



T.C.
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



KONVOLÜSYONEL SİNİR AĞLARI
KULLANILARAK ÇİÇEK TÜRLERİNİN
SINIFLANDIRILMASI

Elaf Sabri GHRAIRI

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

TEMMUZ-2019
KONYA
Her Hakkı Saklıdır

ÖZET

YÜKSEK LİSANS TEZİ

KONVOLÜSYONEL SİNİR AĞLARI KULLANILARAK ÇİÇEK TÜRLERİNİN SINIFLANDIRILMASI

Elaf Sabri GHRAIRI

**Selçuk Üniversitesi Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı**

Danışman: Doç. Dr. İsmail BABAÖĞLU

2019, 58 Sayfa

Jüri

**Doç. Dr. Barış KOÇER
Doç. Dr. İsmail BABAÖĞLU
Dr. Öğr.Üyesi Ahmet ÖZKİŞ**

Konvolüsyonel sinir ağları (Convolutional Neural Networks - CNN) yüz tanıma, hasta teşhisi, nesne algılama ve resim sınıflandırma gibi birçok alanda oldukça başarılı olarak kullanılmaktadır. CNN, görüntü veri kümeleri üzerinde sınıflandırma işlemi gerçekleştirir. Önce görüntü veri kümelerini sayısal dizilere çevirir, daha sonra bu sayısal verileri sınıflandırma işlemine tabi tutar. CNN’de oluşturulan model sınıflandırma başarısını doğrudan etkilemektedir, dolayısıyla her görüntü veri kümesine uygun bir CNN modeli tasarlamak gerekmektedir.

Bu tez çalışmasında, Kaggle web sitesinden 10 farklı çiçek türünün 210 görüntüsünden oluşan çiçek resimleri veri kümesi ele alınarak, bu çiçek resim veri kümesine uygun bir CNN modeli tasarımı önerilmiştir. Önerilen CNN modeli üzerinde çiçek resim veri kümesinin daha iyi başarı ile sınıflandırma işlemi gerçekleştirilmesi için çiçek resimleri üzerinde 4 farklı açıda yansıtma ve döndürme işlemleri ile veri kümesinin büyüklüğü artırılmıştır. Çiçek resimleri veri kümesi üzerinde hem renkli olarak hem de gri olarak sınıflandırma işlemi yapılmıştır. Önerilen CNN modeli üzerinde sınıflandırma başarıları 5-fold çapraz doğrulama ile elde edildikten sonra renkli veri kümesinin sınıflandırma sonuçları gri sınıflandırma sonuçları ile karşılaştırılmıştır. Deneysel sonuçlara göre önerilen CNN modeli renkli ve gri veri kümeleri için sırasıyla %84 ve %47 test sınıflandırma başarıları elde etmiştir. Elde edilen sınıflandırma test sonuçlarına göre önerilen CNN modeli renkli veri kümesi üzerinde daha iyi bir performans göstermiştir.

Anahtar Kelimeler: AlexNet, Geri yayılım, Konvolüsyonel Sinir Ağları, Derin Öğrenme, Görüntü Sınıflandırma.

ABSTRACT

MS THESIS

**CLASSIFICATION OF FLOWER SPECIES USING
CONVOLUTIONAL NEURAL NETWORKS**

Elaf Sabri GHRAIRI

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
SELÇUK UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN COMPUTER ENGINEERING**

Advisor: Assoc. Prof. Dr. İsmail BABAOĞLU

2019, 58 Pages

Jury

**Assoc. Prof. Barış KOÇER
Assoc. Prof. Dr. İsmail BABAOĞLU
Assist. Prof. Dr. Ahmet ÖZKIŞ**

Convolutional Neural Networks (CNN) is used very successfully in many areas such as face recognition, patient diagnosis, object detection and picture classification. The CNN performs the classification on the image data sets, first converts the image data sets to numerical arrays, then subject the numerical data to the classification process. The model created in CNN directly affects the success of the classification, so it is necessary to design a CNN model suitable for each image data set.

In this thesis, a flower image dataset consisting of 210 images of 10 different flower species from Kaggle website is considered and a CNN model design suitable for this flower image dataset is proposed. On the proposed CNN model, the data set was increased implementing 4 different angles of reflection and rotation on the flower images in order to achieve better classification results of the flower image data set. Flower images were graded both in color and gray on the dataset. The classification successes on the proposed CNN model were obtained by 5-fold cross validation and the results of the color data set were compared with the gray classification results. According to experimental results, the proposed CNN model achieved 84% and 47% test classification successes for color and gray data sets, respectively. According to the obtained classification test results, the proposed CNN model performed better on the color dataset.

Keywords: AlexNet, Back propagation, Convolutional Neural Networks, Deep Learning, Image Classification.

ÖNSÖZ

Bu çalışmada bana yardımcı olan ve bana rehberlik eden danışmanım Doç. Dr. İsmail BABAOĞLU'na ve Bilgisayar Mühendisliği Bölümü öğretim elemanlarına teşekkür ediyorum. Çalışma süresince beni desteklemiş olan aileme ve arkadaşlarıma şükranlarımı sunarım.

In this work, I would like to thank my advisor Assoc. Prof. Dr. İsmail BABAOĞLU who assisted and guided me, and teaching staff of The Computer Engineering Department. I would like to express my deep gratitude to those who have not given up on me, my family, my friends and all who have supported me throughout the study period.

Elaf Sabri GHRAIRI
KONYA-2019

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	viii
1. GİRİŞ	1
1.1. Tezin Amacı	4
1.2. Tezin Önemi	4
1.3. Tezin Yapısı	5
2. KAYNAK ARAŞTIRMASI	6
3. MATERYAL VE YÖNTEM.....	12
3.1. Veri Kümesi	12
3.1.1. Ön İşleme / Artırma	12
3.2. Sinir Ağı.....	13
3.2.1. Yapay Sinir Ağı	15
3.2.2. Derin Öğrenme	22
3.2.3. Evrimsel sinir ağı	24
3.3. Alexnet.....	34
3.4. Önerilen CNN Modeli	36
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	37
4.1. Parametre ve Değişkenlerin Ayarlanması.....	37
4.1.1. K-Fold Çapraz Doğrulama.....	38
4.2. Renkli Resimlerin Deneysel Sonuçları	38
4.3. Gri Resimlerin Deneysel Sonuçları	41
5. SONUÇLAR VE ÖNERİLER	45
5.1. Sonuçlar	45
5.2. Öneriler	46
KAYNAKLAR	47
ÖZGEÇMİŞ	50

SİMGELER VE KISALTMALAR

Simgeler

D : Boyut


W : Ağırlık

Kısaltmalar

AI	: Artificial Intelligence (Yapay Zeka)
BP	: BackPropagation (Geri Yayılım)
CNN	: Convolutional Neural Networks (Konvolüsyonel Sinir Ağları)
CSV	: Comma Separated Value (Virgül ile Ayrılmış Değer)
DL	: Deep Learning (Derin Öğrenme)
FNNs	: Feedforward Neural Networks (İleri Beslemeli Sinir Ağları)
GPU	: Graphics Processing Unit (Grafik İşleme Ünitesi)
MLP	: Multi Layer Perceptron (Çok Katmanlı Perceptron)
NLP	: Natural Language Processing (Doğal Dil İşleme)
NN	: Neural Networks (Sinir Ağları)
RGB	: Red, Green, and Blue (Kırmızı, Yeşil ve Mavi)
RL	: Reinforcement Learning (Güçlendirme Öğrenmesi)
RNNs	: Recurrent Neural Networks (Tekrarlayan Sinir Ağları)
SL	: Supervised Learning (Denetimli Öğrenme)
UL	: Unsupervised Learning (Denetimsiz Öğrenme)
ANN	: Artificial Neural Network (Yapay Sinir Ağları)

1. GİRİŞ

Konvolüsyonel Sinir Ağları (Convolutional Neural Networks - CNN) derin öğrenme algılayıcıların bir türüdür. CNN, derin öğrenme alanında genelde büyük veri kümelerinde sıkça kullanılan çok katmanlı yapay sinir ağıdır. Son dönemlerde derin öğrenme algoritmaları özellikle tıp ve görüntü işleme alanlarında sıkça kullanılmıştır ve görüntü işleme alanlarında genelde konvolüsyonel sinir ağları kullanılmaktadır. Konvolüsyonel sinir ağları, özellikleri saptamak için kullanılan “convolutional layer”, sisteme doğrusal olmayanlığın (non-linearity) tanıtılması için kullanılan “Non-Linearity Layer”, ağırlık sayısını azaltılması ve uygunluğunun kontrol edilmesi için kullanılan “Pooling (Downsampling) Layer”, özellik sayısının tek boyuta önüştürülmesi için kullanılan “Flattening Layer” ve sınıflama için kullanılan “Fully-Connected Layer” benzeri birçok katmandan oluşmaktadır. Temel olarak CNN, sınıflandırma sorununun çözümü için standart sinir ağı kullanır, ancak ayrıştırıcı bilgileri belirlemek ve bazı özellikleri tespit etmek amacıyla diğer katmanları kullanır. İlk konvolüsyonel sinir ağı 1988 yılında Yann LeCun tarafından ortaya atılan ve 1998'lere kadar iyileştirmeleri devam eden LeNet isimli mimaridir. LeNet ağında, alt katmanlar art arda yerleştirilmiştir ve ağ konvolüsyonel ve maksimum havuzlama katmanlarından oluşur. Sonraki üst katmanlar ise tamamen bağlı geleneksel çok katmanlı yapay sinir ağlarına karşılık gelmektedir. Konvolüsyonel sinir ağları modelinin mimarisi aşağıda (Şekil 1.1)'de verilmiştir.



Şekil 1.1. Konvolüsyonel sinir ağları mimarisi

Konvolüsyonel sinir ağları algoritmaları görüntü ve ses işleme alanı başta olmak üzere doğal dil işleme, biyomedikal gibi birçok farklı alanda uygulanmaktadır. Bu tez çalışmasında, CNN çiçek sınıflandırılması için kullanılmıştır.

Çiçeklerin iyi bir şekilde anlaşılması, rastlandığında yeni veya nadir türlerin belirlenmesine yardımcı olmak için esastır. Bu sınıflandırma, ilaç endüstrisinin gelişmesine yardımcı olacaktır. Tezde önerilen sistem, bilişim uzmanlarının yanı sıra botanikçiler, kampçılar ve doktorlar tarafından da kullanılabilir. Bu, konu hakkında daha fazla bilgi edinmek, en iyi eşleşen sonuçları bulmak ve buna göre arama yapmak için fotoğrafın metin yerine girdi olarak alınabileceği bir resim arama çözümü olarak genişletilebilir (Gurnani, 2017).

Yabani çiçek sınıflandırması, şekillerin yüksek çeşitliliği, renk dağılımı, aydınlatma durumu ve poz deformasyonu nedeniyle zorlu bir iştir. Gerçek uygulama senaryolarında zorlaşan durum, bir çiçek sınıfı için her zamanki gibi yalnızca birkaç deneme verisinin toplanabilmesidir. Örneğin, bir veya iki çiçek resmi cep telefonuyla çekildiğinde, kullanıcı gelecekte aynı kategorideki çiçekleri belirleyen bir çiçek tanıyıcıya sahip olmak ister. Sadece birkaç deneme örneği mevcut ise çiçeğin ön bölgesi genel olarak bilinmemektedir. Bu nedenle, çiçeklerin sınırlı eğitim örnekleriyle bölgeye özgü görüntü temsillerinden öğrenilebilen güçlü bir sınıflandırıcı gerekli olur. CNN'ler, görüntü sınıflandırma, rakam tanıma ve yaya algılama gibi birçok görüş tanıma görevi için etkili olduğu kanıtlanmış, zengin orta seviye görüntü temsillerini öğrenme yeteneğine sahiptir (Lin, 2015).

Çiçek türlerinin sınıflandırılması önemli bir görev olduğundan, sıklıkla araştırılmaktadır ve birçok farklı yaklaşım araştırmacılar tarafından geliştirilmiştir. Önceden, deforme edilebilir parça modelleri, yönlendirilmiş gradentlerin histogramı ve ölçek değişmez özellik dönüşümü gibi yöntemler, özellik çıkarımı, doğrusal sınıflandırıcılar ve nesne dedektörlerinde girdi oluşturmak amacı için kullanılmıştır. Daha sonra çalışma, manuel özellik mühendisliği kullanılarak bölümlendirme ve sınıflandırma üzerinde durulmuştur. Ancak günümüzde, en iyi performanslar CNN'ler ile sağlanmıştır. CNN'ler sağlamlık ihtiyacını yerine getirmiş ve manuel özelliklere duyulan ihtiyacı gidermiştir. CNN'ler, yapay sinir ağlarına benzerler ancak özellik mühendisliği gerektirmezler. Her bir nöron bazı girdiler alır, bir nokta ürünü yapar ve isteğe bağlı olarak doğrusal olmayan bir işlemle takip eder. Sonunda, CNN'ler ayrıca optimizasyon için en aza indirilecek olan bir kayıp fonksiyonuna sahiptir (Gurnani, 2017).

CNN'ler son yıllarda birçok görüntü sınıflandırma ve işleme görevinde bilgisayar doğruluğunu büyük ölçüde arttırmıştır. Bununla birlikte, daha geniş görüntü gruplarının çeşitli sınıflarla sınıflandırılması konusunda çok fazla çalışma yapılmış olsa da, dar kapsamdaki sınıflandırma problemleri daha az araştırılmıştır. Çiçek taksonomisi böyle

bir sorunun başlıca örneğidir - bitki örtüsü farklı ve çeşitli olsa da, temel konu aynıdır, bu yüzden görüntülerin çoğu hala özelliklerde büyük bir örtüşmeyi paylaşır (yani, çiçeklerin çoğunun yaprakları vardır ve geniş çapta aynı şekillidirler). Çiçekler rijit olmayan cisimlerdir ve görüntüden görüntüye farklı şekillerde deforme olabilirler. Daha genel olarak, taksonomi kendi başına ilginç bir görüntü sınıflandırma problemi; insanlar için bazı türler arasında doğru şekilde ayırım yapılması için önemli bir eğitim alır ve çoğu zaman çok özel morfolojik özellikler birbiriyle yakından ilişkili organizmaları birbirinden ayıran tek şeydir. Ayrıca, bu belirli özellikler, belirli bir bitki türünden diğerine tamamen farklı olabilir (örneğin, gövde uzunluğu - taç yaprağı şekli) (Mignot, 2016).

Konvolüsyonel sinir ağları ilk olarak Fukushima tarafından tanıtılmıştır ve daha sonra LeCunn ve ark. öğrenme için backpropagation algoritmasını kullanmıştır. Bu çalışmalar başarılı derin mimarilerin ilk örnekleridir. Seksenlerin ortasından beri kullanılmaktadırlar ve belirli alanlarda da ticari başarı elde etmişlerdir. LeCunn'un LeNet mimarileri, belge mektubu, sayı tespiti ve yüz tanıma gibi belirli görevlerde mükemmel performans göstermiştir. 2006 yılına kadar, çok özel görevler için tasarlanan CNN'ler dışında derin öğrenme için uygun araçların tasarlanmasında çok fazla bir başarı elde edilememiştir. O zamandan bu yana çok sayıda çalışma yapılmıştır ve her birinin kendi yararına sahip olduğu birçok yeni mimar mevcuttur. Özellikle denetlenmeyen özellik öğrenmesi için açgözlü katman bilge eğitim stratejisi büyük potansiyel göstermiştir. Derin denetimsiz öğrenme, büyük etiketli veri setlerine daha az dayanır ve bu nedenle transfer öğreniminde, örneğin eğitim ve test dağılımları arasında küçük farklılıklar olduğunda olağanüstü sonuçlar üretir. Bir örnek daha önce bulunmayan kategoriler hakkında bilgi yakalayabilmektir. Bazı çalışmalar, belirli bir veri kümesinden öğrenilen özelliklerin, tamamen farklı veri kümeleriyle denetimli ortamlarda bile kullanılabileceğini göstermiştir. Öte yandan, derin denetimli öğrenme mimarileri, özellikle derin evrimsel sinir ağları, çok sayıda etiketlenmiş veri ile denetlenen öğrenme görevlerine gelince olağanüstü performans göstermektedir.

CNN'ler, belge tanıma gibi belirli alanlara başarıyla uygulanmıştır. Son üç veya dört yıl boyunca, daha karmaşık vizyon temelli sınıflandırma problemleri konusunda olağanüstü performans gösteren CNN mimarilerini sunan makaleler yayınlanmıştır. Ciresan ve ark. NORB ve CIFAR-10 veri setlerinde en gelişmiş performansı göstermektedir. En dikkat çekici performans sonucu Krizhevsky ve ark. ImageNet 2012 sınıflandırma kriterlerinde, tamamen denetimli on katmanlı CNN modeliyle elde edilmiştir. Son geliştirmeler ile hatayı %26,1'den %15,3'e düşürmeyi başarmışlardır. O

zamandan bu yana, birçok yarışmayı kazanan AlexNets (ana yazarın ilk isminden türetilmiş) denilen genişlemelerle elde edilmiştir. ImageNet 2012 kıyaslama kriterinin daha derin ağ hata oranı kullanılması ile %6,5'e getirilmiştir (Karagöz, 2015).

1.1. Tezin Amacı

Son yıllarda, konvolüsyonel sinir ağları, görüntü işleme, yüz tanıma, hasta teşhisi, nesne algılama, ilaç vb. birçok alanda çok başarılı bir şekilde kullanılmıştır. Konvolüsyonel sinir ağları bir çeşit çok katmanlı sensördür ve görüntü verilerinden özellik çıkarma işlemini çok hızlı ve başarılı bir şekilde işler. Konvolüsyonel sinir ağlarında birden fazla gizli katman vardır. Bu katmanlara konvolüsyonel katmanlar denir.

