turing and the development of artificial intelligence”, *AI Communications*, 27 (1): 3-10 (2014).
35. LeCun, Y., Bengio, Y. and Hinton, G., “Deep learning”, *Nature*, 521 (7553): 436–444 (2015).
36. Coşkun, M., Yıldırım, Ö., Uçar, A. and Demir, Y., “An overview of popular deep learning methods”, *European Journal of Technic*, 7 (2): 15-176 (2017).
37. Ayodele, T., “Machine learning overview”, *New Advances in Machine Learning*, edited by Yagang Zhang, *InTech*, Rijeka, Croatia, 9-16 (2010).
38. Mitchell, T. M., “The Discipline of Machine Learning”, Machine Learning Department technical report CMU-ML-06-108, *Carnegie Mellon University*, (2006).

39. Abraham, A., “Artificial neural networks”, Handbook of Measuring System Design, edited by Peter H. Sydenham and Richard Thorn, *John Wiley & Sons*, New York, 901-908 (2005).
40. İnternet: “What is a neural network?”, <https://www.ibm.com/topics/neural-networks>. (Erişim: 01 Ekim 2023).
41. İnternet: Kurama, V., “Feedforward neural networks: a quick primer for deep learning”, <https://builtin.com/data-science/feedforward-neural-network-intro>. (Erişim: 01 Ekim 2023).
42. Mijwel, M. M., “Artificial neural networks advantages and disadvantages”, *Mesopotamian Journal of Big Data*, 29-31 (2021).
43. Fukushima, K., “Neocognitron: a self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position”, *Biological Cybernetics*, 36: 193–202 (1980).
44. LeCun, Y. Bottou, L., Bengio, Y. and Haffner, P., “Gradient-based learning applied to document recognition”, *Proceedings of the IEEE*, 86 (11): 2278–2324 (1998).
45. O’Shea, K. and Nash, R., “An introduction to convolutional neural networks”, arXiv preprint arXiv:1511.08458v2, (2015).
46. Li, Z., Liu, F., Yang, W., Peng, S. and Zhou, J., “A survey of convolutional neural networks: analysis, applications, and prospects”, *IEEE Transactions on Neural Networks and Learning Systems*, 33 (12): 6999-7019 (2022).
47. Hadi, M. U., Qureshi, R., Ahmed, A. and Iftikhar. N., “A lightweight CORONA-NET for COVID-19 detection in X-ray images”, *Expert Systems With Applications*, 225 (2023).
48. Kamilaris, A. and Prenafeta-Boldú, FX., “A review of the use of convolutional neural networks in agriculture”, *The Journal of Agricultural Science*, 156 (3): 312-322, (2018).
49. Ajit, A., Acharya, K. and Samanta, A., “A review of convolutional neural networks”, *International Conference on Emerging Trends in Information Technology and Engineering*, Vellore, India, 1-5 (2020).
50. Yu, D., Wang, H., Chen, P. And Wei, Z., “Mixed pooling for convolutional neural networks”, *International Conference on Rough Sets and Knowledge Technology*, Shanghai, China, 364–375 (2014).
51. Bieder, F., Sandkühler, R. and Cattin, P. C., “Comparison of methods generalizing max- and average-pooling”, arXiv preprint arXiv:2103.01746v1, (2014).
52. Yani, M., Irawan, B. and Setiningsih, C., “Application of transfer learning using convolutional neural network method for early detection of terry’s nail”, *Journal*

of Physics: Conference Series, International Conference on Electronics Representation and Algorithm, Yogyakarta, Indonesia (2019).

