

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**DERİN ÖĞRENME KULLANILARAK SEAM
CARVİNG İLE BOYUTLANDIRILMIŞ
GÖRÜNTÜLERİN TESPİTİ**

YÜKSEK LİSANS TEZİ

Hamidullah NAZARI

**Enstitü Anabilim Dalı : BİLGİSAYAR VE BİLİŞİM
MÜHENDİSLİĞİ**
Tez Danışmanı : Doç. Dr. Devrim AKGÜN

Ocak 2021

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**DERİN ÖĞRENME KULLANILARAK SEAM
CARVING İLE BOYUTLANDIRILMIŞ
GÖRÜNTÜLERİN TESPİTİ**

YÜKSEK LİSANS TEZİ

Hamidullah NAZARI

Enstitü Anabilim Dalı

**: BİLGİSAYAR VE BİLİŞİM
MÜHENDİSLİĞİ**

Bu tez 25.01.2021 tarihinde aşağıdaki jüri tarafından oybirliği / oyçokluğu ile kabul edilmiştir.

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Hamidullah NAZARI

25/01/2021

TEŞEKKÜR

Yüksek lisans programı boyunca bana akademik bilgi ve deneyimlerini esirgemedен aktaran, beni çalışmaya teşvik eden, tezimin başından sonuna kadar yazılmasına rehberlik eden değerli danışman hocam Doç.Dr. Devrim AKGÜN'e teşekkürlerimi ve şükranlarımı sunarım. Eğitim hayatım boyunca bana maddi manevi her türlü desteği sağlayan aileme sonsuz teşekkür ederim.

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	iv
ŞEKİLLER LİSTESİ	v
TABLolar LİSTESİ	vii
ÖZET	viii
SUMMARY	ix

BÖLÜM 1.

GİRİŞ	1
1.1. İçeriğe Duyarlı Görüntü Yeniden Boyutlandırma Tekniği	3
1.2. Seam carving Tespiti	4
1.3. Literatür Taraması	4
1.4. Tezin Amacı	10

BÖLÜM 2.

YÖNTEM VE MATERİYALLAR	11
2.1. Seam Carving Algoritması	11
2.1.1. Enerji hesaplaması	12
2.1.2. Seam belirleme	13
2.1.3. Seam silinmesi	16
2.2. Konvolüsyon Sinir Ağları (CNN - Convolutional Neural Networks)..	20
2.2.1. Konvolüsyon katmanı (Convolution - layer)	20
2.2.2. ReLU (Düzleştirilmiş doğrusal birim - Rectified linear unit)	
katmanı	21

2.2.3. Havuzlama veya örnekleme katmanı (Pooling layer)	21
2.2.4. Tam bağlantılı katmanı (Fully connected layer)	22
2.2.5. Dropout katmanı	22
2.2.6. Softmax katmanı	23
2.2.7. Kayıp fonksiyonu (Loss function)	23
2.3. Yerel İkili Örüntü (Local Binary Pattern – LBP).....	23
2.4. Performans Ölçüme ve Değerlendirme Matrisleri	30
2.5. ImageNet Görsel Veri Seti	31
BÖLÜM 3.	
GELİŞTİRİLEN MODEL	32
3.1. Geliştirilen Konvolüsyon Sinir Ağı (CNN)	32
BÖLÜM 4.	
DENEYSEL ALTYAPISI	36
4.1. Test Görüntülerin Seam Carving Tespit Sonuçları	39
4.2. YİÖ Tabanlı Seam Carving Tespit Sonuçları	42
4.3. Görüntülerin Katmanlar Arası Görünümü	45
4.3.1. Ara aktivasyonları görselleştirme	45
BÖLÜM 5.	
SONUÇ VE ÖNERİLER	48
KAYNAKLAR	50
EKLER	56
ÖZGEÇMİŞ	63

SİMGELER VE KISALTMALAR LİSTESİ

BACM	: Blocking Artifact Characteristics Matrix
CNN	: Convolutional Neural Network
CPU	: Central Processing Unit
CV	: Computer Vision
FC	: Fully Connected
FN	: False Negative
FP	: False Positive
HPF	: High Pass Filter
HTML	: Hypertext Markup Language
JPEG	: Joint Photographic Experts Group
LBP	: Local Binary Pattern
LDP	: Local Derivative Pattern
RAM	: Random Access Memory
Relu	: Rectified Linear Unit
SIFT	: Scale Invariant Feature Transfer
SVM	: Support Vector Machine
TN	: True Negative
TP	: True Positive
UCID	: Uncompressed Color Image Database
VIA	: Visualizing Intermediate Activations
WLD	: Weber Local Descriptor
YİÖ	: Yerel İkili Örüntü