Çiçeklerin tarımda, bahçe çiçeklerinde ve bitkilerde sınıflandırılması önemli bir araştırma konusudur. Genelde çiçeklerin sınıfları çiçeğin birkaç özelliği bilindikten sonra binlerce sayfalardan oluşan çiçek sınıfları anahtar kitabından öğrenmek araştırmacının saatlerce zamanını alacaktır, bu da araştırmacı için büyük bir problem oluşturmaktadır.. Bu tez çalışmasında konvolüsyonel sinir ağlarını ve çiçek türlerini sınıflandırarak bu sorunun önlenmesi amaçlanmaktadır. Konvolüsyonel sinir ağlarının, çiçeklerin sınıflandırılmasında büyük bir avantaj sağlaması, çiçeklerin çok hızlı ve başarılı bir şekilde sınıflandırılması ile zaman kaybının önlenmesi de sağlanacaktır.

1.2. Tezin Önemi

Konvolüsyonel sinir ağları yapay sinir ağlarına dayanan oldukça gelişmiş bir makine öğrenmesi yöntemidir. Yapay sinir ağlarında, sinir ağlarına verilmeden önce verilerin işlenmesi ve sayısal verilere dönüştürülmesi gerekir ve bu dönüşüm süreci çok yavaştır. Bu dezavantaj, konvolüsyonel sinir ağlarında ortadan kaldırılır ve görüntü işleme, alt katmanlarda çok kolay bir şekilde gerçekleştirilir. Bu nedenle birçok görüntü tanıma ve sınıflandırma işlemi yüksek performanslarla gerçekleştirilir.

Yapay sinir ağlarında çiçeklerin sınıflandırılması çok karmaşık ve zor bir süreç olabilir. Bu tez çalışmasının önemi, konvolüsyonel sinir ağları kullanarak on çiçek sınıfını çok hızlı ve başarılı bir şekilde sınıflandırmaktır. Çiçeklerin görüntü verileri Kaggle veri web sitesinden alınmıştır ve bu görüntüler belirli bir oranda eğitim ve test veri setlerine bölünmüştür. Eğitim verileri, konvolüsyonel sinir ağları modelinin eğitimi için kullanılmış ve test verileri modelin testi için kullanılmıştır. Bu tanıma sistemi, tarım,

bahçe çiçekleri ve bitkileri alanındaki birçok çiçek tanıma sisteminde kullanılabilir ve bu sisteme sınıf dışı bir çiçek verildiğinde, model veri kümesinde olmayan bu çiçeğin sınıflandırmasını gerçekleştirecektir.

1.3. Tezin Yapısı

Tezin organizasyonu şu şekilde düzenlenmiştir; 2. bölümde literatür çalışmaları sunulmaktadır. Bölüm 3, materyal ve yöntemleri sunmaktadır. Araştırma sonuçları ve tartışma 4. bölümünde açıklanmış, ardından sonuçlar ve öneriler 5. Bölümde sunulmuştur.



2. KAYNAK ARAŞTIRMASI

Bugüne kadar CNN modeli araştırmacılar tarafından hastalık teşhisi, yüz tanıma ve nesne tanıma gibi birçok sınıflandırma probleminde kullanılmıştır. Son yıllarda, CNN modeli ile ilgili yapılan çalışmalar bu bölümde incelenmiştir.

İnik, Ö. ve Ülker yaptıkları çalışmada, derin öğrenme modelleri ve konvolüsyonel sinir ağları hakkında detaylı bilgi vermişlerdir. Yazarlar çalışmada özellikle konvolüsyonel sinir ağı mimarisinin katmanları olan konvolüsyonel, havuzlama, ReLu, DropOut, tam bağlantılı ve sınıflandırma katmanı hakkında detaylı bilgiler vermişlerdir. Bu çalışmada ayrıca derin öğrenmede temel mimariler olarak kabul edilebilecek AlexNet, ZFNet, GoogLeNet, Microsoft RestNet ve RCNN mimarileri anlatılmıştır (İnik, 2017).

Büyükyılmaz yaptığı çalışmada, konvolüsyonel sinir ağı derin öğrenme algoritması tasarlayarak, Eimeria parazit türlerini otomatik olarak algılamışlar ve bunların hastalıklı olup olmadığını tespit etmişlerdir. Tasarlanan çok katmanlı sinir ağı ve konvolüsyonel sinir ağı sistemine giriş olarak tavuk ve tavşanlara ait Eimeria mikroskopik görüntüleri verilmiş, daha sonra bu hayvanlarda görüntülerine göre hastalığı tespit edilmiştir. Sistemin yazılım kısmında var olan OpenCV ve Keras gibi kütüphanelerden faydalanarak farklı modeller oluşturulmuş ve testler yapılmıştır. Elde edilen test sonuçlarına göre tavuk veri kümesi için %87.75 doğruluk oranıyla, tavşan veri kümesi için %78.42 doğruluk oranıyla hastalıklı hücreler sınıflandırmıştır (Büyükyılmaz, 2017).

Powell yaptığı çalışmada, sosyal sanal gerçeklik (SG) için bir kıvrımlı nöral ağlar (KNA) sistemi tasarlamıştır. Bu sistemin ilk adımında sosyal SG platformları tarafından uygulandığında, kullanıcılar arasındaki tacizi engelleme konusunda etkili bir araç olmaktadır, aynı zamanda KNA ile sosyal SG’de üretilen üç boyutlu bayağı görsel unsurları sınıflandırmak için de bir metot sunulmuştur. Sistemin test aşamasında %78 tutarlılık oranıyla ayıklamak için kullanılabilir bir sınıflandırma modeli üretmiştir (Powell, 2018).

Ergün yaptığı çalışmada, video verileri içindeki görsel kavramların arama ve geri getirme uygulamalarına yönelik bir sınıflandırma sistemi tasarlamıştır. Tasarlanan sistemde kelime kümesi yaklaşımı ve konvolüsyonel sinir ağları olarak iki görsel sınıflandırma yaklaşımı kullanılmış, kelime kümesi temsili ve konvolüsyonel sinir ağları aşamalarında optimizasyonlar yaparak, öğrenme algoritmalarının başarımları artırılmaya çalışılmıştır. Önerilen algoritmalar Oxford buildings ve Paris (Ergün, 2016) veri kümeleri

üzerinde test edilmiştir. Deneysel sonuçlara göre kelime kümesi temsili ve konvolüsyonel sinir ağları aşamalarında yapılan optimizasyonlar yüksek performans sergilemiştir (Ergün, 2016).

Yurdakul yaptığı çalışmada, konvolüsyonel yapay sinir ağları mimarisinde video semantik bölütlenmesine derinlik ve zaman bilgilerinin katkılarını araştırmak için bir sentetik ve bir gerçek RGBD video veri kümesi uygulamıştır. Deneysel sonuçlar, derinlik bilgisinin semantik bölütleme sonuçlarını geliştirdiğini ve zaman bilgisinden faydalanmanın daha yüksek kaliteli çıktı bölütlemeleriyle sonuçlandığını göstermektedir (Yurdakul, 2017).

Anwer yaptığı çalışmada, derin öğrenme CNN algoritmasını tıp alanında kullanmıştır. Anwer tez çalışmasında, göğüs kanseri teşhisi için derin öğrenme CNN tabanlı bir sistemi önermiştir. Önerilen CNN tabanlı sistemi Wisconsin UCI makine öğrenme deposundaki göğüs kanseri veri setleri üzerinde test etmiştir. Deneysel sonuçlara göre önerilen sınıflandırma tabanlı göğüs kanseri teşhis sistemi çok başarılı bir şekilde hasta teşhisi yapmıştır (Anwer, 2017).

Mignot ve Siegelman çalışmalarında 102 sınıfı bir resim veri kümesini sınıflandırmak için konvolüsyonel bir sinir ağı kullanmışlardır. Çalışmada orijinal görüntüler 32 x 32 piksel olacak şekilde yeniden boyutlandırılmış ve küçük bir konvolüsyonel ağı ve çeşitli veri büyütme stratejileri ile (rastgele kırpma, yansıtma) 0,61'lik göreceli olarak yüksek sınıflandırma doğruluğu elde edilmiştir. Ayrıca, son katmanları ince ayarlayarak önceden tanımlanmış daha derin bir mimari test edilmiş, ancak yüksek doğruluk elde edilememiştir. Naif otomatik taksonomi görevinin daha klasik görüntü tanıma görevlerinden hem zor hem de farklı olduğu sonucuna varılmıştır (Mignot, 2016).

Gurnani ve ark. çalışmalarında farklı çiçeklerin sınıflandırılması için derin bir öğrenme ağı geliştirmişlerdir. Bunun için Oxford üniversitesi'nden görsel geometri grubunun 102 çiçek kategorisinde 8189 çiçek verisini kullanmışlardır. Yazarların metodları temel olarak iki bölüme ayrılmaktadır; görüntü bölümlendirme ve sınıflandırma. Sınıflandırma amacıyla iki farklı konvolüsyonel sinir ağı mimarisi GoogleNet ve AlexNet'i karşılaştırmışlardır. Her iki mimaride de aynı hiper parametreleri koruyarak, GoogleNet'in Top-1 ve Top-5 doğruluğunun sırasıyla %47,15 ve %69,17 olduğunu, AlexNet'in ise Top-1 ve Top-5'in doğruluğunun %43,39 ve %68,68 olduğunu gözlemlemişlerdir. Bu sonuçlar, %0,98'lik rasgele sınıflandırma doğruluğuyla karşılaştırıldığında oldukça iyidir (Gurnani, 2017).

Lin ve ark. çalışmalarında, başka bir alanda yeni bir görev yapmak için geniş çaplı bir veri kümesinde (örneğin, ImageNet) önceden eğitilmiş CNN özelliklerini genellemeye / aktarmaya odaklanmışlardır. CNN özelliklerini başka alanlara uyarlayarak üstün sonuçlar elde edilmiş olmalarına rağmen çok az sayıda eğitim örneğiyle derin bir CNN'de ince ayar yapılması sorun olmaya devam etmektedir. Bu çalışmada, bir CNN'de ince ayar yapmak için eğitim örneklerini zenginleştirebilecek bir çerçeve önerilmektedir. Çalışmanın temel fikri, önceden eğitilmiş modelden benzer kalıpları hatırlamak ve bu geri kazanılmış görüntüleri ağına yeniden eğitilmesine dahil etmektir. Oxford 17 ve 102 kategori çiçek veri setleri üzerinde deneyler yapmışlardır. Deneysel sonuçlar, eğitim verilerinin zenginleştirilmesinin ince ayarlı ağına performansını iyileştirdiğini göstermektedir. Yazarların metodları ayrıca diğer modern yaklaşımlara göre üstün performans göstermektedir (Lin, 2015).

Nkemelu ve ark. bitki fidelerinin sınıflandırılmasında iki geleneksel algoritma olan destek vektör makinesi ve k-en yakın komşu ile derin öğrenme modellerinden CNN ile çalışmışlardır. 12 tür ve yaklaşık 960 fide için 4.275 farklı görüntü içeren bir veri kümesi kullanmışlardır. Konvolüsyonel sinir ağının diğer algoritmalarından daha başarılı olduğunu gözlemlemişlerdir. Çalışmanın, CNN verimini optimize etmek ve verimliliğini arttırmak için önemli bir potansiyele sahip olduğu bulunmuştur (Nkemelu, 2018).

Li ve ark. interstisyel akciğer hastalığı (ILD) ve akciğer görüntü yamalarının sınıflandırılmasında CNN'lerin performansını göztermişlerdir. Özelleştirdikleri CNN yapısı ile halka açık olan ILD veri kümesini kullanmışlardır. CNN modelinde 7x7 filtreli bir konvolüsyonel, 2x2 filtreli maxpooling ve 3 tamamen bağlı katman vardır. Önerilen tek evri katmanlı mimarileri başarılı sonuçlar elde etmiştir (Li, 2014).

Hershey ve ark. CNN'lerin görüntü performansındaki başarılarından ilham alarak CNN'nin ses performansındaki başarısını araştırmışlardır. 70M eğitici video veri kümesinin müziğini sınıflandırmak için, tam bağlantılı derin sinir ağları (DNN'ler), AlexNet, inception, VGG ve ResNet kullanılmıştır. Eğitim veri kümesinin boyutunun artırılmasının başarıyı bir dereceye kadar arttığını göstermişlerdir. Modellerin en iyi performansı ResNet-50 modeli tarafından sunulmaktadır (Hershey, 2017).

Yalçın ve Razavi, akıllı agrostasyonlardan toplanan görüntülerde bitki türlerinin sınıflandırılmasını önerdikleri bir CNN modeli ile sunmuşlardır. Önerilen mimari 5 katmanlı konvülasyon ve 3 tam bağlantı katmanlarından oluşmaktadır. Modellerde önceden eğitilmiş bir ağ kullanılmaktadır. Elde edilen sonuçlar destek vektörü makine sınıflandırıcısı ve LBP ve GIST gibi özellik tanımlayıcıları ile karşılaştırılmıştır. Diğer

algoritmalarla göre önerilen model %97.04 oranında bir başarıya ulaşmıştır (Yalçın, 2016).

Şeker ve ark. yaptıkları çalışmada, derin öğrenmenin tarihçesini, derin öğrenmede kullanılan yöntemleri ve derin öğrenmenin uygulama alanlarını anlatılmışlardır. Çalışmada ayrıca, son yıllarda derin öğrenmede kullanılan kütüphaneler ve derin öğrenme üzerine yoğunlaşan çalışma grupları hakkında da bilgiler verilmiştir. Çalışmanın amacı, hem araştırmacılara derin öğrenme konusundaki gelişmeleri anlatmak, hem de derin öğrenme ile çalışılacak muhtemel konuları göstermektir (Şeker, 2017).

Karagöz yaptığı çalışmada, derin mimarilerini uydu görüntülerine uygulamıştır, sistemin performansını ve uygunluğunu analiz etmiştir. Derin Konvolüsyonel sinir ağlarının başarısı çek okuma, el yazısı tanımlama ve yüz tanımlama gibi birçok örüntü tanıma probleminde kanıtlanmıştır. Karagöz, tezinde belirli bir derin evrimsel sinir ağı mimarisini seçmiş ve bu mimari denetlemeli öğrenmeyle eğitilmiştir. Deneysel sonuçlarına göre %90 ortalama kesinlik oranı elde etmiştir ve bu rakam uzaktan algılamada derin Konvolüsyonel sinir ağlarında umut verici olarak belirtilmiştir (Karagöz, 2015).

Zia yaptığı çalışmada, derinlik ve renk bilgisinin birleştirilmesi problemini geniş çapta araştırmıştır. Yazar, RGB bilgisi için bir 2-D CNN transfer öğrenme ve derinlik bilgisini kodlamak için 3-D Konvolüsyonel Sinir Ağı'nı kullanmıştır. Konvolüsyel sinir ağı ile daha iyi özellikler üretmiştir ve RGB-D nesnesi üzerinden iyi bir performansı sergilemiştir (Zia, 2016).

Ulu yaptığı çalışmada, kişi tanıma problemi için derin öğrenme ve metrik öğrenme tabanlı bir çözüm önermiştir. Bunun için şu anda bilinen en büyük kişi tanıma eğitim kümesi kullanılmıştır. Bu eğitim kümesi oldukça büyük olmasına rağmen, bir Konvolüsyonel sinir ağını sıfır ağırlıkları ile en başından itibaren eğitecek düzeyde değildir. Bu işlem için kullanılacak eğitim setlerinin büyüklüğünün en az milyon seviyesinde olması tavsiye edilmektedir. Bu nedenle ulu çalışmasında transfer eğitim metodu ile farklı alanlarda oldukça başarılı sonuçlar veren Konvolüsyonel sinir ağları modellerini kullanmıştır. Deneysel sonuçlarına göre başarılı sonuçlar elde etmiştir (Ulu, 2016).

Özdemir yaptığı çalışmada, sınıflandırma haritası oluşturmayı amaçlamıştır,. Hiperspektral veri kümelerinden, matematiksel biçimbilim dalına ait bir yaklaşım olan öznetelik Profilleri uygulayarak alan ve moment betimleyicileriyle her piksel için öznetelik vektörleri hesaplamıştır. Veri girdileri, piksele ait spektrum verisi, farklı

betimleyicilerden oluşturulan öznelik Profilleri ve bunların birleşimini de kapsayacak şekilde hazırlamıştır. Hiperspektral veri kümeleri beş farklı Konvolüsyonel Sinir Ağları'nda denenmiş ve derin öznelikleri çıkarılmıştır. Rasgele Orman sınıflandırıcılarıyla kontrollü olarak yapılan deneylerin sonuçlarında sayısal açıdan Pavia üniveritesi veri kümesinde büyük ilerlemeler görülmüş ve oluşturulan sınıflandırma haritalarının daha anlaşılır olması sağlanmıştır (Özdemir, 2016).

Abdulnabi yaptığı çalışmada, CNN'yi küçük boyuttaki veriler üzerinde çalıştırıp daha iyi bir sınıflandırma yapısını amaçlamıştır. çalışmasında sunulan CNN, bir çok katmandan oluşmaktadır. Birinci katmanda cümleler ikili tabandaki sayı sistemlerine dönüştürülmektedir. Bir sonraki katmanda cümlelerin özellikleri çıkarılmıştır. CNN ve yapay sinir ağı blokları cümlelerin özelliklerinin öğrenilmesini etkin bir hale getirmiştir. Elde edilen sonuçlara göre, CNN'in sayesinde sınıflandırma çok kısa sürmüştür ve anlaşılması zor olan cümlelerin sınıflandırılması mümkün olmuştur (Abdulnabi, 2016).