53. Zafar, A., Aamir, M., Mohd Nawi, N., Arshad, A., Riaz, S., Alruban, A., Dutta, A.K. and Almotairi, S., “A comparison of pooling methods for convolutional neural networks”, *Applied Sciences*, 12 (17): 8643 (2022).
54. İnternet: Srivatsavaya, P., “Flatten Layer-Implementation, Advantage and Disadvantages”, <https://medium.com/@prudhviraju.srivatsavaya/flatten-layer-implementation-advantage-and-disadvantages-0f8c4ecf5ac5>. (Erişim: 10 Ekim 2023).
55. Rguibi, Z., Hajami, A., Zitouni, D., Elqaraoui, A. and Bedraoui, A., “CXAI: explaining convolutional neural networks for medical imaging diagnostic”, *Electronics*, 11(11):1775 (2022).
56. Hao, W., Yizhou, W., Yaqin, L. and Zhili, S., “The role of activation function in CNN”, *2nd International Conference on Information Technology and Computer Application*, Guangzhou, China, 429-432 (2020).
57. Ding, B., and Qian, H. and Zhou, J., “Activation functions and their characteristics in deep neural networks”, *Chinese Control And Decision Conference*, Shenyang, China, 1836-1841 (2018).
58. Sharma, S., Sharma, S. and Athaiya, A., “Activation functions in neural networks”, *International Journal of Engineering Applied Sciences and Technology*, 4 (12): 310-316 (2020).
59. Kandel, I. and Castelli, M., “Transfer learning with convolutional neural networks for diabetic retinopathy image classification. a review”, *Applied Sciences*, 10 (6): 2021 (2020).
60. Mercioni, M. A. and Holban, S., “The most used activation functions: classic versus current”, *International Conference on Development and Application Systems*, Suceava, Romania, 141-145 (2020).
61. Krizhevsky, A., Sutskever, I., and Hinton, G. E., “Imagenet classification with deep convolutional neural networks”, *NIPS*, (2012).
62. Simonyan K., and Zisserman, A., “Very deep convolutional networks for large-scale image recognition”, *ICLR*, (2015).
63. İnternet: Erol, Y., “Elektronik devre elemanlarını tanıyalım”, <https://bilimgenc.tubitak.gov.tr/makale/kendimiz-yapalim-elektronik-devre-elemanlari>. (Erişim: 01 Ekim 2023).
64. Shorten, C., and Khoshgoftaar, T. M., “A survey on image data augmentation for deep learning”, *Journal of Big Data* 6, 60 (2019).

65. İnternet: Neto, J. L. A., “Basic electronic components: basic electronics components image dataset”, <https://www.kaggle.com/datasets/julioazancort/basic-electronic-components>. (Erişim: 13 Ocak 2023).
66. Cattin, P., “Image Restoration: Introduction to Signal and Image Processing”, *MIAC, University of Basel*, (2012).
67. Burger, W. and Burge, M. J., “Digital image processing: an algorithmic introduction using java, 2nd ed.”, *Springer-Verlag London*, 756 (2016).
68. Miller, S. L., Childers, D.G., “Probability and random processes: with applications to signal processing and communications”, *Elsevier Academic Press*, ABD, 57 (2004).
69. Ulu, A., “Renkli imgelerde gauss gürültüsü azaltma”, Yüksek Lisans Tezi, *Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü*, Trabzon, 8-9 (2018).
70. Feng, Z., Gao, C., Shen, T. and Lv, J., “Fast action detection with web camera”, *8th International Congress on Image and Signal Processing (CISP)*, Shenyang, China, 64-68 (2015).
71. Johansson, T., “The live outdoor webcams and the construction of virtual geography”, *Knowledge, Technology & Policy*, 21 : 181- 189 (2008).
72. Eliza,S,B. and Bradley, E. S. and Clarke, K. C., “ Outdoor webcams as geospatial sensor networks: challenges, issues and opportunities”, *Cartography and Geographic Information Science*, 38 (1): 3-19 (2011).

ÖZGEÇMİŞ

Kadir AHMED DJAMA 2020 yılında ISETS (Institut Supérieur d'Enseignement Technologique et des Sciences) Üniversitesi Bilişim Ağ Bakımı Bölümü'nde lisans eğitimini tamamladı. 2021 yılından beri Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü Mekatronik Mühendisliği Anabilim Dalında Yüksek Lisans eğitimine devam etmektedir.