ŞEKİLLER LİSTESİ

Şekil 2.1. Orjinal görüntü (Dikey optimal seam yolu) ve enerji harısı	12
Şekil 2.2. Optimal seam'ın bulunması	15
Şekil 2.3. Seam carving algoritması sözde kodu (dikey seam çıkarma)	16
Şekil 2.4. Görüntüyü üç farklı yöntem ile dikey olarak boyutunun azaltılması ve optimal seam yolu: standart ölçekleme, kırpma, %40 seam carving ...	17
Şekil 2.5. Görüntüyü üç farklı yöntem ile dikey olarak boyutunun azaltılması ve optimal seam yolu: standart ölçekleme, kırpma, %20 seam carving ...	18
Şekil 2.6. Görüntüyü üç farklı yöntem ile dikey olarak boyutunun azaltılması ve optimal seam yolu: standart ölçekleme, kırpma, %10 seam carving ...	19
Şekil 2.7. CNN tasarım sıralaması	20
Şekil 2.8. Konvolüsyonel katmanın girdi görüntüyü filtreden geçirmesi	21
Şekil 2.9. Standart CNN ve ağa dropout uygulandıktan sonraki hali	23
Şekil 2.10. Seçilen pikselin YİÖ dönüşümü	25
Şekil 2.11. Merkez pikseli kuşatan komşu piksel	26
Şekil 2.12. Gri görüntü (soldaki) YİÖ uygulanan görüntü (sağdaki)	28
Şekil 2.13. Gri görüntü (soldaki) YİÖ uygulanan görüntü (sağdaki)	29
Şekil 2.14. Karmaşık matris örneği	30
Şekil 3.1. Seam carving uygulanan RGB + geliştirilen CNN yapısı	32
Şekil 3.2. Seam carving + YİÖ + geliştirilen model yapısı	34
Şekil 3.3. Geliştirilen ağın genel yapısı	35
Şekil 4.1. ImageNet veritabanından örnek resimler	38
Şekil 4.2. Doğruluk, Geçerleme doğruluğu ve Kayıp Fonksiyonların Grafiği	39
Şekil 4.3. Test görüntülerin karmaşıklık matrisi	40
Şekil 4.4. YİÖ doğruluk, geçerleme doğruluğu ve kayıp fonksiyonların grafiği ..	42
Şekil 4.5. YİÖ uygulanmış örnek görüntülerin karmaşıklık matrisi	43
Şekil 4.6. Örnek görüntü	46

Şekil 4.7. Birinci konvolüsyon katmanının görselleştirilmesi.....	46
Şekil 4.8. Birinci aktivasyon katmanının görselleştirilmesi.....	46
Şekil 4.9. Birinci max_pooling katmanının görselleştirilmesi	47
Şekil 4.10. İkinci konvolüsyon katmanının görselleştirilmesi.....	56
Şekil 4.11. İkinci aktivasyon katmanının görselleştirilmesi.....	56
Şekil 4.12. İkinci max_pooling katmanının görselleştirilmesi.....	56
Şekil 4.13. Üçüncü konvolüsyon katmanının görselleştirilmesi	57
Şekil 4.14. Üçüncü aktivasyon katmanının görselleştirilmesi	57
Şekil 4.15. Üçüncü max_pooling katmanının görselleştirilmesi	57
Şekil 4.16. Dördüncü konvolüsyon katmanının görselleştirilmesi	58
Şekil 4.17. Dördüncü aktivasyon katmanının görselleştirilmesi.....	58
Şekil 4.18. Dördüncü max_pooling katmanının görselleştirilmesi	59
Şekil 4.19. Beşinci konvolüsyon katmanının görselleştirilmesi	60
Şekil 4.20. Beşinci aktivasyon katmanının görselleştirilmesi	61
Şekil 4.21. Beşinci max_pooling katmanının görselleştirilmesi	62

TABLÖLAR LİSTESİ

Tablo 4.1. Önerilen modelin performans matrisleri	41
Tablo 4.2. YİÖ tabanlı önerilen modelin merformans matrisleri	44



ÖZET

Anahtar Kelimeler: İçerik Duyarlı Boyutlandırma, Seam Carving Tespiti, Konvolüsyonel sinir ağı, Derin Öğrenme

İçeriğe duyarlı görüntü yeniden boyutlandırma olarak bilenen seam carving, görüntünün içeriği koruncak şeklinde, görüntü boyutunu ayarlama yöntemlerinden biridir. Görüntüyü yeniden boyutlandırma, çeşitli aygıt ekranları ve uygulamalar gibi modüller arasındaki farklı çözünürlüklerin üstesinden gelebilmek için kullanılır. Görüntünün orijinal içeriği bozmak veya kaldırmak için de kasıtlı olarak kullanılabilir. Dolayısıyla görüntülere bu tür dış müdahaleyi tespit etmek, büyük önem arz etmektedir.

Bu tez çalışmasında görüntülere uygulanan seam carving tespiti, derin öğrenme modelleri, bilgisayar görmesinde yaygın olarak başvuru olan 2 boyutlu konvolüsyonel sinir ağıları (CNN – Convolutional Neural Network) ve tam bağlantılı (FC - Fully Connected) kullanılarak tespit gerçekleştirilmiştir. Önerilen model, % 0, % 10, %20 ve % 40 seam carving sınıflarından oluşan dört çıkışa sahip, çoklu sınıflandırıcı olarak geliştirilmiştir. Oluşturulan derin öğrenme ağlarının eğitimi, ImageNet açık kaynak görüntü seti kullanılmaktadır.

Orijinal görüntülerin yanında, dikey yönünde seam carving ile %10, %20 ve %40 boyutları azaltılmış görüntüler kullanılarak eğitim ve test veri setleri elde edilmiştir. Modelin başarımı, karmaşıklık (confusion) matrisi ve test setlerini doğru sınıflandırma oranı ile ölçülmüştür. Modelin doğruluk analizi, görüntüler üzerinde model test edilerek, karmaşıklık, kesinlik (precision), F1-score ve recall matrisleriyle sonuçları ve doğruluk değeri detaylı olarak gösterilmiştir.

DETECTION OF IMAGES RESIZED WITH SEAM-CARVING USING DEEP LEARNING

SUMMARY

Keywords: Content-Aware Resizing, Seam Carving Detection, Convolution Neural Network, Deep Learning

Seam carving, also known as content-aware image resizing, is one of the methods for adjusting the image size such that the content of the image will be preserved. Image resizing is used to handle different resolutions between modules of various device screens and applications. It can also be used intentionally to corrupt or remove the original content of the image. Therefore, it is of great importance to detect external interference with the images.