Bhandare ve ark. yaptıkları çalışmada, CNN algoritmasını açıklanmışlar ve algoritmanın ne tür sınıflandırma problemlerinde daha iyi sonuçlar üretebileceğini göstermişlerdir. Çalışmada, yüz tanıma, sahne etiketleme, görüntü sınıflandırması, aksiyon tanıma, insan pozlama tahmini ve belge analizi gibi problemlerin CNN'de nasıl çözülebilir olduğu gösterilmiştir. Ayrıca CNN'nin doğal dil işleme konuşma tanıma ve metin sınıflandırması alanında nasıl kullanıldığı anlatılmıştır (Bhandare, 2016).

Taşhan yaptığı çalışmada, konvolüsyonel sinir ağlarını veri depolama elemanları, hafıza birimleri ve çoklu çekirdek destekli mikro işlemci maliyetlerinin düşmesi için kullanılmıştır. Maliyet düşümünün yanında bu aygıtların birbiri ile uyumlu çalışması ve inter-net teknolojileri ile toplanan veriler ve bu verilerin işlenmesi için gelişmeye başlayan derin öğrenme teknikleri de göz önünde bulundurulmaktadır. Önerilen yöntem başarılı bir şekilde veri depolama elemanları, hafıza birimleri ve çoklu çekirdek destekli mikro işlemci tasarımında kullanılmıştır (Taşhan, 2017).

Mercan yaptığı çalışmada, göğüs radyografisini konvolüsyonel sinir ağları ile göğüs kanseri tespiti için kullanılmıştır. Konvolüsyonel sinir ağları tabanlı C++ dilinde kodlanan bir yazılım geliştirmiştir. Bu yazılım bir kütüphane şeklinde tasarlanıp ve konvolüsyonel sinir ağlarının farklı yapılarında çalışmasına yardımcı olmuştur. Bu yazılımın en büyük avantajı görüntülerden hızlı bir şekilde özellik çıkarım işlemini gerçekleştirmesidir. Geliştirilen yazılımın testi ve performansı piksel tabanlı ROC analizi ile gerçekleştirilmiş ve test aşamasında ortalama doğruluk, hassasiyet, özgünlük,

yüzdeleri hesaplanmıştır. Sonuç olarak %99.99 doğruluk, %59 hassasiyet, %99.99 özgünlük değerleri elde edilmiştir (Mercan, 2015).

Küçüksubaşı yaptığı çalışmada, otonom İnsansız Hava Araçlar (İHA)'lar ile görsel yapı denetiminde belirlenen konumların yeniden ziyaret edilebilmesi için bir karar destek aracı sunmuştur. Önceden eğitilmiş bir yapay sinir ağı'nın yeniden eğitilmesiyle, araç yüzey çatlaklarını tespit edip noktasal olarak belirlenen konumların denetim sırasında tekrar gözden geçirilebilmesi için görev planlamasında kullanımına yönelik bir yöntem sunmuştur. GPS erişimsiz ortamlarda otonom olarak gezinebilen dört pervaneli bir İHA sistemine entegre edilmiştir. Deneysel sonuçlara göre sistemin bina denetimi için GPS erişimsiz ortamlarda otonom seyrüseferi ve çatlak algılamayı gerçekleştirdiğini göstermiştir (Küçüksubaşı, 2017).

Kaptan yaptığı çalışmada, görüntü sınıflandırma ve doku giydirme tekniklerini tek bir sistemde çalıştırarak, insan faktörü olmadan çalışan bir mimari oluşturmuştur. Bu mimaride herhangi bir 3D modeline ihtiyaç duymadan otomatik çalışan görsel tabanlı doku giydirme gerçekleştirilmiştir. Mimaride derin öğrenmenin CNN algoritmasını kullanmış ve bu mimari bir simülasyon yazılımı üzerinde uygulanmıştır. Simülasyon yazılımı çalışmada kullanılan tekniğin kumaş kaplamada ve iç mimari tanıtımında faydalı olduğunu ortaya çıkarmıştır (Kaptan, 2018).

Orhan yaptığı çalışmada, hayvanların sahip oldukları desenleri CNN ile ayırt etmek (örneğin; benekli leoparlar, siyah beyaz çizgili zebralar vb) ve konumunu bulmak için EANN kullanan yeni bir yaklaşım önermiştir. Desen özelliklerini öğrenmek için, hayvan vücudunun çeşitli bölgelerinden küçük parçalar alınmış ve bu parçalar modellerin eğitimi için kullanılmıştır. Önerilen CNN algoritmasının eğitim performansı güncel algoritmalarından biri olan Faster R-CNN ile karşılaştırılmıştır. Deneysel sonuçlarına göre, önerilen eğitim yöntemi Faster R CNN'e göre daha iyi bir performans göstermiştir (Orhan, 2017).

Cengil ve Çınar yaptıkları çalışmada, derin öğrenme algoritması ile bir görüntü sınıflandırma problemine çözüm aramışlardır. CIFAR-100 veri kümesinden otobüs, traktör, tren, dinazor, fil, kelebek, sandalye ve televizyon olmak üzere 8 farklı görüntü seçilmiştir. Toplamda 840 görüntü seçilmiş bu görüntülerin 800 adedi eğitim geri kalan 400 adedi ise test verisi olarak kullanılmıştır. Bu görüntüler CNN ile sınıflandırılmıştır. Deneysel sonuçlara göre görüntü sınıflandırması için tasarlanan CNN mimarisi büyük bir sınıflandırma başarısı ile görüntüleri sınıflandırmıştır (Cengil, 2016).

3. MATERYAL VE YÖNTEM

3.1. Veri Kümesi


Önerilen CNN modeli çiçek resimleri veri kümesi üzerinde test edilmiştir. Çiçek veri kümesinde 10 farklı çiçek türünün resimleri bulunmaktadır. Bu çiçek türleri arasında phlox, rose, nergis, iris, lösanthemum maksimum, bellflower, viola, goldquelle, şakayık ve aquilegia bulunur. Veri kümesi 128x128 boyutunda 210 görüntüye sahiptir. Görüntüler PNG veri formatındadır. Her görüntünün sınıf etiketi CSV formatında ayrı bir dosyada sunulmaktadır. Veri kümesi "Flower Color Images (Çiçek-renkli görüntüler)" olarak adlandırılmaktadır ve ve Kaggle web sitesinde yer almaktadır (Belitskaya, 2017). Veri kümesinde bulunan çiçeklere ait örnek resimler Şekil 3.1’de verilmiştir.



Şekil 3.1. Örnek çiçek resimleri

3.1.1. Ön İşleme / Artırma

CNN’leri kullanırken, birçok derin öğrenme yaklaşımında büyük miktarda veriyle daha iyi başarı oranlarının elde edildiği bildirilmiştir. Bu çalışmada başarı oranını arttırmak için veri kümesindeki verilere ön işleme tekniği uygulanmıştır. Veri artırma yöntemi, dikey ayna, yatay ayna, çapraz üst sol ve çapraz üst sağ olmak üzere 4 farklı yöne uygulanır. Yapılan veri artırma ön işlemesine bağlı olarak veri kümesindeki görüntülerin sayısı 210’dan 1050’ye çıkartılmıştır. Görüntü boyutları 128x128 pikselden 100x100 piksele düşürülmüştür. Veri kümesinde orijinal renkli görüntüler gri tondaki benzerleri ile birlikte kullanarak değerlendirilmiştir. Veri artırma ile elde edilen bazı görüntüler Şekil 3.2’de verilmiştir.



Şekil 3.2. Veri artırma sonrası bazı görseller

3.2. Sinir Ağı

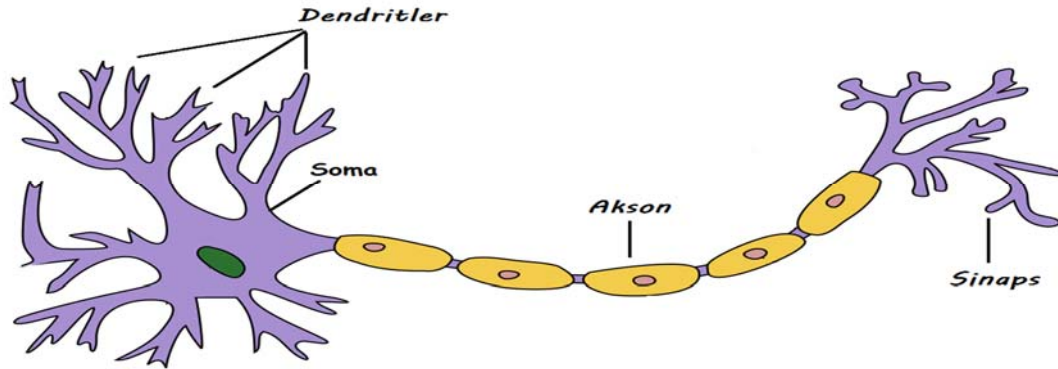
İnsan beyni yaklaşık olarak her bir nöronun yaklaşık 10.000 diğer nöronla bağlandığı yaklaşık 86 milyar nörondan oluşmaktadır. Biyolojik sinir ağının temsili gösterimi Şekil 3.3’de verilmiştir.



Şekil 3.3. Biyolojik sinir ağının temsili gösterimi (Webb, 2018)

Bir nöron, giriş ve çıkış kanalları olan ve nöronları birbirine bağlayan soma (vücut), dendritler ve aksonlardan oluşur. Her bir nöron dendritler üzerinden diğer nöronlardan elektrokimyasal sinyaller/girdiler almaktadır. Bu elektrokimyasal girdilerin toplamı nöronu etkinleştirmek için yeterince güçlü olduğunda, nöron, sinyali akson boyunca iletir ve bu elektromekanik sinyali aksonlara bağlı olan sonraki nöronlara iletir.

Eşik deęerini geince birbirine baęlanan nronlar aktif edebilir (tetiklenebilir). Biyolojik bir nronun temsili gsterimi Őekil 3.4’de verilmiřtir.



Őekil 3.4. Biyolojik nron (Lagandula, 2018)

Sinir aęlarındaki nemli nokta, bir nronun yalnızca vcutta alınan toplam sinyal belirli bir seviyeyi ařtıęında yanmasıdır; bu, nronun aktifleřtięi veya aktifleřmedięi anlamına gelir. İnsan beyni, ok fazla sayıdaki bu basit birimlerin ok karmařık bir grevi yerine getirebildięi birbirine baęlı elektrokimyasal iletim nronlarından oluřur. Bu biyolojik model yapay sinir aęlarının temelidir. Ancak yapay sinir aęları hala beynin karmařık modeline yaklařmaz. Yapay sinir aęları bazı problemlerde iyi olduklarını gstermiřlerdir ancak bu problemler hala ok kolaydır. İnsan beyni hala, ANN’ların yaptıęı gibi eęitim srecine ihtiya duymadıęı grnt tanıma benzeri arařtırılması gereken problemler iermektedir (Tařhan, 2017).

Standart bir sinir aęı (NN), her biri gerek deęerli aktivasyon dizisi reten, nron adı verilen birok basit ve baęlı iřlemciden oluřur. Giriř nronları evreyi algılayan sensrler vasıtasıyla harekete geirilirken, dięer nronlar daha nce aktif olan nronlardan gelen aęırlıklı baęlantılarla harekete geerler. Bazı nronlar, eylemleri tetikleyerek evreyi etkileyebilir. ęrenme, NN’yi istenen davranıřı gstermesini saęlayan aęırlıkları bulmakla ilgilidir. Soruna ve nronların nasıl baęlandıęına baęlı olarak bu davranıř, her bir evrenin aęın toplam aktivasyonunu (genellikle doęrusal olmayan bir Őekilde) dnřtrdę hesaplama ařamalarının uzun nedensel zincirlerini gerektirebilir.

Ardıřık birka lineer olmayan nron katmanına sahip modeller, en azından 1960’lara ve 1970’lere dayanmaktadır. 1960’larda ve 1970’lerde geri yayılım (BP) adı verilen rastgele derinlięe sahip ayrık, farklı aęlarda ęretmen tabanlı denetimli ęrenme

(SL) için etkili bir gradyan iniş yöntemi geliştirilmiştir ve bu yöntem 1981’de NN’lere uygulanmıştır. Bununla birlikte, birçok katmana sahip derin NN’lerin BP tabanlı eğitimlerinin 1980’lerin sonunda pratikte zor olduğu ve 1990’ların başında açık bir araştırma konusu haline geldiği görülmektedir. Denetimsiz öğrenme (UL), bir dereceye kadar pratik olarak uygulanabilir hale gelmiştir. 1990’lar ve 2000’lerde aynı zamanda tamamen denetlenen SL’de birçok gelişme gözlemlenmiştir. Yeni binyılda, derin NN’ler nihayet çok sayıda önemli uygulamada çekirdek makineler gibi alternatif makine öğrenme yöntemlerinden (Schölkopf, Burges ve Smola, 1998; Vapnik, 1995) daha iyi performans göstererek geniş çapta dikkat çekmiştir. Aslında, 2009’dan beri denetlenen derin NN’ler birçok resmi uluslararası örüntü tanıma yarışmasını kazanmıştır. Derin NN’ler aynı zamanda denetleyici öğretmen bulunmayan daha genel güçlendirme öğrenimi (RL) alanıyla da ilgili olmuştur.

Hem ileriye dönük NN’ler (FNN’ler) hem de tekrarlayan NN’ler (RNN’ler) çeşitli yarışmalarda başarı elde etmiştir. Bir anlamda, RNN’ler tüm NN’lerin en derinleridir - bunlar FNN’lerden daha güçlü genel algoritmalarıdır ve prensipte, girdi paternlerinin rastgele dizilerinin anılarını oluşturabilir ve işleyebilir (Schmidhuber, 1990a; Siegelmann ve Sontag, 1991). Otomatik sıralı program sentezi için geleneksel yöntemlerin aksine (Balzer, 1985; Deville & Lau, 1994; Soloway, 1986; Waldinger & Lee, 1969), RNN’ler sıralı ve paralel bilgi işlemeyi doğal ve verimli bir şekilde karıştıran programları öğrenebilmektedirler. Geçtiğimiz 75 yıl boyunca gözlenen hesaplama maliyetindeki hızlı düşüşün sürdürülmesi için çok önemli olduğu düşünülen büyük paralellikten istifade etmek temel amaçlardan biridir (Schmidhuber, 2015).

3.2.1. Yapay Sinir Ağı


Warren McCulloch ve Walter Pitts, sinir ağları için hesaplamalı bir model oluşturmuştur. Model, biri beyindeki biyolojik işleme ve diğeri sinir ağlarının yapay zeka uygulamalarına odaklanan iki farklı yaklaşım göstermektedir (McCulloch, 1943). 1949’da Donald Hebb kitabında bu yaklaşımdan bahsetmektedir ve aynı anda aktifleşen nöronlar arasındaki bağlantıların insan beyninin öğrenmesi için gerekli olduğu kadar gelişmiş olduğunu belirtmiştir (Hebb, 1949). Frank Rosenblatt (1958), basit toplama ve çıkarma kullanan iki katmanlı bir bilgisayar öğrenme ağına dayanan örüntü tanıma algoritması olan algılayıcıyı oluşturmuştur. Rosenblatt, matematiksel gösterimle, özel-devre ya da temel algılayıcıda olmayan devreyi, geri-yayımla algoritması Paul Werbos

(1975) tarafından yaratılana kadar, sinir ağı tarafından işlenemeyen bir devre olarak tanımlanmıştır (Rosenblatt, 1958).

Sinir ağı algoritması hesaplama gücü ve kaynaklara ihtiyaç duyduğundan, yapay zeka (AI) ve destek vektör makineleri gibi pek çok başka yaklaşım da çalışmanın yerine geçmiştir. Bu nedenle sinir ağı üzerindeki gelişmeler ve çalışmalar oldukça sessiz ilerlemiştir. İlerleyen zamanda derin katmanlı ağlara sahip sinir ağı, önemli ölçüde geliştirilmiş hesaplama kaynakları ve bilgisayarların paralellığı nedeniyle 2000'den sonra popüler hale gelmiştir (Taşhan, 2017).

3.2.1.1. Algılayıcı (Perseptron)

Algılayıcı ana hesaplama birimi ve biyolojik nöronun matematiksel modelidir. Gerçek nöronlarda dendrit, diğer nöronların aksonlarından bir sinyal alırken, algılayıcıda bu elektrokimyasal sinyaller ikili veya sayısal değerler olarak temsil edilir. Gerçek nöronlarda, dendrit ve aksonlar arasındaki sinyaller, her bir giriş değerini, ağırlık adı verilen bir değerle çarparak modellenen algılayıcıyı çeşitli miktarlarda modüle eder. Nöron, yalnızca giriş sinyallerinin toplam kuvvetleri belirli bir eşiği aştığında bir çıkış sinyali verir. Algılayıcı benzer şekilde, mevcut girişlerin ağırlıklı toplamını hesaplayarak giriş sinyallerinin toplam kuvvetini bağlı olduğu diğer nöronları aktifleştirdiği çıkışı belirlemek için toplam üzerinde bir adım fonksiyonu uygular. Matematiksel modellemesine göre, bir algılayıcı birçok ikili girdiden oluşur ($x_1, x_2, x_3 \dots x_n$). Ağırlıklar ($w_1, w_2, w_3 \dots w_n$) ise gerçel bir sayıdır ve her bir giriş değerinin önemini ifade eder (Taşhan, 2017). Şekil 3.5'de bir algılayıcının temsili gösterimi verilmiştir.




Şekil 3.5. Algılayıcı algoritması (Polat, 2018)

Giriş değerleri alındığında, algılayıcı $\sum_{i=1}^n w_i x_i$ bir eşik değerinden θ (Teta) küçük veya büyük olup olmadığını belirlemek için bir aktivasyon çıkış değeri hesaplar. Çıkışın aktifleşmesi Eşitlik 3.1’de açıklandığı gibi ifade edilebilir;

$$\begin{aligned} \text{Çıkış} &= 0, \text{ eğer } \sum_j w_j x_j \leq \text{eşik} \\ &1, \text{ eğer } \sum_j w_j x_j > \text{eşik} \end{aligned} \quad (3.1)$$

Aktivasyon değeri aşıldığında (veya ona eşitse - teta), algılayıcı “1” (eylem potansiyeli) verir ve eğer 0 veya daha az ise θ (teta) “0” verir. Bu, şekil 3.6’da gösterildiği gibi grafiksel olarak ifade edilebilir. Burada çıktı y sembolü ile belirtilir. Bu ilişki “adım fonksiyonu” olarak adlandırılır ve eğer aktivasyon eşiği aşarsa, algılayıcının aktiflenip aktiflenmeyeceğine karar verir.



Şekil 3.6. Grafiksel olarak aktivasyon-çıkış eşik ilişkisi (Taşhan, 2017)

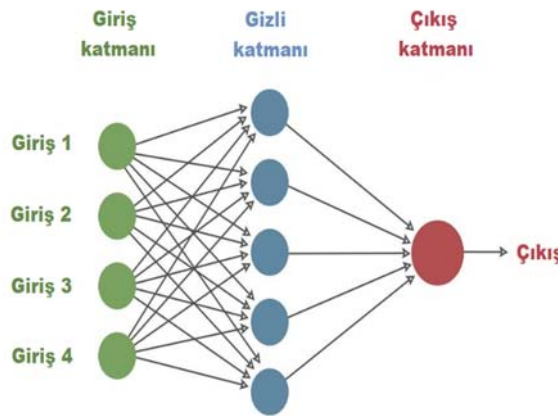
Açıktır ki algılayıcı tek başına tam bir insan beyninin ve nasıl karar verdiğinin bir modeli değildir. Ancak bu algılayıcıları birbirine bağlamak ve onlarla bir ağ oluşturmak bazı problemler hakkında karar verebilir olmasını sağlamaktadır. Şekil 3.6’da, grafik bir aktivasyon-çıkış eşik ilişkisi görülür (Taşhan, 2017).

Algılayıcı başlangıçta ümit verici görünse de, bu modelin görevlerin çoğu için çok ilkel olduğu anlaşılmıştır. Doğrusal olmayan bir fonksiyon olmasına rağmen, giriş alanını hiper düzlemle ayırır. Bu nedenle, bir veri kümesi doğrusal olarak ayrılamazsa, algılayıcı algoritması birleşemez; örneğin, XOR işlevini öğrenemez (Polat, 2018).

ANN bir bilgisayarda beyin aktivitesini simüle etmek için insan sinir sisteminden ilham almıştır. Sinir sisteminde, nöron hücreleri birbirlerine bağlanır ve uyarıldıklarında, bağlantılar kullanılarak beyine bir sinyal iletilir. Her bir nöron, sadece komşu hücrelerinin bir kısmını aktive eder. Bu davranışı ANN’de taklit etmek için, bir katmandaki her düğüm bir ağırlık değerine sahip bir sonraki katman düğümlerine bağlanır. Düğümler giriş

değerlerini toplar ve uyarılıp uyarılmadığını belirleyen bir aktivasyon fonksiyonuna geçer. Aktivasyon değerleri bir sonraki katman nöronlarının girişi olarak kullanılır. Bu işlem son tabakaya kadar takip edilir. Şebeke sınıflandırma için tasarlanmışsa, giriş son katmandaki en yüksek aktivasyon değerine sahip nöron tarafından etiketlenir (Demir, 2017).

Şekil 3.7’de 4 boyutlu girişe, 5 nöronlu bir gizli katmana ve bir nöronlu bir çıkış katmanı sahip örnek bir ANN gösterilmektedir. Bu örnek ağ, ikili bir sınıflandırma işlemi gerçekleştirir. Son nöronun aktif olup olmadığını kontrol ederek girişine bir sınıf etiketi atar. ANN çoğunlukla girişleri bir sınıf etiketine veya belirli bir değere eşleyen bir işlevi öğrenmek için kullanılır. Genel olarak, giriş vektörü boyutu ve çıkış nöronu sayısı problem tanımı ile tanımlanır. Gizli katmanların sayısı ve gizli katmanlardaki nöronların sayısı ANN mimarisini tanımlar. Bunlar bir doğrulama seti kullanarak tahmin edilmesi gereken hiper parametrelerdir.



Şekil 3.7. Bir gizli katmana sahip Yapay Sinir Ağı(Fauske, 2006)

Bir katmandaki her nöron ardışık bir katmandaki tüm düğümler için bağlantılara sahiptir. Ağ parametrelerini yüklemek için gereken hafıza alanı, yeni bir katman eklendiğinde hızla artar. Bu nedenle, yalnızca saf ANN kullanmak yerine, bilgisayarlı görüdeki son çalışmaların çoğu onu CNN’deki bir konvolüsyon tabakasının sonuna bağlı bir blok olarak kullanır (Demir, 2017).

Ağ mimarisinin ilk katmanı giriş nöronlarından oluşan giriş katmanı, son katman çıkış katmanı ve giriş ve çıkış katmanı arasındaki katmanlar ise gizli katmanlardır. Gizli katman, mimariye göre bir veya daha fazla sayıda olabilir. Genellikle çok katmanlı ağlara çok katmanlı algılayıcı (multi-layered-perceptron - MLP) denir. Giriş sinyalleri

nöronlarda işlenir ve bir sonraki nöronun girişlerine yayılır. Bağlantı kalıplarına gelince, ağ topolojilerinin ana özelliği ileri beslemeli ağlar (FFN) ve tekrarlayan ağlardır (RNN).

İleri beslemeli ağlarda girdiden çıktıya veri akışı ileri yönde iletilir. Veri işleme, çoklu birim katmanlarına uzanabilir, ancak her katman arasında geri besleme bağlantısı yoktur; bu, verilerin bir döngü biçimi olmadan katmanlardan bir sonraki katmanın girişlerine yayıldığı anlamına gelir. İleri beslemeli ağların aksine, tekrarlayan sinir ağları, geri bildirim yapacak birimler arasında bir döngü biçimine sahiptir. RNN'nin ana özelliği, ağın giriş dizilerini işlemesi için geçici belleğe sahip olmasına neden olan dinamik özelliklere sahiptir (Taşhan, 2017).


3.2.1.2. Çok Katmanlı Algılayıcı

Çok katmanlı algılayıcı (MLP) bir çeşit ileri beslemeli ANN'dir. MLP, en az üç düğüm katmanından oluşur. İlk katmana girdi katmanı, son katmana çıktı katmanı denir. Orta katmanlara gizli katmanlar denir. Gizli katmanları nedeniyle, MLP doğrusal olarak ayıramayan verileri ayırt edebilir. Bir MLP sisteminde giriş ve çıkış düğümlerinin sayısı verilere göre belirlenir. Örneğin, rakamların 28x28 boyutlu görüntülerde depolandığı el yazısı basamak tanıma amaçlı bir ağ mimarisi tasarlamak için giriş katmanında 784 düğüm (bir piksel için bir giriş düğümü, $28 \times 28 = 784$) ve çıkış düğümlerinde 10 düğüm (her bir rakam için bir düğüm) olacaktır.

Gizli katmanların sayısı ve gizli katmanlardaki düğüm sayısı tasarım sorunlarıdır. Literatürde, gizli katmanların sayısını belirlemek için genel bir formül yoktur. Deneyimler, gizli katmanların sayısının artırılmasının eğitim hatasını azaltabileceğini, ancak algoritmanın karmaşıklığını arttırdığını ve sistemin genelleme yeteneğinin azalmasına neden olduğunu göstermektedir. Ayrıca, gizli katmanların sayısı arttıkça, sistemin ağırlıkları güncelleyemediği ve daha fazla yerel minimum gözlemlendiği görülmüştür. Öte yandan, bu katmanlardaki gizli katman ve düğüm sayısı sistem için yeterli değilse, model düzgün çalışmaz. Gizli katman sayısında olduğu gibi gizli katmandaki düğüm sayısının belirlenmesi de başka bir tasarım konusudur. Çok fazla düğüm eğitimi daha uzun hale getirecek ve ağ genelleme yeteneğini kaybedebilir. Aksine, çok az sayıda düğüm olduğunda, ağın çok az bilgi kullanması gerekir ve karmaşık modelleri çözemeyebilir. Bu hiper parametreler, eğitim sonuçlarına göre eğitim sürecinde belirlenir.


MLP ağlarında, düğümlerdeki aktivasyon fonksiyonları genellikle doğrusal olmayan fonksiyonlar olarak seçilir. Yaygın olarak kullanılan aktivasyon fonksiyonları sigmoid'dir. Sigmoid fonksiyonu Eşitlik 3.2 (Şekil 3.8), hiperbolik tanjant fonksiyonu Eşitlik 3.3 (Şekil 3.9) ve düzeltilmiş doğrusal birim fonksiyonu Eşitlik 3.4 (Şekil 3.10)'te verilmiştir (Polat, 2018).

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.2)$$




Şekil 3.8. Sigmoid işlevi (Polat, 2018).

$$f(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (3.3)$$



Şekil 3.9. Tanh fonksiyonu (Polat, 2018).

$$f(x) = \begin{cases} 0, & \text{için } x < 0 \\ x, & \text{için } x \geq 0 \end{cases} \quad (3.4)$$



Şekil 3.10. Düzeltilmiş (Rektifiye) Doğrusal Birim (ReLU) fonksiyonu (Polat, 2018)

MLP'yi geri yayılımla eğitirken iki ana adım vardır. Bunlar ileri besleme adımı ve geriye yayılım adımıdır (Polat, 2018).

3.2.1.3. Geriye yayılım (Backpropagation)

Bir sinir ağının girişi ve çıkışı arasında doğru bir eşleme oluşturmak için, yaygın bir yöntem denetimli öğrenmeyle ağ parametrelerini (ağırlıklarını) eğitmektir. Bu işlem, verilen girdi verileri için çıktı verileri içeren bir eğitim veri setine sahip olmayı gerektirir. Bu eğitim verisi ile bir ağ çıktısını gerçek çıktı ile karşılaştırabilir. İstenilen çıktının y olduğunu ve gerçek çıkışın y' 'nin ağırlığını ve önyargılarını (biases) ayarlayarak çıktı hatasını en aza indiren bir maliyet veya kayıp fonksiyonuna C geçtiği kabul edilebilir. Eşitlik 3.5 bu kabulü göstermektedir.

$$\min_{\theta} \frac{1}{N} \sum_{t=1}^N C(y_t, \hat{y}_t | \theta) \quad (3.5)$$


İşlem, ağ üzerinden veri iletmekte, maliyeti hesaplamakta ve eğitim seti test seti tarafından onaylandığında ağ yeterli doğruluk seviyesine ulaşana kadar parametreleri yeniden ayarlamaktadır. Bu yöntem, geri yayılım olarak adlandırılır ve gradyan iniş ile geri yayılma, maliyet işlevinin gradyanlarını parametrelerle yayar ve bunları ağa geri koyar (Taşhan, 2017).

Bu eğitim algoritması sözde kodsals olarak aşağıdaki gibi özetlenebilir (Polat, 2018):

- ❖ Ağırlıkları sıfırla
- ❖ Her örnek için ileri yayılım prosedürünü uygula (düğümün çıkış değerini hesapla)
- ❖ Ağırlıkları güncellemek için geri yayılım algoritmasını uygula
- ❖ Bir yaklaşma gerçekleşene kadar 2. ve 3. adımları tekrarla.

3.2.1.3.1. İleri Beslemeli Adımı (Feedforward Step)

İleri besleme adımında, düğümler karşılık gelen ağırlıkları ile çarpılır ve sonuçlar toplanır. Sonuç toplamı doğrusal olmayan bir aktivasyon fonksiyonunda işlenir. Aktivasyon fonksiyonunun çıkışı bu düğümün değeri haline gelir (Şekil 3.11). Giriş düğümlerinden başlayarak, bu işlem, çıkış katmanının düğüm değerleri hesaplanıncaya kadar tüm düğümlere uygulanır (Polat, 2018).



Şekil 3.11. İleriyayma işlemi (Polat, 2018)

3.2.2. Derin Öğrenme

Derin öğrenme bir makine öğrenme sınıfıdır. Derin öğrenme, özellik çıkarma ve dönüştürme için birçok doğrusal olmayan işlem birimi katmanını kullanır. Ardışık her katman, önceki katmandan çıktıyı girdi olarak alır. Algoritmalar denetlenebilir veya denetlenemez olarak ikiye ayrılabilir (Şeker, 2017).

Derin öğrenme yüksek boyutlu verilerin düşük boyutlu dönüşümlerini oluşturmak için derin mimarileri kullanan çok sayıda algoritmayı içinde barındırmaktadır. Kullanılan derin öğrenme mimarisi, girdi verilerinin özelliklerini doğrudan hesaplamak yerine, farklı soyutlama seviyelerine sahip çok sayıda hesaplama katmanlarından oluşur. Derin öğrenme algoritmasına bağlı olarak değişen belirli bir doğrusal olmayan dönüşüm fonksiyonu ile her katmandaki verilerin yeni bir temsili hesaplanır. Bir katmanın çıktısını sonraki katmanın girişi olarak kullanarak, katman başına katmanın aşamalı olarak azaldığı hiyerarşik bir ağ oluşturulur. Derin öğrenme kavramı, insan beyninin çalışma mekanizmasına benzetilir ve aldığı yeni bilgiyi derinlemesine anlamak için farklı seviyelerde hiyerarşik soyutlama kullanır. Böylece, her katmanın soyutlanmasıyla daha güçlü hale gelen, yüksek boyutlu girdi verilerinin üst düzey özelliklerini öğrenir.

Derin öğrenme, desen sınıflandırması ve özellik çıkarımı gibi hiyerarşik mimarilerde kullanılan makine öğrenmesi işlemlerini içermektedir. Grafik modelleme, optimizasyon, model tanıma, görüntü işleme, doğal dil işleme ve sinyal işleme gibi çeşitli araştırma alanlarında kullanılmaya başlanmıştır. GPU (Graphics Processing Unit) kullanımı ile hesaplama güçlerinde oluşan artış sayesinde eğitim için kullanılacak veri setlerinin büyümesi ve daha güçlü algoritmaların kullanılabilmesi ile derin öğrenmenin son zamanlardaki popülerliği artmıştır (Büyükyılmaz, 2017).

Sinir ağlarının tarihi geçmişe kadar uzanır. 1980'lerin ortasında, ilk derin sinir ağları tanıma görevlerine uygulanmıştır. Bu, bilimsel bir başarı olmasına rağmen, eğitim çok zaman aldığı için ilgi azalmaya devam etmiştir. Yıllar sonra, daha büyük, daha hızlı ve daha ucuz BT birimlerinin geliştirilmesi, derin öğrenme tekniklerini canlandırmıştır. Derin öğrenme birçok alanda başarıyla kullanılmıştır. Yeni mimariler, algoritmalar ve araçlar kısa sürede oluşturulmuştur.


Sinir ağları genellikle bir insan beynindeki nöronlar tarafından tanımlanabilir. Yapay sinir ağlarının tasarımı, her bir katmanın birbirini takip ettiği katmanlı bir mimariye benzemektedir. Bu sistemde, her katman birkaç üniteden (veya nöronlardan) ve sigmoid veya ReLu gibi aktivasyon fonksiyonlarından oluşur. Derin sinir ağları kendi kendine öğrenme mekanizmaları olarak düşünülebilir. Bu öğrenme yolunun prensibi özellikleri çıkarmaktır. Otomatik öğrenilen özellikler, ağların derin katmanlarında mevcuttur. Bir görüntünün piksellerini analiz ederek, nesne algılama ve benzer tespiti gibi genel görevlerin temel işlevselliği olan öğrenilmiş özellikleri elde edilebilir (Kaptan, 2018).

Klasik makine öğrenme teknikleriyle bir makine öğrenme sistemi veya model tanımı oluşturmak için önce özellik vektörünü çıkarmak gereklidir. Özellik vektörünü çıkarmak için uzmanlara ihtiyaç vardır. Bu işlemlerin ikisi de çok zaman alır ve uzmanı çok meşgul eder. Bu nedenle, bu teknikler ham verileri ön işlemden geçirmeden ve uzman yardımı olmadan işlemez. Derin öğrenme, uzun yıllardır makine öğrenmesi alanında zor olan bu problemi ortadan kaldırarak muazzam ilerleme kaydetmiştir. Çünkü derin ağlar, geleneksel makine öğrenmesi ve görüntü işleme tekniklerinin aksine, öğrenme sürecini ham verilerde yaparlar. Farklı katmanlarda oluşturduğu temsillerden gerekli bilgiyi elde eder. Derin öğrenme ilk önce 2012’de nesne sınıflandırma için Büyük Ölçekli Görsel Tanıma (ImageNet) yarışmasındaki başarısıyla dikkat çekmiştir. Her ne kadar derin öğrenmenin temelleri geçmişe bağlı olsa da son yıllarda başlıca iki nedenden dolayı popüler olmuştur; ilk neden olarak eğitim için yeterli sayıda verinin günümüz şartlarında elde edilebiliyor olması gelirken ikinci neden ise bu eğitimi gerçekleştirebilecek donanımsal alt yapıya sahip olabilmektir (İnik, 2017).