In this thesis, we made detection of seam carving applied to images, by using deep learning models, 2-dimensional convolutional neural networks (CNN - Convolutional Neural Network), and fully connected (FC - Fully Connected) commonly used in computer vision. The proposed model was developed as a multi-classifier with four outputs consisting of 0%, 10%, 20% and 40% seam carving classes. ImageNet which is an open source image data set is used in the training of created deep learning networks.

In addition to the original images, training and testing data sets were obtained using images with reduced dimensions of 10%, 20% and 40% by seam carving in the vertical direction. The performance of the model has been scaled with the confusion matrix and the correct classification rate of the test sets. The accuracy analysis of the model was tested on the images, and the results and accuracy value were shown in detail with confusion, precision, f1-score and recall matrices.

BÖLÜM 1. GİRİŞ

Günümüzde teknolojinin gelişmesiyle, cihazlar veya uygulamalar arası görüntülerin dinamik olarak dönüştürülmesi, görüntüleri yeniden boyutlandırma tekniğine olan talebi bir zorunluluk haline getirmektedir. Farklı boyutlardaki cihazlar arasında farklı çözünürlüklere sahip ve aynı zaman da görüntünün ön planındaki nesneleri ve içeriği korunacak şekilde görüntü alışverişi paylaşımı, görüntüyü yeniden boyutlandırmayı daha da önemli hale getiriyor. Örneğin, bir masaüstü bilgisayardan açılan bir duyarlı (responsive) web sitesinde görüntülenen bir görüntü boyutu, mobil cihazından da açılırsa farklı olarak gözükmektedir. Klasik görüntü işleme yöntemleri olan ölçekleme ve kırpma en yaygın görüntü yeniden boyutlandırma teknikleridir, bu yöntemler görüntünün içeriğini dikkate almaz. Ölçekleme, görüntüdeki piksel sayısını artırarak veya azaltarak görüntünün boyutunu büyütür veya küçültür. Kırpma ise bir görüntüden bazı çevresel alanların kaldırılmasıdır. Standart görüntü ölçeklendirme, yeniden boyutlandırma sırasında görüntü içeriğini dikkate almadığı için gözle görünür bozukluklara neden olacağından ve kırpma ise veri kayıplarına sebep olacağından yeterli değildir. Bu sebepten dolayı, araştırmacılar yeniden içeriğe duyarlı boyutlandırma yöntemleri keşfetme çabasına girmişlerdir.

2007 yılında Avidan ve Sharma [1] oldukça başarılı bir yeniden boyutlandırma yöntemi geliştirdiler. Geliştirilen bu yöntemde görüntünün yüksekliğini veya genişliğini azaltmak için en düşük enerji (önemsiz) değerine sahip piksel yollarını teker teker çıkarılmaktadır. Görüntünün boyutunu büyütmeyi ise düşük enerjiye sahip piksel yolu ile ve komşu piksel arasına interpolasyon ile oluşturulmuş yapay piksel yollarını ekleyerek gerçekleştirdiler. Geliştirilen bu yöntem standart ölçeklendirme yöntemlerinin birçok dezavantajını yok ederek görüntülere daha iyi kalite sağlamış ve seam carving (piksel yolu çıkarma) olarak adlandırdılar.

Seam carving veya piksel yolu çıkarma, görüntü içeriğın mümkün olduėunca ön planındaki nesnelere dokunmaz. Görüntüdeki önemsiz piksel deėerlerini her iterasyon da teker teker sildiėinden ve görüntülerde çok az veya insan gözü tarafından algılanamayacak kadar bozukluklar oluşabilir. Her sütundan veya her satırdan birer birer piksellerin silinmesi görüntünün çerçeve yapısını korunmasını sağlamaktadır. Bu sebepten dolayı kırpma ve ölçeklendirme yöntemlerinden daha etkili bir görüntü yeniden boyutlandırma tekniklerinden biri olmuştur. Seam carving, bir görüntünün piksel önemini tanımlayan bir enerji fonksiyonu (optimal seam) kullanmaktadır. Bir optimal seam, görüntüdeki düşük enerjili piksellerin yukarıdan aşağıya veya soldan sağa bağlantılı bir yoldur. Böylece optimal seam'i kaldırarak veya ekleyerek, bir görüntünün yüksekliğini ve genişliğini azaltabilir veya büyütebilir.

Seam carving, kırpma ve ölçeklendirme yöntemlerine nazaran işlem hızı bazı hesaplamaların yapılmasından dolayı daha yavaştır. Kırpma yönteminde belirtilen pencere boyutunun haricindeki alanları herhangi bir hesaplama yapılmadan doğrudan atılır. Bundan dolayı en hızlı yeniden boyutlandırma yöntemlerinden biridir. Ölçeklendirme yönteminde ise görüntüyü küçültürken bazı pikselleri birleştirir ve görüntüyü büyütürken ise komşu piksellerin ortalamasını alarak ekler. Seam carving'de ise bu iki yöneme göre daha karmaşıktır. İlk olarak enerji fonksiyonuna ilişkili olarak enerji haritasının çıkarılması oldukça zaman alıcıdır. Bulunan düşük enerji (optimal seam) deėerlerini çıkarıldıktan sonra kalan görüntü piksellerini yukarıdan aşağıya ya da soldan sağa kaydırır.