3.2.3. Konvolüsyonel Sinir Ağları

Konvolüsyonel sinir ağı, bir MLP türüdür ve ileri beslemeli sinir ağı olan CNN algoritması da, hayvanların görme merkezinden ilham alınarak geliştirilmiştir. Nöronun uyarı alanından uyarılara cevap vermesi ağda bulunan matematiksel konvolüsyon işlemi olarak varsayılmaktadır (Şeker, 2017).

CNN, temel olarak geleneksel NN yöntemiyle kullanılan vektörler yerine matrisleri kullanır (Şekil 3.12). Matris kullanmanın temel avantajı, yerel alıcı alanlar olarak çalışmaları ve yerel mekânsal komşulukları korumalarıdır. Örüntü tanıma durumunun klasik şemasının bazı görüntü işleme, özellik çıkarımı ve örüntü tanıma aşamalarını simüle etmemize izin verir (Mercan, 2015).




(a) Geleneksel Dügüm: Skaler Girişler, skaler ağırlıklar ile çarpılır. Tüm parametreler skaler sayılardır.



(b) CNN Dügümü: Konvolüsyonel işlemi, Matris Ağırlıkları ile Matris Girişleri üzerinde çalışır. Bütün parametreler matrislerdir.

Şekil 3.12. Geleneksel Sinir Ağı Dügümü ve CNN Dügümü Arasındaki Fark (Mercan, 2015).

CNN farklı bir yaklaşım kullanır ve çok katmanlı sinir ağlarına benzer özel yöntemlere sahiptir. Bir Konvolüsyonel sinir ağı, alt örnekleme / havuzlama katmanı ile birlikte olan ve sonunda sinir ağlarında görülen tamamen birbirine bağlı katmanlar tarafından izlenen bir veya daha fazla konvolüsyon katmanından oluşur. Konvolüsyonel sinir ağlarının arkasındaki fikir, insan beyninin görsel korteksi olarak adlandırılan görsel algı ile motive edilir. Görsel korteks, daha karmaşık hücrelerin daha büyük alıcı alanlara sahip olduğu bir görsel alan olan alıcı alanların küçük ve alt bölgelerinde ışığın tespitinden sorumlu olan birçok hücre tarafından oluşur. Bu alıcı alan hücresi, verilen giriş alanındaki kenarları tespit ettiği giriş alanındaki yerel filtreler olarak işler. Bu araştırma sonuçları, hücrelerin görsel korteks üzerinde yaptıkları aynı işlevselliği sağlamak için CNN konvolüsyon katmanlarını motive etmiş ve yönlendirmiştir. Tipik bir CNN diyagramı Şekil 3.13'te gösterilmiştir. Bir katmanın özellikleri, önceki alıcıda yerel alıcı alan olan küçük bir komşulukta bulunan bir dizi özellikten girdiyle beslenir. Bu yerel alıcı alanların amacı, kenarları, yatay çizgileri, köşeleri gibi temel görsel özellikleri daha yüksek katmanlarla birleştirmek için çıkarmaktır (Taşhan, 2017).



Şekil 3.13. CNN Tipik bir blok diyagramı (Hijazi, 2015)

CNN'ler normal sinir ağı modellerine kıyasla çok az ön işleme kullanır. CNN'deki ağı modeli, özellikleri kendisi öğrenir çünkü bitişik düğümler arasındaki ilişkileri kurar. Örneğin, elle yazılmış rakamları (28x28 piksel) sınıflandırırken, MLP her pikseli ayrı ayrı alır ve boyutu 784 olan bir vektör oluşturur. Ancak, bitişik pikseller arasındaki bilgiyi kaybetmektedir. Her pikselin komşu pikselleriyle uzamsal bir ilişkisi vardır. Ancak girişi vektörleştirerek bu bilgi kaybolur. Bu durum aynı zamanda doğal dil işleme için benzer şekildedir. Her kelime veya hece, önceki veya sonraki kelime veya hece bağlıdır. Ancak, MLP'ler bu uzamsal bilgiyi atar ve her bir giriş düğümünü bağımsız olarak işler. Bu durumun üstesinden gelmek için, genellikle ön işleme adımı uygulanır.

CNN'de bu uzamsal bilgi bir konvolüsyon basamağıyla dikkate alınır. Filtreler, eğitim sırasında değerlerini kendi kendine öğrenir ve verilerdeki belirli desenleri ortaya çıkarır. CNN'ler genellikle konvolüsyon katmanlarından, havuz katmanlarından ve tamamen bağlı katmanlardan oluşur. Kısaca, CNN'ler filtreleri kullanarak belirli kalıpları çıkarır, daha sonra havuz katmanları modeldeki verileri işleme kolaylığı sağlamak için belirli yöntemler kullanarak azaltır. Son adım olarak, elde edilen veriler vektörleştirilir ve son adımda MLP kullanılır.

CNN'de ham veriler tensör olarak temsil edilir. Tensör kavramı daha yüksek dereceli matrisler olarak geliştirilebilir. Örneğin, bir vektör bir 1. düzen tensörüdür, gri ölçekli görüntü bir 2. düzen tensörüdür ve üç kanala (R, G ve B) sahip bir görüntü, 3. düzen tensörüdür. Girdi, ara gösterimler ve parametrelerin tümü CNN modelinde tensörler olarak gösterilir (Polat, 2018).

CNN'nin ilk başarılı kullanımı LeCun ve ark. (Demir, 2017) tarafından belge tanımak için tasarlanmıştır. Kullanılan bu CNN, LeNet olarak adlandırılmıştır. Konvolüsyon tabakasını, bir havuz tabakası tarafından belirli bir derinliğe ulaşana kadar

istifleyen sezgisel bir tasarım kuralı takip edilmiştir. Son havuzlama katmanının sonunda, tamamen bağlı katmanlar takip etmiştir. Bu yaklaşım, yeni mimariler arasında hala popülerdir (Demir, 2017).

CNN algoritmaları, doğal dil işleme (NLP), biyomedikal, özellikle görüntü ve ses işleme alanında birçok farklı alanda uygulanmaktadır. Özellikle, görüntü işleme alanında son teknoloji sonuçlar elde edilmiştir. 2014 yılında, ImageNet Yarışması'nda milyonlarca görüntü ve yüzlerce nesne sınıfı ile nesne sınıflandırma ve tespitinde en başarılı dereceleri alan ekiplerin tümü CNN algoritmalarının çeşitlerini kullanılmıştır. 2015 çalışmasında, CNN, ters yüzler de dahil olmak üzere geniş açı aralıklarında yüzleri yakalamayı başarmıştır. Bu ağ, 20.000'den fazla 200.000 görüntünün görüntüsünü ve çeşitli açılar ve yönlerde yüzleri içeren bir veri seti ile eğitilmiştir. CNN modellerinin görüntü işlemenin yanı sıra çeşitli doğal dil işleme (Natural Language Processing - NLP) problemlerinde de kullanılabileceği gösterilmiştir. Anlamsal ayrıştırma, arama sorgusunda, cümle modellemesinde, sınıflandırmada, tahmin problemlerinde mükemmel sonuçlar elde edilmiştir. Atomwise tarafından 2015 yılında geliştirilen AtomNet, ilaç tasarımı için kullanılan ilk derin ağ olmuştur. Kimyasal reaksiyonların 3 boyutlu gösterimi ile eğitilmiş olan sistem, Ebola ve Skleroz gibi hastalıklarda yeni biyomolekülleri keşfetmek için kullanılmıştır. (Go) oyunu için, CNN oyunda kullanılmış ve geleneksel olarak geliştirilen GNU Go algoritması önceden eğitilmiş 12 katmanlı bir CNN modeline %97'sinde yenmiştir. Google DeepMind tarafından geliştirilen CNN tabanlı AlphaGo, profesyonel bir oyuncuyu yenen ilk programdır (Şeker, 2017).

3.2.3.1. Konvolüsyonel Sinir Ağlarının Katmanları

Konvolüsyonel sinir ağları sınıflandırma problemleri için karmaşık bir mimari oluşturmak amacıyla çok sayıda istiflenmiş katmandan oluşur. Bu katmanlar, konvolüsyon katmanları, havuzlama / alt örnekleme katmanları, doğrusal olmayan katmanlar ve tamamen bağlı katmanlar olmak üzere tanımlanmaktadır. Tipik olarak, bu katmanların arkasındaki amaç, girdiye ait özellik haritaları oluşturmak, ara katmanların boyutlarını azaltmak, tamamen bağlı katmanları yeniden şekillendirmek ve simüle etmektir. Aşağıdaki bölümlerde verilen bu bileşenler açıklanmaktadır (Taşhan, 2017).


3.2.3.1.1. Giriş katmanı

Giriş katmanı, adından da anlaşılacağı gibi, CNN'nin ilk katmanını oluşturur. Bu katmanda, veriler ağa ham olarak iletilir. Bu katmandaki verilerin büyüklüğü, tasarlanacak modelin başarısı için önemlidir. Yüksek giriş görüntü boyutu, hem yüksek bellek gereksinimini hem de eğitim süresini ve görüntü başına test süresini artırabilir. Ayrıca, ağın başarısını artırabilir. Düşük giriş boyutu seçmek, hafıza ihtiyacını ve eğitim süresini azaltır. Bununla birlikte, kurulacak ağın derinliği azalır ve performans düşük olabilir. Görüntü analizinde, hem ağ derinliği, donanım hesaplama maliyeti hem de ağ başarısı için uygun bir giriş görüntü boyutu seçilmelidir (İnik, 2017).

3.2.3.1.2. Konvolüsyon Katmanı

Bir konvolüsyon katmanının birincil işlevi, girdi verilerinden özellikler çıkarmaktır. Konvolüsyon iki fonksiyonun matematiksel bir işlemidir. CNN konseptinde konvolüsyon işlemi basit olarak, her elemanın eleman-bazında çarpımını gerçekleştirerek, ana veri üzerinde filtre de denilen bir çekirdek fonksiyonunu kaydırır. Kayma işlemindeki her pencere için, eleman bilgili çarpmanın toplamı o pencerenin sonucunu verir. Tüm görüntü boyunca pencereler kaydırılarak, özellik haritası adı verilen konvolüsyon işleminin çıkışı üretilir.

Şekil 3.14'te, 5x5 ebadında bir matris, 3x3 ebadında bir çekirdekle kıvrılmıştır. Sol üst köşeden başlayarak, çekirdek tüm resim boyunca kayar. Son görüntüdeki kıvrılmış özellik, özellik haritasını gösterir. Çekirdek ve giriş görüntüsü arasında bir korelasyon olduğunda, sonuçta ortaya çıkan özellik haritasının bu alanlarda daha yüksek değerlere sahip olduğu görülmektedir. Benzerlik olmadığında ortaya çıkan özellik haritasının bu bölgelerde daha düşük değerleri vardır. Bu yüzden çekirdeklere "özellik dedektörleri" de denir. Konvolüsyon katmanında, orijinal veriler üzerinde birçok çekirdek kullanılır. Bu çekirdeklerin her biri girdi verilerinin farklı desenlerini ve özelliklerini öğrenir. Örneğin, kenarları, eğrileri, lekeleri ve düz alanları tespit etmeyi öğrenebilirler (Polat, 2018).



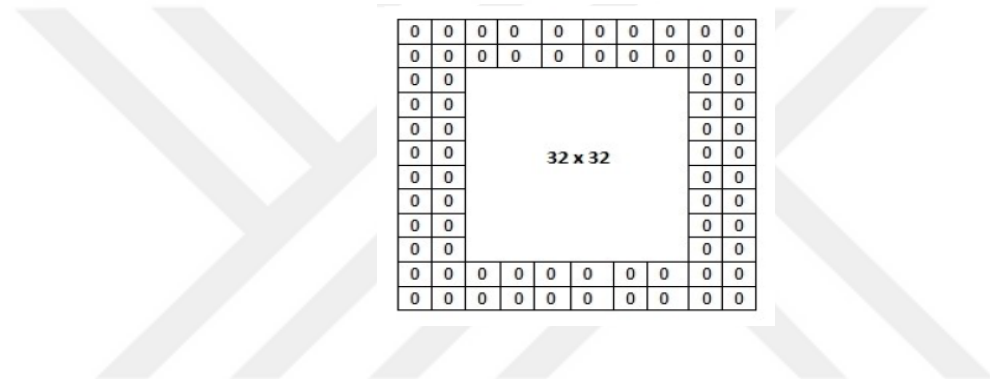
Şekil 3.14. Konvolüsyon işlemi (Polat, 2018)

CNN'lerdeki konvolüsyon işlemi göz önüne alındığında, düşünülmesi gereken üç tasarım sorunu vardır: çekirdek boyutu, çekirdek sayısı ve adım sayısı. Bu hiper parametrelerin çıktı verilerinin şekli ve bellek kullanımı üzerinde etkisi vardır.

Çekirdek boyutu, her bir nöronun alıcı alanını, konvolüsyon katının çıkışındaki alıcı alanını belirler. Çekirdeğin değerleri modelin ağırlıklarını temsil eder. Örneğin, çekirdeğin boyutu 3x3 ise, çıktısının giriş katmanındaki 9 farklı düğümle bağlantısı vardır. Genel olarak, çekirdek boyutu girdi veri boyutuyla aynıdır. Giriş 1 kanallı gri tonlamalı bir görüntü ise, çekirdek de 1 kanaldır. Giriş 3 kanallı bir RGB görüntü ise, çekirdek 3 boyutlu bir yapı olarak seçilir. Eğer çekirdek büyüklüğü çok küçükse (örneğin, 2x2), yeterince özellik çıkaramaz. Örneğin, küçük taneler büyük karmaşık kalıpları tespit edemez. Bununla birlikte, küçük çekirdekli büyüklükteki konvolüsyonlar art arda uygulanırsa, özellikleri çıkarabilirler. Öte yandan, daha büyük çekirdek boyutu hesaplama karmaşıklığını arttırmaktadır. Genel olarak, CNN eğitiminde 3x3 veya 5x5 gibi küçük çekirdek boyutları kullanılır. Bununla birlikte, son yayınlar ayrıca, ağdaki boyutu azaltmak için bazı durumlarda 1x1 filtrelerin yararlı olabileceğini belirtmektedir (Polat, 2018).

Adım sayısı (stride) parametresi, çekirdek kaymasının adım boyutunu belirler. Eğer adım birden fazla ise, çıkışın genişliği ve yüksekliği belirgin şekilde azalır. Alt örnekleme işlemi, havuz katmanı yerine aşamalı konvolüsyon ile gerçekleştirilebilir (Demir, 2017).

Konvolüsyon işleminde, çıkış tensörünün boyutunu giriş hacmiyle aynı tutmak için giriş tensörüne dolgu eklenebilir. Dolgu boyutu genellikle çekirdeğin boyutuna göre belirlenir. Örneğin, çekirdek boyutu 3x3 ise, görüntünün etrafındaki 1 piksel yeterlidir. Çekirdek boyutu 5x5 ise, görüntünün etrafında 2 piksel kullanılabilir. Bu senaryoya örnek gösterim Şekil 3.15'te verilmiştir. Dolgu değerleri genellikle sıfır veya kenar pikselleriyle aynı değer olarak seçilir (Polat, 2018).



Şekil 3.15. 5x5 çekirdeğin boyutu için, görüntü boyutunu aynı tutmak amacıyla iki piksel sıfır dolgu kullanılabilir (Polat, 2018).

Herhangi bir Konvolüsyonel katmanında çıktı boyutunu hesaplamak için Eşitlik 3.6 kullanılabilir (Polat, 2018):

$$O = \frac{(W-K+2P)}{S} + 1, \text{ dır ve;} \quad (3.6)$$

O çıkış yüksekliği / uzunluğu, W giriş yüksekliği / uzunluğu, K filtre boyutu, P dolgu malzemesi ve S adımdır.

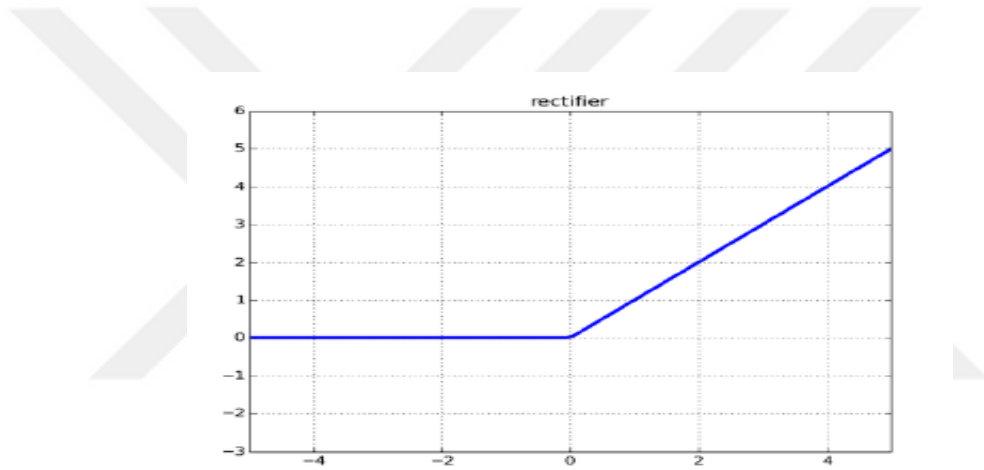
3.2.3.1.3. Rektifiye Doğrusal Birim Katmanı (ReLU)

Rektifiye Doğrusal Birimi (Rectified Linear Units Layer - ReLU), sinir ağlarının başka bir aktivasyon işlevidir. ReLU karakteristiği Şekil 3.16'da görülebilir. ReLU doğrusal olmayan bir fonksiyondur. Çıkış değeri 0 ile $+\infty$ arasında olabilir. Sigmoid ve tanh işlevini kullanırken, ağıın hemen hemen tüm nöronları bir şekilde aktive edilir. Bu

durumda hesaplama maliyetli olduğu için nöronlar seyrekleştirmek istenir. ReLU, rasgele başlatma sırasında bazı nöronların aktive edilmediği ağı daha etkin bir şekilde kullanılmasını sağlamaktadır ve hesaplama maliyeti sigmoid ve tanh'tan daha az bir hale getirmektedir. ReLU işleviyle ilgili bir sorun, hesaplama gradyanı ve güncelleme ağırlıkları olsa da, yatay çizginin değerlerinin gradyana yanıt vermemesi ve ağı önemli bir kısmının geri yayılma sırasında güncellenmemesi olabilir. Bu soruna ölen nöronlar denir. Bu sorun kısmen Leaky ReLU ile engellenebilir. Leaky ReLU formülü Eşitlik 3.8'de görülebilir, φ küçük bir sabittir (Orhan, 2017).

$$f(x) = x^+ = \max(0, x) \quad (3.7)$$

$$f(x) = 1(x < 0) * (\varphi x) + 1(x \geq 0)(x) \quad (3.8)$$



Şekil 3.16. Doğrultulmuş Doğrusal Birimler (Orhan, 2017).

3.2.3.1.4. Havuz Katmanı (Max Pooling)

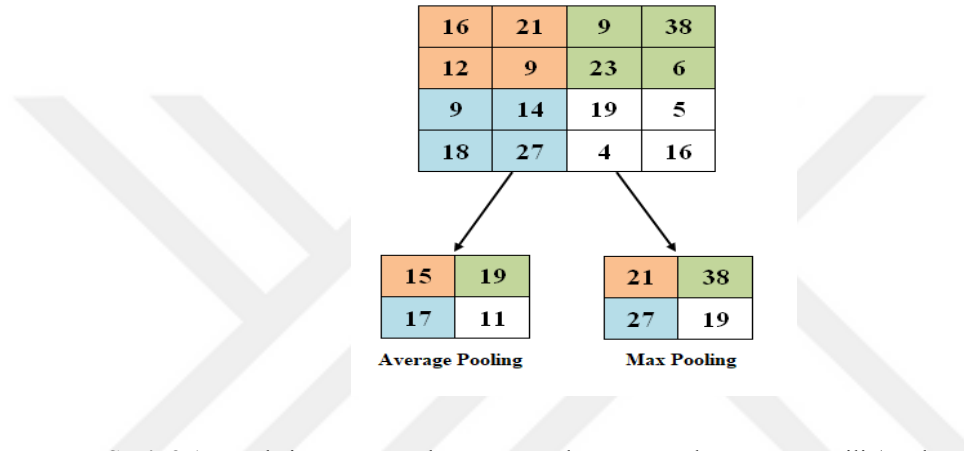
Havuzlama katmanının amacı, ağıdaki parametre ve hesaplama sayısını azaltmaktır. Bu azaltma işlemi havuzlama olarak tanımlanmakta ve iki farklı şekilde yapılmaktadır. Biri maksimum havuzlama, diğeri ise ortalama havuzlamadır. Her iki yöntem de aynı giriş alanını aynı örtüşmeyen $2B$ alanlara bölerek yapar (Taşhan, 2017).

Bu işlem gerçekleştirilirken girdinin üzerinde dikdörtgen bir pencere kaydırılır ve yapılacak olan havuzlama türüne göre işlemler gerçekleştirilir.

Max Pooling, dikdörtgen pencerenin içinde en büyük değere sahip olan aktivasyonu seçer ve merkeze yerleştirir.

Ortalama Havuzlama, pencerenin içindeki aktivasyonlardan ortalama değeri hesaplar ve merkeze atar (Demir, 2017).

Şekil 3.17, girişin 4x4 ve 2x2 alt örnekleminin büyüklüğü olduğu havuzlama işlemini temsil eder. Bu 4x4 görüntü, 2x2 boyutunda dört farklı matrise bölünmüştür. Max-pooling yöntemi, 2x2 matrisindeki dört değer için maksimum değeri ürettiği çıktıdır. Ancak, ortalama havuzlama yöntemi, dört değer için ortalamasını ürettiği çıktıdır. Ortalama havuzda, çıktı değeri kesir olarak hesaplanırsa, en yakın tam sayıya yuvarlanır (Taşhan, 2017).



Şekil 3.17. Maksimum Havuzlama ve Ortalama Havuzlamamın Temsili (Taşhan, 2017).

3.2.3.1.5. Tamamen Bağlı Katman


Tamamen bağlı katman esas olarak bir CNN'in son katmanı olarak kullanılır ve oluşturulur. Bu tür katmanda, her giriş nöronu her çıkış nöronuna bağlanır. Her bir bağlantıyla ilişkili ayrı bir ağırlık ve her bir çıkış nöronu için ayrı bir önyargı (bias) değeri vardır (Jassmann, 2015).

Tamamen bağlı bir katmandaki nöronlar, düzenli yapay sinir ağlarında görüldüğü gibi, önceki katmandaki tüm aktivasyonlarla tam bağlantılara sahiptir. Etkinlikleri matematiksel olarak önceki katmandan matris çarpımlarıyla yapılabilecek özelliklerin ağırlığını toplar ve asıl amacı, sınıflandırma olarak kabul edilebilecek hedefi belirlemektir. Bu tamamen bağlı katmanda, önceki katmanın beslediği tüm özellik elemanları, çıktı özelliğini hesaplamak için kullanılır (Taşhan, 2017).

Çıktılar vektör formatına dönüştürülür, böylece ağırlık matrisi ile çarpılabilirler (Polat, 2018). Örneğin, CNN mimarisindeki son katman tarafından üretilen matris boyutu ve tam bağlı olarak matris boyutu katman 4096x1'dir. Toplam 160000x4096 ağırlık

matrisi oluşturulmuştur. Yani, her 160000 nöron 4096 nöronla bağlanır. Bu nedenle, bu katmana tamamen bağlı bir katman denir (İnik, 2017).

Şekil 3.18’ de 3 giriş nöronu ve 2 çıkış nöronu bulunan tamamen bağlı bir tabaka gösterilmektedir. Her bağlantının kendi ağırlık değeri vardır ve etiketli 1 nöronuna bağlı ağırlıklar önyargı terimleridir (Jassmann, 2015).



Şekil 3.18. Tamamen bağlı bir katmana bir örnek (Jassmann, 2015).

Tamamen bağlı bir katmanın ileri yayılımı Eşitlik 3.9 kullanılarak hesaplanır,

$$z = f(x \times \theta + b), \quad (3.9)$$

Buradaki x , satır başına bir örnek içeren giriş matrisidir, θ ağırlık matrisi, \times matris çarpma operatörüdür, b önyargı değerlerini içeren satır vektörüdür, f aktivasyon işlevidir ve z , çıkış nöronlarının aktivasyonunu içeren matristir (Jassmann, 2015).

Tam olarak bağlı katmanın ağırlık matrisinin gradyanı Eşitlik 3.10’da gösterilmiştir (Jassmann, 2015),

$$\frac{\partial \varepsilon}{\partial \theta} = \frac{x^T \times \left(\frac{\partial \varepsilon}{\partial f(z)} \circ \frac{\partial f(z)}{\partial x} \right)}{m}, \text{ dir ve;} \quad (3.10)$$

$\partial \varepsilon / \partial f(z)$ daha derin bir katmandan yayılan hatadır ve $\partial f(z) / \partial x$ bu katmanın çıkış nöronlarının aktivasyonunun gradyanı ve m antrenman örnekleri sayısıdır. Önyargı teriminin gradyanı Eşitlik 3.11 ‘de gösterilmiştir.

$$\frac{\partial \varepsilon}{\partial b} = \text{sütunOrtalaması} \left(\frac{\partial \varepsilon}{\partial f(z)} \circ \frac{\partial f(z)}{\partial x} \right) \quad (3.11)$$

Hatanın katman boyunca ilerlemesi ise Eşitlik 3.12’de görülebilir.

$$\frac{\partial \varepsilon}{\partial x} = \left(\frac{\partial \varepsilon}{\partial f(z)} \circ \frac{\partial f(z)}{\partial x} \right) \times \theta^T \quad (3.12)$$

Bu denklemlerde, \times matris çarpım operatörü ve \circ element-matris çarpım operatörüdür.

3.2.3.1.6. Sınıflandırma Katmanı

Bu katman tamamen bağlı katmandan sonra gelir. Bu katmanın çıkış değeri, sınıflandırılacak nesne sayısına eşittir. Örneğin, 15 farklı nesnenin sınıflandırması yapılacaksa, sınıflandırma katmanı çıkış değeri 15 olmalıdır. Çıktı değeri tam olarak bağlanmış katmanda 4096 olarak seçilirse, bu çıkış değerine göre sınıflandırma katmanı için bir 4096×15 ağırlık matrisi elde edilir. Bu katmanda farklı sınıflandırıcılar kullanılır. Diğer sınıflandırıcılara oranla daha yüksek başarı elde etmesinden dolayı softmax sınıflandırıcısı tercih edilir. Sınıflandırmada, sınıflandırılacak toplam sınıf sayısı kadar 0-1 aralığında belirli bir değer üretir. 1’e yakın sonuç üreten çıktının ağ tarafından öngörülen nesne olduğu anlaşılmaktadır (İnik, 2017).

Tam olarak bağlı katmanın ağırlık matrisinin gradyanı Eşitlik 3.13’te gösterilmiştir (Jassmann, 2015),

$$\frac{\partial \varepsilon}{\partial \theta} = \frac{x^T \times (h(x \times \theta) - y)}{m}, \quad (3.13)$$

burada \times matris çarpma işlemidir, ağırlık matrisi, x , tabakaya girdi, h , softmax aktivasyon işlevi, y , beklenen çıktı ve m , eğitim örneklerinin sayısıdır. Hatanın katman boyunca ilerlemesi Eşitlik 3.14’de görülebilir (Jassmann, 2015).

$$\frac{\partial \varepsilon}{\partial x} = (h(x \times \theta) - y) \times \theta^T \quad (3.14)$$


3.3. Alexnet

2010 yılında düzenlenen ImageNet Büyük Ölçekli Görsel Tanıma Yarışması’nda (ILSVRC), 1.2 milyon yüksek çözünürlüklü görüntüyü 1000 farklı sınıfa sınıflandırmak

için büyük, derin bir evri sinir ağı kurulmuştur. Test sonuçlarına göre, yazarlar eski teknik yaklaşımlardan çok daha iyi olan %37,5 ve %17,0 oranlarında ilk 1 ve ilk 5 hata oranlarına ulaşmışlardır. Ayrıca, daha hızlı bir eğitim süresi elde etmek amacıyla doygun olmayan nöronlar ve konvolüsyon operasyonu uygulanan çok etkili bir GPU kullanmışlardır. Daha sonra, tam bağlantılı katmanlardaki fazla uyumu azaltmak için, verimli olduğu kanıtlanan yakın zamanda geliştirilen bir düzenleme yöntemi kullanılmıştır (ILPV-2012 yarışmasında değerlendirilen AlexNet, önerilen başka bir CNN modeli olan ILSVRC 2012 yarışmasında değerlendirilmiştir) ve %15.3 değeri ile en iyi ikinci hata oranına sahip olmuştur. Yeni önerilen bu model 60 milyon parametreye ve 650 bin nörona sahip ve ağırlıkları olan sekiz katmandan oluşmaktadır; ilk beş katman kıvrımlıdır ve geri kalan üçü tamamen birbirine bağlıdır. Son tam olarak bağlanmış son katmanın çıktısı, 1000 sınıf etiketler üzerinde bir dağılım yaratan 1000 düğümlü softmax'a beslenir (Krizhevsky, 2012).

Konvolüsyonel tabakalar sırasıyla 11x11, 5x5, 3x3, 3x3, 3x3 çekirdekleri içerir. Orijinal mimarilerin giriş boyutu 256x256x3 (Bircanoğlu, 2017). Normalleştirme katmanlarının tepkisi birinci ve ikinci Konvolüsyonel katmanları takip eder. Maksimum havuzlama katmanları, hem yanıt normalleştirme katmanlarını hem de son konvolüsyon katmanı (beşinci) izler. ReLu doğrusal olmayanlık tüm konvolüsyon ve tam bağlı tabakaların sonucuna uygulanır; kullanılan standart doğrusal olmayanlık, Tanh veya Sigmoid doğrusal olmayanlıktır. Ancak onlarla ilgili problem “doygun bölgelere” sahip olmalarıdır. Bu bölgelerde gradyan çok küçük hale gelir. Bu nedenle, degrade iniş çok yavaş olur ve eğitim uzun zaman alır. Yalnızca çok küçük bir sinüs vardır, bu işlevler eğitimin daha hızlı ilerlemesini sağlayacak kadar büyük degrade verir.

Alexnet modeli, fazla güçlendirme sorununun üstesinden gelmek için bir dropout katmanı kullanır. Düşmüş nöronlar bu tabakada ileri aktarılmaz. Bu nedenle, ne zaman bir girdi rastgele örneklerde sinir ağı çeşitli bir mimari sunulduğunda ancak o zaman tüm bu mimariler ağırlıkları paylaşır. Bunun bir sonucu olarak, her bir nöronu daha az bağımlı olmaya zorlar, böylece diğer nöronların senkronizasyonunda avantajlı olan daha güçlü özellikleri öğrenmeye zorlayan diğer nöronlara karmaşık bağımlılıklar oluşturur. Test aşamasında, bütün nöronlar kullanılır, fakat bunların çıkışları düşme olasılığı ile çarpılır. Bırakma AlexNet modelinde ilk iki tamamen bağlı katman (tabakalar 6 ve 7) kullanılmaktadır (Krizhevsky, 2012). Şekil 3.19’da AlexNet yapısı verilmiştir.



Şekil 3.19. AlexNet Katmanları (Bircanoğlu, 2017).

3.4. Önerilen CNN Modeli

Önerilen CNN modeli, yapıdaki bazı değişiklikler dahil olmak üzere AlexNet'e benzer şekilde inşa edilmiştir (Krizhevsky, 2012). Önerilen CNN modelinin yapısında dört adet iki boyutlu katman kullanılmıştır. Birinci katmanda 32, ikinci katmanda 64, üçüncü katmanda 128 ve dördüncü katta 256 filtre kullanılmıştır. Önerilen CNN modelinin ilk Conv2D katmanında (3x3) çekirdek boyutları ve Conv2D katmanlarının geri kalanında (2x2) çekirdek boyutları kullanılmıştır. Bu Conv2D katmanlarının her biri arasında MaxPooling2 havuz katmanları kullanılmıştır. Önerilen CNN modelinin son katmanında, diğer katmanlarda kullanılan ReLu aktivasyon fonksiyonu yerine softmax kullanılmıştır. Önerilen CNN modelinin yapısı Tablo 3.1'de verilmiştir.

Tablo 3.1. Önerilen CNN modeli

Katman (tür)	Çıkış şekli	Parametre #
conv2d_1 (Conv2D)	(Yok, 84, 84, 32)	896
max_pooling2d_1 (MaxPooling2)	(Yok, 42, 42, 32)	0
conv2d_2 (Conv2D)	(Yok, 42, 42, 64)	18496
max_pooling2d_2 (MaxPooling2)	(Yok, 21, 21, 64)	0
conv2d_3 (Conv2D)	(Yok, 21, 21, 128)	73856
max_pooling2d_3 (MaxPooling2)	(Yok, 11, 11, 128)	0
conv2d_4 (Conv2D)	(Yok, 11, 11, 256)	295168
max_pooling2d_4 (MaxPooling2)	(Yok, 6, 6, 256)	0
dropout_4 (Dropout)	(Yok, 6, 6, 256)	0
flatten_1 (Flatten)	(Yok, 9216)	0
dense_1 (Dense)	(Yok, 256)	2359552
dropout_5 (Dropout)	(Yok, 256)	0
dense_2 (Dense)	(Yok, 256)	65792
dropout_6 (Dropout)	(Yok, 256)	0
dense_3 (Dense)	(Yok, 10)	2570

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu çalışma Google tarafından geliştirilen ve yayınlanan TensorFlow kütüphanesi kullanılarak python programlama dilinde geliştirilmiş ve gözlemlenmiştir. Model, veri kümesine renkli görüntü ve gri tonlamalı görüntü olarak iki farklı şekilde uygulanmıştır. Modelin başarısını arttırmak için veriler veri arttırma ön işlemlerine tabi tutularak veri seti miktarı arttırılmıştır. Önerilen model, 50 iterasyon ve 100 iterasyon için 5-fold çapraz doğrulama yöntemi kullanılarak değerlendirilmiştir.