Seam carving yeniden boyutlandırmanın yanı sıra kullanımı, örneėin Photoshop CS4 ve GIMP gibi birçok yaygın görüntü düzenleme yazılımlarında bir fonksiyonel olarak dâhil edilmiştir. Seam carving farklı amaçlar için de kullanılmaktadır. Görüntüdeki optimal seam deėerlerini silerek resimlerin ön planındaki nesnelere dokunmadan, resimlerin estetik açıdan güzelleştirilmesi ve çözünürlüğü korumasında olumlu sonuçlar vermiştir [2]. Seam carving avuç izi tanımada da kullanılmıştır [3]. Geliştirilen bu model, optimal piksel çıkarma yerine yüksek enerjiye sahip (önemli piksel) yolları bulur ve eşleşen avuç izleri ile mukayese eder. Bir başka örneėi ise, görüntünün ön planındaki nesneleri silmek içinde kullanılmasıdır. Görüntü sahteciliėi

genellikle kötü niyetli kişiler tarafından kamuoyunda tanınmış kişilerin itibarını zedelemek için veya etik olmayan davranışları göstermek için kullanılabilir [1]. Bu tür sahtecilikleri tespit etmek için günümüzde araştırmacılar çeşitli yöntemler geliştirmeye devam etmektedirler. Bu tez çalışmamızda, dijital JPEG görüntüler sayesinde, seam carving uygulanan görüntülerin nasıl gerçekleştirildiği tespit edilmiştir.

1.1. İçeriğe Duyarlı Görüntü Yeniden Boyutlandırma Tekniği

Hâlihazırda popüler içeriğe duyarlı görüntü yeniden boyutlandırma algoritmalarından birisi seam carving algoritmasıdır. Dijital çağımızda internette bulunan resim ve videolar gibi multimedya içerikleri her geçen gün artmaktadır. Multimedya içeriklerine erişmek için farklı çözünürlük ve en boy oranına sahip çeşitli görüntüleme cihazları kullanılır. Örneğin, çeşitli ekran boyutundaki televizyon, bilgisayar, tablet, cep telefonları, akıllı saatler ve responsive HTML web sayfaları. Görüntüleri çeşitli ekran boyutlarına dinamik olarak sığdırmak için, görüntünün içeriklerini koruyabilen verimli görüntü yeniden boyutlandırma yöntemleri gereklidir.

Görüntüleri daha kullanılabilir hale getirmek için görüntü işleme uygulamalarında görüntüler çeşitli boyutlara dönüştürülür. Standart ölçekleme ve kırpma görüntü işleme yeniden boyutlandırma yöntemleri görüntü bozukluklarına ve veri kaybına sebep olduğundan bu yöntemlerin yerine görüntünün ön planındaki nesnelere dokunmadan önemsiz piksel değerleri birer birer çıkarak görüntüyü herhangi bir bozukluk veya veri kaybına sebep olmayan içeriğe duyarlı yeniden boyutlandırma (seam carving algoritması) kullanılmaktadır.

Görüntüler bilgisayarda satır ve sütundan oluşan matris olarak tutulmaktadır. Görüntü matrisinin her bir hücresine piksel olarak adlandırılır. Seam carving algoritması görüntünün piksellerinden yola çıkarak, görüntüdeki önemli bölgeleri belirlemek için bir enerji fonksiyonu kullanarak enerji haritası oluşturur. Dinamik bir programlama yaklaşımı kullanarak görüntüyü yukarıdan aşağıya veya soldan sağa (yata veya dikey) boyutlarına bağlı olarak her bir piksel yolu için bir değer tahsis etmektedir, en az

öneme sahip pikseller en düşük enerji değerine ve en önemlileri ise en yüksek enerji değerine sahiptir. Görüntünün boyutunu büyütmek veya küçültmek için art arda optimal seam'i ekler yada çıkarır. Her bir iterasyonda düşük enerjiye (optimal seam) sahip piksel yolları çıkarıldığından dolayı görüntülerin ön planındaki nesnelere çok yüksek oranda seam çıkarılmadığı sürece insan gözü tarafından algılanmayacaktır. Bir seam, bir görüntü üzerinde yukarıdan aşağıya veya soldan sağa, enerji fonksiyonu tarafından tanımlanan 8 bağlantılı optimum piksel yoludur. Bir görüntünün yeniden boyutlandırmak için sırasıyla yüksekliğini ve genişliğini etkileyen, dikey seam ve yatay seam dikkate alınır.

1.2. Seam Carving Tespiti

Dijital görüntülerin geniş çaplı kullanım nedeniyle, geçmişten günümüze farklı şekillerde birçok görüntü işleme yöntemleri geliştirilmektedir, bu yöntemlerin müspet yönlerinin yanı sıra menfi yani olumsuz yönleri de mevcuttur. Özellikle dijital görüntülerin adli olarak gerçek olup olmadığının analiz yapılması ve incelenmesi araştırmacıların son zamanlarda popüler konularından biri olmuştur. Günümüzde popüler olan seam carving algoritması görüntüleri küçültme, genişletme ve görüntüdeki nesneleri silme işlemlerinde başarılı bir yöntemdir. Bunlarla birlikte, seam carving veya yeniden boyutlandırma, görüntünün ön planındaki görüntülerine müdahale için de kullanılabilir, bu da bilgi güvenliği ile ilgili bir sorun olarak ortaya çıkmakta ve sahtekârların önünü açmaktadır.

Seam carving veya içeri duyarlı yeniden boyutlandırma tespiti, dijital görüntülerin doğruluk analizinin yanı sıra, sahtekârlıkları, yapay olarak oluşturulmuş görüntüleri, genellikle sahtecilik tespitini önlemek için kullanışlı bir yöntemidir.