4.1. Parametre ve Değişkenlerin Ayarlanması

Bu bölümde, çiçek sınıflandırılması için önerilen CNN modelinin parametreleri ve değişkenleri açıklanmıştır. CNN modelinde birden fazla parametre bulunmaktadır, bu parametreler modelin başarısını doğrudan etkilemektedir. CNN'de girdi görüntüleri matematiksel olarak matrisler şeklinde modele verilmektedir. CNN ağ modelinde girdi görüntülerinin boyutları aynı olmalıdır bu yüzden önerilen modelde tüm görüntülerin boyutu 84 x 84 piksel olarak ayarlanmıştır. Özelik çıkarım işleminde görüntüler 3 x 3 alt dizilere bölünmüş ve bir hücre kaydırarak maksimum havuzlama işlemi gerçekleştirilmiştir. Önerilen CNN modelinde özelik çıkarım işlemi için 4 adet iki boyutlu konvolüsyon katmanı kullanılmıştır. Her konvolüsyon katmanında ReLu aktivasyon fonksiyonu kullanılmıştır. Özellik çıkarma katmanları ile sınıflandırma katmanları arasında 0.25 oranında dropout kullanılmıştır. Sınıflandırma katmanlarında ise her gizli katmanında 256 nöron kullanılmıştır ve bu katmanlarda ReLu aktivasyon fonksiyonu olarak ayarlanmıştır. Gizli katmalar arasında ezberlemeyi önlemek için 0.25 oranında dropout kullanılmıştır. Sınıflandırma katmanının en son katmanı çıkış katmanı olarak bilinmektedir ve bu katmanda çıkış sayısı kadar yani 10 adet nöron bulunmaktadır. Bu katmanda softmax aktivasyon fonksiyonu olarak kullanılmıştır. Önerilen CNN modelinden 5-fold doğruluk çaprazlama kullanılarak 50 ve 100 değerli iki farklı iterasyonda eğitim sınıflandırma başarıları, eğitim sınıflandırma hata oranları ve test sınıflandırma başarıları elde edilmiştir.

4.1.1. K-Fold Çapraz Doğrulama

Veri madenciliği çalışmalarında, uygulanan yöntemin başarısını test etmek için veri seti eğitim ve test setlerine bölünmektedir. K-fold çapraz doğrulama bu bölünme işlemi için kullanılan bir yöntemdir. K-fold çapraz doğrulama yönteminde ilk önce k değeri seçilir. K değerine göre veri seti bölünür, örneğin eğer k=5 veri seti 5 parçaya bölünür daha sonra k sayısı kadar tekrar ederek 4 parça eğitim ve 1 parça test için kullanılır.

Bu tez çalışmasında, k sayısı 5 olarak alınmıştır. Ancak, literatürde en çok tercih edilen k değerinin 10 olduğu belirtilmektedir (Şeker, 2013). Sistemin genel başarısı ve hata oranı, elde edilen 5 sonucun ortalaması olarak hesaplanır. Bu, son adımın ortalaması olduğundan ve ortalamayı hesaplamak için kullanılan toplama işlemi yer değiştirme özelliği olduğundan, hangi bölümün başlatıldığı önemli değildir (Şeker, 2013). Bu süreç Eşitlik 4.1 görülebilir:

$$CV_{(k)} = \sum_{k=1}^K \frac{n_k}{n} MSE_k \quad (4.1)$$

burada $MSE_k = \frac{\sum_{i \in C_k} (y_i - \hat{y}_i)^2}{n_k}$ dır ve;

- \hat{y}_i , k. fold kaldırılmış verilerden elde edilen i gözlemine uygundur.
- Ortalama hata gözlem i için uygun \hat{y}_i değerini verir.
- Hata (MSE) eklenir.
- Eşitlikte n_k/n ile verilen ağırlıklı ortalamayı belirten bir ifade mevcuttur, çünkü katların her biri aynı boyutta olmayabilir.


4.2. Renkli Görüntülerin Deneysel Sonuçları

Veri seti, eğitim aşaması için yetersiz olduğundan dolayı, veri seti üzerinde veri artırma işlemleri gerçekleştirilmiştir. Çiçek veri setinin örnek sayısı 4 farklı açıda döndürme ve yansıma işlemleri ile 210 örnekten 1050 örneğe yükseltilmiştir. Önerilen CNN modelinin sınıflandırma sonuçları 50 ve 100'e eşit olarak iki farklı iterasyon döngüsü ile elde edilmiştir. Sınıflandırma sonuçlarının elde edilmesinde 5-fold çapraz doğrulama yöntemi kullanılmıştır. Her iterasyonda eğitim süreleri hesaplanmıştır. Renkli veri seti 50 iterasyon ve 5-fold çapraz doğrulama yöntemi ile elde edilen eğitim sınıflandırma başarısı ve hata değeri sonuçları aşağıda Tablo 4.1'de verilmiştir.

Tablo 4.1. Renkli görüntüler için eğitim aşamasının sınıflandırma başarısı ve hata değeri

Eğitim başarısı (%)	5. epoch	10. epoch	15. epoch	20. epoch	25. epoch	30. epoch	35. epoch	40. epoch	45. epoch	50. epoch
1. Fold	0.60	0.83	0.93	0.97	0.98	0.99	0.99	0.99	0.99	1.00
2. Fold	0.58	0.82	0.91	0.96	0.97	0.98	0.98	0.99	0.99	0.99
3. Fold	0.54	0.80	0.92	0.97	0.98	0.97	0.98	0.99	1.00	0.99
4. Fold	0.12	0.58	0.82	0.92	0.98	0.97	0.97	0.99	0.99	0.99
5. Fold	0.60	0.83	0.93	0.96	0.98	0.98	0.99	0.99	0.98	0.99
Ortalama	0.49	0.77	0.90	0.96	0.98	0.98	0.98	0.99	0.99	0.99
Eğitim hata değeri	5. epoch	10. epoch	15. epoch	20. epoch	25. epoch	30. epoch	35. epoch	40. epoch	45. epoch	50. epoch
1. Fold	1.16	0.48	0.18	0.12	0.08	0.05	0.02	0.03	0.02	0.02
2. Fold	1.12	0.50	0.26	0.11	0.08	0.05	0.06	0.03	0.04	0.03
3. Fold	1.29	0.55	0.24	0.11	0.05	0.09	0.05	0.03	0.02	0.04
4. Fold	13.92	1.25	0.52	0.23	0.08	0.09	0.08	0.04	0.03	0.06
5. Fold	1.19	0.53	0.20	0.11	0.09	0.06	0.04	0.04	0.05	0.04
Ortalama	3.74	0.66	0.28	0.14	0.08	0.07	0.05	0.03	0.03	0.04

Eğitim aşamasından elde edilen sınıflandırma başarısına ve eğitim hatasının değerine bakıldığında, önerilen CNN modelinin renkli görüntüler için eğitim sınıflandırma başarısı ve eğitim hata değerinin sırasıyla %99 ve 0,04 olarak elde edildiği görülmektedir. Önerilen CNN modeli, renkli görüntülerde çok başarılı eğitim sınıflandırma başarısı ve eğitim hatasının değeri vermiştir. Ayrıca, 50 iterasyona ait renkli görüntülerin iterasyon boyutuna göre sınıflandırma başarısı ve sınıflandırma hata değeri grafikleri Şekil 4.1’de verilmektedir. Şekil göz önüne alındığında, önerilen modelin eğitim aşamasının çok düzgün bir şekilde gerçekleştirildiği söylenebilir.

**Şekil 4.1.** Renkli görüntülerin eğitim sınıflandırma başarısı ve hata değerleri

Renkli görüntülerin eğitim aşamasında her iterasyonu ortalama 22 saniye almıştır. Eğitim aşaması bittikten sonra, veri setinin bir kısmı test veri seti olarak kullanılmıştır.

Renkli görüntüler için oluşturulan CNN modeli test örnekleri ile test edildiğinde, modelin test başarısı %84 olarak elde edilmiştir. Sınıflandırma problemlerine göre bu


değer çok iyi bir değer olarak bilinmektedir, test sınıflandırma başarısının yüksek olması modelin eğitim aşamasında çok iyi bir şekilde eğitildiği anlamına gelmektedir.

Önerilen CNN modelinin eğitim sınıflandırma sonuçları 100 iterasyon ve 5-fold çapraz doğrulama kullanılarak da ayrıca elde edilmiştir. Renkli veri setinin 100 iterasyon ve 5-fold çapraz doğrulama yöntemi ile sınıflandırılmasında elde edilen eğitim sınıflandırma başarısı sonuçları Tablo 4.2’te verilmiştir.

Tablo 4.2. Renkli görüntüler için eğitim aşamasının sınıflandırma başarısı ve hata değeri (100 epoch)

Eğitim başarısı (%)	10. epoch	20. epoch	30. epoch	40. epoch	50. epoch	60. epoch	70. epoch	80. epoch	90. epoch	100. epoch
1. Fold	0.71	0.94	0.98	0.99	0.99	0.99	1.00	0.99	1.00	1.00
2. Fold	0.82	0.97	0.99	0.99	0.99	0.99	1.00	0.99	1.00	1.00
3. Fold	0.10	0.10	0.10	0.10	0.10	0.26	0.89	0.98	0.98	0.99
4. Fold	0.82	0.96	0.98	0.99	0.99	1.00	0.99	1.00	1.00	0.99
5. Fold	0.78	0.95	0.98	0.99	0.99	0.99	1.00	0.99	0.99	1.00
Ortalama	0.65	0.79	0.81	0.81	0.81	0.85	0.98	0.99	0.99	0.99
Eğitim hata değeri	10. epoch	20. epoch	30. epoch	40. epoch	50. epoch	60. epoch	70. epoch	80. epoch	90. epoch	100. epoch
1. Fold	0.84	0.17	0.08	0.03	0.05	0.03	0.00	0.04	0.02	0.01
2. Fold	0.53	0.09	0.03	0.03	0.03	0.04	0.00	0.04	0.01	0.01
3. Fold	14.43	14.43	14.43	14.43	14.43	5.73	0.32	0.08	0.05	0.05
4. Fold	0.51	0.12	0.07	0.05	0.04	0.01	0.02	0.01	0.02	0.01
5. Fold	0.63	0.14	0.05	0.08	0.03	0.06	0.01	0.03	0.03	0.02
Ortalama	3.39	2.99	2.93	2.92	2.92	1.17	0.07	0.04	0.02	0.02

Eğitim aşamasının sınıflandırma başarısına ve eğitim hatasının değerine bakıldığında, önerilen CNN modelinin renkli görüntüler için eğitim sınıflandırma başarısı ve eğitim hata değerinin sırasıyla %99 ve 0,02 olarak elde edildiği görülmektedir. Önerilen CNN modeli, renkli görüntülerde 100 iterasyonda elde ettiği eğitim sınıflandırma başarısı ve eğitim hatasının değeri 50 iterasyon sonuçları ile çok fazla değişmemektedir. Ayrıca, 100 iterasyona ait renkli görüntülerin iterasyon boyutuna göre sınıflandırma başarı ve sınıflandırma hata değeri grafikleri Şekil 4.2’de verilmektedir.



Şekil 4.2. Renkli görüntülerin eğitim sınıflandırma başarısı ve hata değeri (100-Epoch)

Şekil 4.2'ye bakıldığında, önerilen modelin 100 iterasyonda eğitim aşamasının çok düzgün bir şekilde gerçekleştirildiği görülmektedir. Renkli görüntülerin eğitim aşaması her iterasyonda ortalama 22 saniyede gerçekleşmektedir. 100 iterasyon eğitim aşaması sona erdikten sonra önerilen CNN modeli veri setinin test parçası ile test edilmektedir.

Renkli görüntüler için 100 iterasyonla oluşturulan CNN modeli test örnekleri ile test edildiğinde, modelin test başarısı %83 olarak elde edilmiştir. Sınıflandırma problemlerine göre bu değer çok iyi bir değer olarak bilinmektedir, test sınıflandırma başarısının yüksek olması modelin eğitim aşamasında çok iyi bir şekilde eğitildiği anlamına gelmektedir.


4.3. Gri Tonlamalı Görüntülerin Deneysel Sonuçları

Çiçek veri kümesinin orijinali renkli görüntü veri kümesi olarak web sitesinden indirilmiştir. Fakat renkli görüntülerin yanı sıra önerilen CNN modele renkli görüntüler gri tonlamalı görüntülere çevrilerek verilmiştir, çünkü gri tonlamalı görüntüler CNN modelinde renkli görüntülere göre daha hızlı olarak işlem gerçekleştirir. Çiçek veri kümesi üzerinde veri arttırma işlemleri gerçekleştirildikten sonra tüm görüntüler gri tonlamalı görüntülere dönüştürülmüştür. Önerilen CNN modeli üzerinde gri tonlamalı görüntüler için model eğitimi renkli görüntülerle aynı şartları altında yapılmıştır. Önerilen CNN modeli üzerinde gri seviyeli görüntüler için eğitim sınıflandırma başarıları 50 iterasyon ve 5-fold çapraz doğrulama yöntemi kullanarak elde edilmiş ve sonuçlar Tablo 4.3'te verilmiştir.

Tablo 4.3. Gri tonlamalı görüntüler için eğitim aşamasının sınıflandırma başarısı ve hata değeri

Eğitim başarısı (%)	5. epoch	10. epoch	15. epoch	20. epoch	25. epoch	30. epoch	35. epoch	40. epoch	45. epoch	50. epoch
1. Fold	0.24	0.32	0.38	0.42	0.48	0.54	0.60	0.63	0.70	0.76
2. Fold	0.23	0.35	0.39	0.45	0.46	0.51	0.58	0.61	0.69	0.74
3. Fold	0.24	0.30	0.39	0.44	0.48	0.51	0.57	0.62	0.68	0.71
4. Fold	0.26	0.33	0.39	0.44	0.48	0.54	0.60	0.65	0.73	0.78
5. Fold	0.23	0.32	0.38	0.42	0.47	0.52	0.55	0.60	0.65	0.69
Ortalama	0.24	0.32	0.39	0.44	0.47	0.52	0.58	0.62	0.69	0.74
Eğitim hata değeri	5. epoch	10. epoch	15. epoch	20. epoch	25. epoch	30. epoch	35. epoch	40. epoch	45. epoch	50. epoch
1. Fold	2.03	1.83	1.72	1.61	1.47	1.30	1.17	1.04	0.86	0.70
2. Fold	2.07	1.84	1.71	1.60	1.48	1.38	1.21	1.11	0.92	0.79
3. Fold	2.07	1.89	1.73	1.64	1.48	1.37	1.24	1.10	0.95	0.83
4. Fold	2.03	1.85	1.69	1.57	1.43	1.28	1.16	0.99	0.81	0.64
5. Fold	2.09	1.88	1.76	1.64	1.54	1.38	1.28	1.14	1.01	0.88
Ortalama	2.06	1.86	1.72	1.61	1.48	1.34	1.21	1.08	0.91	0.77

Eđitim ařamasından elde edilen sınıflandırma başarısına ve eđitim hatasının deęerine bakıldığında, önerilen CNN modelinin gri görüntüler için eđitim sınıflandırma başarısı ve eđitim hatasının deęerinin sırasıyla %74 ve 0,77 olarak elde edildiđi görülmektedir. Önerilen CNN modeli, gri tonlamalı görüntülerden elde edilen sonuçlar renkli görüntülerin eđitim sonuçlarıyla kıyaslandığında başarı oranının düşük ve hata deęerinin yüksek olduđu gözlemlenmiştir. Ayrıca, 50 iterasyona ait gri tonlamalı görüntülerin iterasyon boyutuna göre sınıflandırma başarı ve sınıflandırma hata deęeri grafikleri Şekil 4.3'te verilmektedir. Şekil göz önüne alındığında, önerilen modelin eđitim ařamasının renkli görüntü veri setine benzer olarak düzgün bir şekilde gerçekleşmediđi gözlemlenmiştir.



Şekil 4.3. Gri resimlerin eğitim sınıflandırma başarısı ve hata değeri

Gri tonlamalı görüntülerin eđitim ařamasında her iterasyonu ortalama 8 saniye almıştır. Gri seviyeli görüntü veri setinin eđitim hızına bakıldığında renkli görüntü veri setine göre daha hızlıdır. Eđitim ařaması sona erdikten sonra önerilen CNN modeli veri setinin test parçası ile test edilmektedir.


Gri görüntüler için oluşturulan CNN modeli test örnekleri ile test edildiğinde, modelin test başarısı %47 olarak elde edilmiştir. Sınıflandırma problemlerine göre bu deęer çok iyi bir deęer olarak bilinmemektedir, test sınıflandırma başarısının yüksek olmaması modelin eđitim ařamasında çok iyi bir şekilde eđitilemediđi anlamına gelmektedir.

Önerilen CNN modelinin eđitim sınıflandırma sonuçları 100 iterasyon ve 5-fold çapraz doęrulama kullanılarak da ayrıca elde edilmiştir. Gri tonlamalı veri seti 100 iterasyon ve 5-fold çapraz doęrulama yöntemi ile elde edilen eđitim sınıflandırma başarıları aşağıda Tablo 4.4'de verilmiştir.

Tablo 4.4. Gri tonlamalı görüntüler için eğitim aşamasının sınıflandırma başarısı ve hata değeri (100 epoch)

Eğitim başarısı (%)	10. epoch	20. epoch	30. epoch	40. epoch	50. epoch	60. epoch	70. epoch	80. epoch	90. epoch	100. epoch
1. Fold	0.33	0.43	0.52	0.63	0.71	0.83	0.90	0.95	0.97	0.99
2. Fold	0.31	0.44	0.53	0.60	0.74	0.85	0.92	0.96	0.97	0.97
3. Fold	0.34	0.46	0.56	0.69	0.75	0.87	0.93	0.95	0.96	0.98
4. Fold	0.31	0.44	0.53	0.63	0.74	0.83	0.91	0.93	0.96	0.98
5. Fold	0.35	0.45	0.52	0.63	0.76	0.84	0.93	0.96	0.97	0.98
Ortalama	0.33	0.44	0.53	0.64	0.74	0.84	0.92	0.95	0.97	0.98
Eğitim hata değeri	10. epoch	20. epoch	30. epoch	40. epoch	50. epoch	60. epoch	70. epoch	80. epoch	90. epoch	100. epoch
1. Fold	1.86	1.61	1.38	1.11	0.83	0.50	0.31	0.16	0.10	0.05
2. Fold	1.88	1.62	1.36	1.11	0.77	0.49	0.25	0.15	0.09	0.08
3. Fold	1.85	1.55	1.27	0.99	0.71	0.39	0.22	0.14	0.10	0.07
4. Fold	1.87	1.57	1.34	1.07	0.75	0.52	0.30	0.19	0.13	0.08
5. Fold	1.83	1.56	1.35	1.07	0.74	0.48	0.24	0.15	0.09	0.07
Ortalama	1.86	1.58	1.34	1.07	0.76	0.48	0.26	0.16	0.10	0.07

Eğitim aşamasının sınıflandırma başarısına ve eğitim hata değerine bakıldığında, önerilen CNN modelinin gri tonlamalı görüntüler için eğitim sınıflandırma başarısı ve eğitim hata değerinin sırasıyla %98 ve 0,07 olarak elde edildiği görülmektedir. Önerilen CNN modeli, gri tonlamalı görüntülerde 100 iterasyonda elde ettiği eğitim sınıflandırma başarısı ve eğitim hata değeri 50 iterasyon sonuçları ile çok fazla değişmemektedir. Ayrıca, 100 iterasyona ait gri tonlamalı görüntülerin iterasyon boyutuna göre sınıflandırma başarı ve hata değeri grafikleri Şekil 4.4'te verilmektedir.



Şekil 4.4. Gri tonlamalı görüntülerin eğitim sınıflandırma başarısı ve hata değeri (100-Epoch)

Şekil 4.4'e bakıldığında, önerilen modelin 100 iterasyonda eğitim aşamasının çok düzgün bir şekilde gerçekleştirildiği görülmektedir. Gri tonlamalı görüntülerin eğitim aşaması her iterasyonda ortalama 8 saniyede gerçekleşmektedir. 100 iterasyon eğitim aşaması sona erdikten sonra önerilen CNN modeli veri setinin test parçası ile test edilmektedir.

Gri görüntüler için 100 iterasyonla oluşturulan CNN modeli test örnekleri ile test edildiğinde, modelin test başarısı %52 olarak elde edilmiştir. Elde edilen sonuçlara göre, gri tonlamalı görüntülerin eğitim aşamasının, renkli görüntülerin eğitim aşamasından daha hızlı olduğu söylenebilir. Genel olarak, önerilen CNN modeli ile, 50 ve 100 iterasyonlarla renkli görüntüler üzerinde çok iyi sınıflandırma doğruluğu ve hata sonuçları elde edilmiştir.



5. SONUÇLAR VE ÖNERİLER

5.1. Sonuçlar

Görüntü sınıflandırma problemlerini çözümü için derin öğrenme algoritmaları gibi birçok makine öğrenme algoritmaları tasarlanmış ve başarıyla uygulanmıştır. Görüntü sınıflandırma problemlerinde genellikle son dönemlerde konvolüsyonel sinir ağları kullanılmaktadır. Konvolüsyonel sinir ağları, derin besleme mimarisine ve yapısında tamamen bağlantılı bir katmana sahip diğer tüm ağ modellerinden daha iyi bir genelleme yeteneğine sahiptir. Konvolüsyonel sinir ağları son derece soyut özellikleri öğrenebilir ve nesnelere etkili bir şekilde tanımlayabilir.

Konvolüsyonel sinir ağları'nın diğer modellerden daha başarılı olmasının bazı nedenleri bulunmaktadır, her şeyden önce, konvolüsyonel sinir ağları modeli eğitim için gerekli parametre sayısını büyük ölçüde azaltmaktadır. Daha az parametre daha yumuşak bir model eğitimi ve daha az uyum sorunu sağlamaktadır. İkinci bir neden ise, sınıflandırma aşaması, her ikisi de öğrenme sürecini kullanan özellik çıkarma aşaması ile birleştirilmiştir. Dahası, karmaşık yapay sinir ağları veya klasik yapay sinir ağı modelleri bazen CNN'den daha zor olabilmektedir. Konvolüsyonel sinir ağlarının bu avantajları sayesinde, konvolüsyonel sinir ağları klasik ANN modellerinden daha iyi sınıflandırma başarı sonuçları elde edebilir. Günümüzde Konvolüsyonel sinir ağları, nesne çıkarma, resim sınıflandırma, resim bölümlendirme, hareket algılama, doğal dil işleme gibi birçok alanda başarılı olmuştur (Sornam, 2017) (Mitchell, 1997).

Çiçek sınıflandırması, benzer özelliklere sahip büyük çiçek sınıfları nedeniyle zor bir sınıflandırma problemi olarak bilinmektedir. Farklı türler olmasına rağmen, bazı çiçekler benzer renk, şekil ve görünüme sahiptir. Bitki izleme sistemleri, bitki tanımlama, çiçek endüstrisi gibi bazı uygulamaların başarısı, başarılı bir çiçek sınıflandırmasının sonucuna bağlıdır. Çiçekleri sınıflandırmak için manuel bir sınıflandırma yapmak mümkündür, ancak karmaşık bir görüntüdeki yüksek sayıda çiçek ve görüntü, sınıflandırma işlemini uzun ve sıkıcı hale getirecektir (Das, 1999). Bu sınıflandırma, çiçek sınıflandırma performansını artırmak ve süreci hızlandırmak için makine öğrenmesi alanında ele alınmıştır.

Bu tez çalışmanın amacı, çiçek endüstrisindeki uygulamalarda başarılı ve daha hızlı sonuçlar elde etmek için çiçek sınıflandırma probleminin başarı oranını arttırmaktır. Sınıflandırma amacıyla kullanılan derin öğrenme algoritmalarından biri olan CNN, çiçek

görüntülerine uygulanmıştır. Model, renkli ve gri ölçekli olmak üzere iki farklı şemada tasarlanmıştır. Renkli görüntüler göz önüne alındığında, önerilen modelin %84'lük bir sınıflandırma başarı oranına ulaştığı gözlenirken, gri tonlamalı görüntüleri dikkate alındığında %47'lik bir başarı oranına ulaşmıştır. Model, gri tonlamalı görüntüler için daha kısa zamanda değerlendirme işlemi gerçekleştirmekte, ancak renkli görüntüler için daha yüksek başarı oranı sağlamaktadır. CNN algoritması, konvolüsyon katmanının renkli görüntülerde daha belirgin ve daha fazla özelliği olması nedeniyle renkli görüntülerde gri tonlamalı görüntülere kıyasla daha başarılı olduğu gözlemlenmiştir. Çalışma sonucunda, çiçek sınıflandırma ile uğraşan araştırmacılara daha hızlı ve daha başarılı bir sınıflandırma modeli sunulmuştur.

5.2. Öneriler

Performansın artırılması amacıyla daha farklı parametrelerle araştırma yapılabilir ve yeni geliştirilen algoritmalar problemin çözümünde önerilen modele ek olarak kullanılabilir. Derin öğrenme algoritmalarının doğruluğunu artıran bir diğer faktör veri büyütmedir ve bu yöntem CNN algoritmalarında yaygın olarak kullanılan bir tekniktir. Veri büyütme, orijinal gerçek pozitiflerden yeni veriler oluşturur, böylece ağ belirli kalıpları ezberlemez ve genelleme yeteneğini artırır. Önerilen yöntemde döndürme ve yansıtma özellikleri kullanılmıştır. Veri kümesi küçük sayıda örneğe sahip olduğundan, ağ yalnızca belirli kalıpları hafızaya alır ve test verileri üzerinde başarılı sonuçlar elde edemeyebilir. Model, büyük veri kümeleri kullanılarak yeniden test edilebilir. Karmaşık özellikleri tespit etmek amacıyla daha fazla konvolüsyonel katman kullanmak da bir diğer hedef olarak planlanmaktadır.

KAYNAKLAR

- Abdulnabi, N. Z. T., 2016, Semantic Analysis Using Natural Language Processing Methods, Master's Thesis, *Yildiz Technical University*, Istanbul, 53.
- Anwer, A. M. O., 2017, Derin Öğrenme Yöntemleri ile Göğüs Kanseri Teşhisi, Yüksek Lisans Tezi, *Türk Hava Kurumu Üniversitesi*, Ankara, 91.
- Belitskaya, O., 2017, Flower Color Images, <https://www.kaggle.com/olgabelitskaya/flower-color-images>: [20.06.2018].
- Bhandare, A., Bhide, M., Gokhale, P. and Chandavarkar, R., 2016, Applications of Convolutional Neural Networks, *International Journal of Computer Science and Information Technologies*, 7 (5), 2206-2215.
- Bircanoğlu, C., 2017, A Comparison of Loss Functions in Deep Embedding, Master's Thesis, *Bahçeşehir University*, Istanbul, 65.
- Büyükyılmaz, M., 2017, Mikroskopik Görüntüler Üzerinde Derin Öğrenme Algoritmaları Kullanarak Hastalıklı Hücrelerin Otomatik Tanımlanması, Yüksek Lisans Tezi, *Necmettin Erbakan Üniversitesi*, Konya, 56.
- Cengil, E. v. Ç., A., 2016, Görüntü Sınıflandırma için Yeni Bir Yaklaşım: Evrimsel Sınır Ağları, *European Journal of Technic*, 6 (2), 96-102.
- Das, M., Manmatha, R., Riseman, E., 1999, Indexing flower patent images using domain knowledge, *IEEE Intelligent Systems and their Applications*, 14 (5), 24-33.
- Demir, U., 2017, Deep Convolutional Neural Networks for Image Inpainting, Master's Thesis, *Istanbul Technical University*, Istanbul, 50.
- Ergün, H., 2016, Video Concept Classification and Retrieval, Master's Thesis, *Başkent University*, Ankara, 56.
- Fauske, K. M., 2006, Example: Neural network, Artificial Neural Network with a hidden layer, <http://www.texample.net/tikz/examples/neural-network/>: [24/06/2019].
- Gurnani, A., Mavani, V., Gajjar, V. and Khandhediya, Y., 2017, Flower Categorization using Deep Convolutional Neural Networks, *ArXiv*, 4321-4324.
- Hebb, D. O., 1949, The organization of behavior; a neuropsychological theory, p. 62.
- Hershey, S., Chaudhuri, S., Ellis, D.P., Gemmeke, J.F., Jansen, A., Moore, R.C., Plakal, M., Platt, D., Saurous, R.A., Seybold, B. and Slaney, M., 2017, CNN architectures for large-scale audio classification. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*: 131-135.
- Hijazi, S. L., Kumar, R. R., Rowen, Ch., 2015, Using Convolutional Neural Networks for Image Recognition, CNN Typical block diagram, <https://www.semanticscholar.org/paper/Using-Convolutional-Neural-Networks-for-Image-By-Hijazi-Kumar/bbf7b5bdc39f9b8849c639c11f4726e36915a0da/figure/3>: [15.04.2019].
- İnik, Ö. v. Ü., E., 2017, Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6 (3), 85-104.
- Jassmann, T. J., 2015, Mobile Leaf Classification Application Utilizing A Convolutional Neural Network, Master's Thesis, *Appalachian State University*, 62.
- Kaptan, E. Ç., 2018, Image Segmentation and Texture Mapping on Pillows Using Fully Convolutional Neural Networks, Master's Thesis, *Bahçeşehir University*, Istanbul, 48.
- Karagöz, B., 2015, Uydu Görüntülerinde Bina Tanımaya Uygulanan Derin Evrimsel Sınır Ağlarının Çözümlemesi Üzerine, Yüksek Lisans Tezi, *Orta Doğu Teknik Üniversitesi*, Ankara, 59.

- Krizhevsky, A., Sutskever, I. and Hinton, G.E., 2012, Imagenet Classification with Deep Convolutional Neural Networks. *Advances in neural information processing systems*: 1097-1105.
- Küçüksubaşı, F., 2017, An Integrated System Design for Building Inspection By Autonomous UAVs, Master's Thesis, *Istanbul Middle East Technical University*, Ankara, 103.
- Lagandula, A. C., 2018, Biological neuron, <https://towardsdatascience.com/mcculloch-pitts-model-5fdf65ac5dd1>: [16.04.2019].
- Li, Q., Cai, W., Wang, X., Zhou, Y., Feng, D.D. and Chen, M., 2014, Medical image classification with convolutional neural network. *13th International Conference on Control Automation Robotics & Vision (ICARCV)*: 844-848.
- Lin, K., Yang, H.F. and Chen, C.S., 2015, Flower classification with few training examples via recalling visual patterns from deep CNN. *Conference on Computer Vision Graphics and Image Processing (CVGIP)*: 1-8.
- McCulloch, W. S., Pitts, W., 1943, A logical calculus of the ideas immanent in nervous activity, *The bulletin of mathematical biophysics*, 5 (4), 115-133.
- Mercan, C. A., 2015, An Approach for The Chest Tube Detection In Chest Radiographs Using Convolutional Neural Network, Doctoral Thesis, *Istanbul Technical University*, Istanbul, 71.
- Mignot, X. a. S., M., 2016, Taxonomic Classification using CNNs, 1-6.
- Mitchell, T. M., 1997, *Machine Learning*, New York, USA, McGraw-Hill, p.
- Nkemelu, D. K., Omeiza, D. and Lubalo, N., 2018, Deep Convolutional Neural Network for Plant Seedlings Classification, *ArXiv*, 1-5.
- Orhan, S., 2017, Localization of Certain Animal Species in Images Via Training Neural Networks With Image Patches, Master's Thesis, *Izmir Institute of Technology*, Izmir, 42.
- Özdemir, M. C., 2016, Deeply Learned Attribute Profiles for Hyperspectral Pixel Classification, Master's Thesis, *Sabançi University*, Istanbul, 56.
- Polat, G., 2018, Classification of Lung Nodules in CT Images Using Convolutional Neural Networks, Master's Thesis, *Middle East Technical University*, 101.
- Powell, L., 2018, A Framework for Understanding and Detecting Harassment in Socialvr, Master's Thesis, *Boğaziçi University*, Istanbul, 95.
- Rosenblatt, F., 1958, The perceptron: a probabilistic model for information storage and organization in the brain, *Psychological review*, 65 (6), 386.
- Schmidhuber, J., 2015, Deep learning in neural networks: An overview, *Neural networks*, 61, 85-117.
- Şeker, A., Diri, B. ve Balık, H.H., 2017, Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme, *Gazi Mühendislik Bilimleri Dergisi (GMBD)*, 3 (3), 47-64.
- Şeker, Ş. E., 2013, K Fold Cross Validation (K Katlamalı Çarpaz Doğrulama), <http://bilgisayarkavramlari.sadievrenseker.com/2013/03/31/k-fold-cross-validation-k-katlamali-carpraz-dogrulama/>: [15.03.2019].
- Sornam, M., Muthusubash, K. and Vanitha, V., 2017, A Survey on Image Classification and Activity Recognition using Deep Convolutional Neural Network Architecture. *International Conference on Advanced Computing (ICoAC)*. Chennai, India, IEEE: 121-126.
- Taşhan, B., 2017, Road Lane Detection System With Convolutional Neural Network, Master's Thesis, *Bahçeşehir University*, Istanbul, 54.
- Ulu, A., 2016, Deep Convolutional Neural Network Based Representations for Person Re-Identification, Master's Thesis, *Istanbul Technical University*, Istanbul, 65.

- Webb, S., 2018, Deep learning for biology, *nature*, 554, 555–557.
- Yalçın, H., Razavi, S., 2016, Plant Classification using Convolutional Neural Network. Fifth International Conference on Agro-Geoinformatics (Agro-Geoinformatics): 1-5.
- Yurdakul, E. E., 2017, Semantic Segmentation of RGBD Videos with Recurrent Fully Convolutional Neural Networks, Master's Thesis, *Koç University*, Istanbul, 43.
- Zia, S., 2016, RGB-D Object Recognition using Deep Convolutional Neural Networks, Master's Thesis, *Koç University*, Istanbul, 41.



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Elaf Sabri GHRAIRI
Uyruğu : Irak
Doğum Yeri ve Tarihi : Bağdat, 14.01.1990
Telefon : 05524996012
Faks :
E-mail : elaf_2@yahoo.com

EĞİTİM

Derece	Adı , İlçe, İl	Bitirme Yılı
Lise	: Asmaa , Bağdat, Irak	2007
Üniversite	: D.U.C.(Dijlah University College), Bağdat , Irak	2011
Yüksek Lisans	: S.Ü.(Selçuk Üniversitesi), Konya , Turkey	2019
Doktora	:	

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2011- Şu anda	Hükümet çalışanı	Bilgisayar mühendisi

UZMANLIK ALANI

YABANCI DİLLER: Türkçe, İngilizce

YAYINLAR: E.S. GHRAIRI, S. KAHVECİ and İ. BABAOĞLU: “Classification of Flower Species Using Convolutional Neural Networks”, International Conference on Advanced Technologies, Computer Engineering and Science (ICATCES2019), Apr 26-28, 2019 Alanya, Turkey.