1.3. Literatür Taraması

Seam carving veya piksel yolu çıkarma algoritmasının uygulanıp uygulanmadığının tespiti ile alakalı birkaç makine öğrenme ve derin öğrenme çalışmaları mevcuttur. Geçmişten günümüzdeki çeşitli yöntemlerle seam carving tespiti ikili sınıflandırma

olarak geliştirilmektedir. İlk çalışma, 2007 yılında Avidan ve Sharmanın muazzam bir yeniden boyutlandırma yöntemi geliştirmesinden iki yıl sonra, görüntüler üzerinde sahtekarlık tespitini, seam carving kullanarak makine öğrenme tabanlı yöntemi geliştirmesidir, bu çalışmada (Discrete Cosine Transform-Ayrık Kosinüs Dönüşümü) ve Markov özelliği JPEG görüntüler kullanarak, görüntüden seam eklenip çıkarıldığı durumlar sınıflandırır, farklı histogramlarla gerçekleştirmesi sayesinde test sonucu %80 - %85 kadar çıkmaktadır [4]. Daha sonra Fillion ve Sharma [5], enerji tabanına dayalı özelliklerden oluşan, yeni bir model önerilmiştir. Görüntünün gardiyan histogramını hesaplayarak dört grup özellik, (Decision Support Machine - Karar Destek Makinesi)'nde eğitmek için kullanmışlar. Bu özellikleri sıralarsak, enerji tabanına dayalı özellik, Mutlak Moment Dalgac yani İstatistiksel tabanlı özellik (wavelet absolute moments) , seam davranış tabanına dayalı özellik ve tekrardan seam çıkarma tabanına dayalı özelliklerden oluşmaktadır.

Başka bir çalışmada [6] görüntülere seam carving uygulanıp uygulanmadığı tespiti ve ek olarak seam carving konumunun ve miktarının kenar bilgisi yardımıyla SIFT (Scale Invariant Feature Transfer - Ölçekten Bağımsız Özellik Dönüşümü) tabanlı tespiti gerçekleştirilmiştir. Orijinal ve işlenmiş görüntüler üzerinde ardışık SIFT noktaları karşılaştırılarak arasındaki mesafe farkları hesaplanıyor ve eğer bu fark sonucu pozitif olursa görüntüden seam çıkarıldığını şayet farkı negatif ise görüntüye seam eklendiğini göstermektedir.

S.J. Ryu ve diğerleri seam carving tespitini ortaya çıkarmak için seam carving süreç özelliklerinden yararlanarak bir yöntem önermişlerdir [7]. Önerilen bu yöntemle göre görüntüden düşük enerjiye sahip piksel yolları çıkarılırsa, görüntüdeki ortamla enerjisi artmaktadır. Bu özelliklerden yolla çıkarak görüntü enerjisi ile ilgili 14/ondört istatistiksel özellik çıkarılmıştır. Bu özellikler ortalama enerji, standart sapma, ortalama satır enerjisi, ortalama sütun enerjisi, iki yön için: maksimum seam, minimum seam, seam farkı, ortalama ve ortalama enerji farkı. Bu özellikler Karar Destek Makinesi'de test edilerek eğitilmiştir. Toplam 8028 görüntü UCID [8] veri tabanı kullanılarak, görüntüden %50 çıkarılmış seam yollarının tespiti %93.50 oranında bulunmuştur.

[9]'da Change ve diğerleri, blok yapay özellikler matrisine (Blocking Artifact Characteristics Matrix - BACM) dayalı olarak, orijinal görüntü bilgisi olmadan doğal görüntülerde seam carving'i tespit etmek için bir yöntem önermişlerdir. Ayrıntılı olarak, orijinal JPEG görüntüler için, BACM'ı düzenli simetrik şekilleri sergiler ve bozulan (ölçeklenen) görüntüler için BACM'ı normal simetrik özelliği yok edilir. Görüntülerden BACM'yı bulduktan sonra BACM'den gelen görüntüyü orijinalliğini veya seam carving uygulanıp uygulanmadığını tespit etmek için 18 özellik ortaya çıkarılır ve destek vektör makinesinin (Support Vector Machine - SVM) eğitiminde kullanılır. Test sonucu %50 küçültülen resimlerde başarı tespit oranı %93.24 ve %50 büyütülen resimlerde ise %94.77'ye kadar çıkmıştır. Bu yöntemde blokların istatistiksel olarak incelenmesi zekice bir yoldur. Ama dezavantajı ise işlenmemiş JPEG kaynak görüntülerde yanlış hizalama sorunu olmamasıdır.

Genişletilmiş [10] bildiri raporuna göre, sıkıştırılmamış görüntülere uygulanan seam carving tespitinin performansı önemli ölçüde düşmektedir. Daha sonra seam carving uygulanmış JPEG görüntüler üzerinde Liu ve diğerleri [11] kalibre edilmiş komşu eklem yoğunluğunu ve Richmodel [12] tabanlı özellikleri önermişlerdir. Bu çalışma daha sonra [13][14] tarafından geliştirilmiştir.

Wei ve diğerleri [15]'da Seam carving tespiti için resimler üzerinde yamalama analiz yöntemini geliştirmişler. Bu yöntemde görüntüler, bir biriyle uyumlu dokuzar yama, 2×2 mini kareler şeklin de küçük alt görüntülere ayrılmış olarak oluşturulur. En uygun yamaya karar veren bir hakem görüntü mevcut olup interpolasyon olarak komşular arasında yamalar oluşturulmaktadır. Her bir küçük alt görüntülere ayrılmış yama ile hakem yaması arasındaki benzerliği karşılaştırarak, en benzer olanı optimal yama olarak kabul edilir ve sıfırdan sekize kadar olan indeksleme verilen yerel bölgeye atanır. Sonuç olarak, her bir ögenin belirtilen konumu için optimal yamanın indekslendiği bir indeksleme 2D dizisi oluşturulur. Son olarak, indeksleme, 2D dizisinden çıkarılan Markov özellikleri seam carving'i tespit etmek için uygulanır. Bu yöntem dikey yönündeki %20, %30 ve %50 seam carving uygulanmış görüntülerin tespitin doğruluk oranı %92.2 - %95.8'e kadar çıkmıştır.

Ryu ve diğerleri [16] çalışmasında, sıkıştırılmamış görüntülerde seam carving izini ortaya çıkarmak için belirli bir görüntünün enerji dağılımını ve gürültü seviyesini ölçen on sekiz enerji temelli özelliği önermiştir. Bu çalışmadan esinlenerek Yin ve arkadaşları [17]'i geliştirmişlerdir. Bu çalışmada Ryu ve diğerlerin çalışmasına benzer olarak on sekiz enerji özelliğine ilave olarak resmin yarısına ait bilgi içeren ve enerji değişimini yakalamak için 6 özellik modeli eklenerek toplam yirmi dört özellik modeline yükseltmişler. Ayrıca önerilen tüm özellikler piksel alanı yerine Yerel İkili Örüntüler (LBP – Local Binary Pattern) [18], kodlanmış görüntülerden çıkarılır. [19]'da ise bu çalışmanın devamı olarak, görüntünün yerel bozukluklarını ortaya çıkarmak için kullanılacak tüm görüntüler YİÖ domenine dönüştürülür. Seam carving uygulanmış görüntülerde bozukluklar tamamında değil de, görüntünün yerel bölgelerinde oluşmaktadır. Piksel yolu çıkarma tespiti dikey ve yatay yönlerinde sırasıyla %10, %20, %30 seam carving uygulanmış görüntüler üzerinde YİÖ tabanlı olarak tespit gerçekleştirilmiştir. Test ve deneyler sonucu yüksek başarı oranı yakalamışlardır [19]. Kullanılan görüntülerin belirtilmiş boyutundan büyük olduğu zaman başarı oranında düşüşler oluşmaktadır [20].

Dengyong Zhang ve diğerleri [21], Seam carving yerel dokuları değiştirdiğinden, Weber Yerel Tanımlayıcı (WLD - Weber Local Descriptor) ve Yerel İkili Örüntüler olmak üzeri seam carving sahteciliğini tespit etmek için bu iki yaklaşımı kullandılar. Spesifik olarak, WLD ve YİÖ'nin histogram özellikleri, kullanılacak görüntülerde ilk olarak bloklara bölünür ve hem YİÖ tabanlı hem de WLD tabanlı histogram özellikleri her bloktan çıkarılır. Daha sonra, Kruskal-Wallis [22] istatistiği, daha ayırt edici özelliklerinin alt kümesini seçmek için kullanılır. Son olarak, destek vektör makinesi, görüntünün seam carving uygulanıp uygulanmadığını değerlendirmek için sınıflandırıcı olması için kullanılır.

[23] bu çalışmada ise seam carving izini tespit etmek için komşu pikseller arasında yapılan değişiklikleri istatistiksel olarak gösteren bir hibrit (karışım) modeli önermişlerdir. Her bir görüntü için önerilen özellik modeli, 2048-D LDP (Local Derivative Pattern – Yerel Türev Örüntüsü) özellikleri, 324-D Markov özellikleri ve 686-D SPAM (Subtractive Pixel Adjacency Model - Çıkarmalı Piksel Bitişiklik

Modeli) özelliklerinden oluşan toplam 3058-D özellik vektörü ile temsil edilmektedir. LDP, 8 bitten oluşan yüksek dereceli tanımlayıcıdır. Yüksek pikseller ile orta pikseller arasındaki ilişkiyi tanımlar. Markov özelliği iki bitişik piksel arasındaki ilişkiyi gösterirken SPAM özelliği ise normalde üç veya daha fazla ardışık ve bitişik piksel arasındaki ilişkiyi temsil etmektedir. Bu özellikler SVM’de eğitilmiştir. Sırasıyla %5, %10 ve % 20 azaltılmış görüntülerde %66, %75 ve %96’ya kadar başarı oranı gösterebilmektedir.

Luiz ve diğerleri [24], bu çalışmada derin öğrenme konvolüsyon sinir ağlarını ve YİÖ tabanlı yaklaşım kullanarak görüntüler üzerinde seam carving uygulanıp uygulanmadığının tespitini gerçekleştirilmiştir. Önerilen bu yaklaşımda, konvolüsyon sinir ağı, içeriğine müdahale edilen görüntüleri öğrenmesine yardımcı olabilecek ve anlamlı özellikleri elde etmek için YİÖ tabanlı tanımlayıcıları kullanarak konvolüsyon sinir ağı eğitilmiştir. Sonuçlar önceki yaklaşımlardan daha iyi bir doğruluk oranına sahiptir. %3, %6, %9, %12, %15, %18, %21, %30, %40 ve %50 oranlarında çıkarılan seam’lerin tespit oranı sırasıyla %81,46, %83,50, %81,72, %84,21, %87,51, %89,73, %88,91, %91,23, %95,12, %98,90 başarı gösterebilmektedir.

Jingyu Ye ve diğeri [25], çalışmasında derin öğrenme tabanlı seam carving, işlenmiş dijital görüntüler üzerinde, seam carving tespiti gerçekleştiren bir konvolüsyon sinir ağı modelini önermişlerdir. Önerilen bu modelin ilk giriş katmanında orijinal ve seam carving uygulanmış görüntüler HPF (High Pass Filter - Yüksek geçiren filtre)’den geçirilerek gri tonunda, konvolüsyon sinir ağında eğitilmiştir. Dikey ve yatay yönünde %5, %10, %20, %30, %40 ve %50 seam carving ile azaltılmış görüntüler üzerinde seam carving tespiti gerçekleştirilmiştir. Eğitilen ağın performansı ise sırasıyla dikey yönünde:

- a) %90,37
- b) %95,18
- c) %97,84
- d) %98,84
- e) %99,21

f) %99,56

Olarak ve yatay yönünde ise sırasıyla

a) %93,99

b) %96,71

c) %98,55, %99,08

d) %99,45

e) %99,56

Oranında başarı gösterebilmektedir.

Bu [24] çalışmada, seam carving uygulanmış görüntüleri tespit etmek için derin bir sinir ağı mimarisini önermişler. %10, %20, %30, %40 ve %50 seam eklenen ve seam çıkarılan görüntüler üzerinde seam carving tespiti gerçekleştirilmiştir. Görüntüler 256 (H x W) piksel boyutunda olup, RGB'den gri tonuna dönüştürülerek konvolüsyon sinir ağı modelini eğitmişler ve sonuçları VGGNet, Xception, ResNet ve Bayar modelleriyle karşılaştırmışlardır. %10, %20, %30, %40 ve %50 uygulanmış seam carving görüntüler üzerinde sırasıyla 88,27, 94,46, 97,06, 98,07, 98,16 ve ortalama 95.39 oranında karşılaştırılan ağlara göre, geliştirilen konvolüsyon sinir ağı daha iyi performans göstermektedir.

Wonhyuk Ahn ve diğerleri [26] seam carving sahteciliğini belirlemek için derin konvolüsyon sinir ağı adlı çalışmasında, 5 blok tipinden (BT-1'den BT-5'e) oluşan ve her blok ayrı özellikleri içeren, ILFNet mimarisi önermişler. Görüntülere %10, %20, %30, %40 ve %50 oranlarında seam carving uygulayarak önerilen ağda eğitilmiştir. Her bir sınıfa ait doğruluk oranı sırasıyla:

a) %88.17

b) %94.93

c) 98.40%

d) %99.43

e) %99.53

Çıkararak seam carving uygulanıp uygulanmadığının tespiti gerçekleştirmişler.

1.4. Tezin Amacı

Bu tez çalışmamızın amacı, seam carving tespitini derin öğrenme tabanlı CNN modeli kullanarak gerçekleştirmektir. Geliştirilen derin öğrenme modeli ile, görüntülerden yüzdelik oranında azaltılan optimal seam'lerin tespitini literatürde sıklıkla incelenen ikili sınıflandırma seam carving tespitinden farklı olarak, seam carving seviyesini çoklu sınıflandırma tespiti gerçekleştirmektir. Girdi olarak, seam carving uygulanan orijinal veya 0, %10, %20 ve %40 görüntüleri içeren veri setlerini, derin öğrenme modelini eğitmek amacıyla kullanılmıştır. CNN modeli renkli JPEG formatında görüntüler ve Yerel İkili Örüntü uygulanmış görüntülerle eğitilmiştir. Eğitim sonuçlarına göre eğitilen modelin doğruluk oranı RGB görüntülerde %84 ve YİÖ görüntülerde ise %88 kadar çıkmıştır. Aşağıdaki bölümlerde önerilen modelin doğruluk analizi çeşitli matrisler kullanılarak detaylı şekilde açıklanacaktır.

BÖLÜM 2. YÖNTEM VE MATERYALLER

Bu bölümde, seam carving algoritmasının tespitini gerçekleştirmek için kullanılan yöntemler ve materyaller açıklanmaktadır. Seam carving algoritması, derin öğrenme CNN modelinin tasarımı, ImageNet veri seti, modelin performans ölçme ve değerlendirme matrisleri ve yerel ikili örüntü yöntemleri hakkında detaylı olarak bilgi verilmiştir.

2.1. Seam Carving Algoritması

İçeriğe duyarlı yeniden boyutlandırma algoritmanın çalışma mantığı, görüntüyü oluşturan pikselleri belirlemek için bir enerji fonksiyonu kullanmasıdır. Enerji fonksiyon sayesinde görüntünün piksel değerlerinin yüksek enerji veya düşük enerjiye sahip olduğu yani görünürlük önemi belirlenip bir enerji haritası oluşturulur. Düşük enerji piksel değerlerinden oluşan optimal piksel yolu (optimal seam) yatay olarak sağdan sola ve dikey olarak ise yukarıdan aşağıya birer birer çıkarılır. Böylece görüntünün ön planındaki nesneler yüksek enerji piksel değerlerine sahip olduğu için herhangi bir bozulmaya uğramaz. Görüntüden büyük oranda optimal seam çıkarılmadığı sürece insan gözü tarafından algılanamaz.

Diğer klasik standart ölçekleme ve kırma yöntemlerine göre seam carving algoritması daha başarılı bir yeniden boyutlandırma yöntemlerinden biridir. Genel olarak seam carving algoritması enerji hesaplama, seam belirleme ve seam silinmesi olarak üç aşamada gerçekleşmektedir. Tüm bu aşamalar aşağıda detaylı olarak açıklanmıştır.

2.1.1. Enerji hesaplaması

Orjinal Görüntü

Enerji haritası



Şekil 2.1. Orjinal görüntü (dikey optimal seam yolu) ve enerji haritası

Seam carving algoritmasında ilk adım, görüntüyü yeniden boyutlandırmadan önce, görüntüdeki her pikselin enerjisini hesaplamasıdır. Şekil 2.1. görüntün dikey optimal seam yolu ve enerji haritası. Enerji değeri, her bir görüntü pikselinin görünürlük açısından önemini belirtmektedir. En düşük enerji değerine sahip pikseller görüntünün önemli bölgelerini içermeyen piksellerdir. Görüntünün piksel önemini tanımlayan enerji fonksiyonudur. Avidan ve Shamir [1]'de birçok enerji fonksiyonunu önermişlerdir. Çift-gradyan (dual-gradient) basit bir enerji fonksiyonudur. Aşağıda gösterilen, (2.1 denklem)'inde tanımlandığı gibi görüntü pikselinin x gradyan ve y gradyanın toplamından oluşmaktadır.

$$e(I) = \left| \frac{\partial}{\partial x} I \right| + \left| \frac{\partial}{\partial y} I \right| \quad (2.1)$$

Yukarıdaki denklem, her bir pikselin enerjisini hesaplamak için kullanılır. Enerji değerleri, bir pikselin komşu piksellere göre ne kadar görünür (önemli) olduğunu ölçer.

x gradyanı, belirli bir piksel ile sol ve sağ komşu piksellerin arasındaki farkıdır. y gradyanı ise, belirli bir piksel ile üst ve alt komşu piksellerin arasındaki farkıdır.

2.1.2. Seam belirleme

Görüntünün her pikselinin enerjisini tanımladıktan sonra, bir sonraki adım, enerji matrisi işlemleridir, dikey seam tanımlanması için matrisin yukarıdan aşağıya, düşük enerji değerine sahip pikseli ve yatay seam belirlemek için ise matrisin soldan sağa düşük enerji değerine sahip pikseller seçilerek gerçekleştirilir. Bir optimal seam, görüntünün yukarıdan aşağıya (dikey seam) veya soldan sağa (yatay seam), düşük enerji piksellerine bağlı bir yoldur. Hesaplanan enerji değeri ile düşük enerjiye sahip yata veya dikey pikseller tanımlanabilir. Bir görüntün yatay ve dikey, $n \times m$ boyutundaki piksel yolları aşağıdaki (2.2) (2.3) denklemler ile hesaplanır.

$$S^v = \{S_p^v\} = \{x(p), p\}_{p=1}^i, \text{ where } \forall p, |x(p) - x(p-1)| \leq 1 \quad (2.2)$$

$$S^h = \{S_q^h\} = \{y(q), q\}_{q=1}^j, \text{ where } \forall q, |y(q) - y(q-1)| \leq 1 \quad (2.3)$$

x burada $[1.....i]$ den $[1.....j]$ ve y ise $[1.....j]$ den $[1.....i]$ 'ye kadardır.


Kümülatif minimum enerji matrisi (Cumulative Minimum Energy Matrix) ile en önemsiz (düşük) enerjili piksel yolu elde edilmektedir. Kümülatif minimum enerji matrisi, enerji haritasının ilk satırı değiştirilmeden, ikinci satırından başlayarak düşük enerjiye sahip piksel değerlerini alt satıra kadar takip ederek elde edilmektedir. (Denklem 2.4)'de ilk satır aynısı ve sonraki satırlar ise ilgili piksel ile üst minimum komşu piksel değerlerinin toplanmasından oluşturulur.

$$M(p, k) = f_{\text{enerji}}(p, q) + \min(M(p-1, q-1), M(p-1, q), M(p-1, q+1)) \quad (2.4)$$

Görüntünün enerji haritası Şekil 2.1.'de optimal seam'n bulunması gösterilmiştir.

Dikey olarak optimal seam belirlenmesi, enerji matrisinin ilk satırını aynı kalması ve sonraki satırlarda ise komşu değerlerin minimum bir üst enerji değerler ile toplanmasıdır. Sağ ve sol taraf, satır başı enerji pikselleri her zaman iki üst komşuya ve ortada ki enerji pikselleri ise 3 komşuya sahiptir. Matrisin son satırına kadar toplanarak devam eder. Böylelikle optimal seam belirlenmiş olur.





Şekil 3.2. Optimal seam'ın bulunması

2.1.3. Seam silinmesi

Oluşturulan enerji haritasından en düşük değere sahip enerji pikselleri, optimal seam enerji yolunu belirler. Görüntüden istenilen boyutta kadar bir iterasyon sonucu, optimal seam yolu teker teker kaldırılır. Kaldırılan optimal seam yerlerini doldurmak için dikey yönünü de aşağıdan yukarıya ve yatay yönünde ise sağdan sola kaydırmalar yapılır. Aşağıdaki Şekil 2.3.'de algoritmanın kaba kodu (sözde kodu) gösterilmiştir. Bu tez çalışmasında dikey olarak görüntüden %10, %20 ve %40 olarak Şekil 2.4. deki gibi piksel yolu çıkarılmıştır.


Algorithm 1 Seam Carving – Genişlik Azaltma Algoritması

```


Input :  $I(n \times m)$ ,  $k$ (silinecek seam sayısı)
Output: Büyütlenmiş görüntü  $I$ 
1:  $l \leftarrow$  Giriş görüntüsünü oku
2: for  $p \leftarrow 1, k$  do
3:    $E \leftarrow$  Enerjiyi Hesapla ( $I$ )
4:    $M \leftarrow$  MinKumulatif Enerji ( $E$ )
5:    $M \leftarrow E$ 
6:   for  $i \leftarrow 1, n$  do
7:     for  $j \leftarrow 1, m$  do
8:        $\min_E \leftarrow \min (E_{i-1, j-1}, E_{i-1, j}, E_{i-1, j+1})$ 
9:        $E(i, j) \leftarrow E(i, j) + \min_E$ 
10:    end for
11:  end for
12:   $\text{seam}(n) \leftarrow \min(E(n, :))$ 
13:  for  $q \leftarrow n-1, 1$  do
14:     $\text{seam}(q) \leftarrow \min (E_{\text{solust}}, E_{\text{ust}}, E_{\text{sagust}})$ 
15:  end for
16:   $d \leftarrow I$ 'dan  $\text{seam}(n \times 1)$ 'i çıkar
17:   $d \leftarrow \text{seam}$ 'den sonraki pikselleri sola kaydır
18:   $l \leftarrow d$ 
19: end for
20:  $l' \leftarrow l$ 

```

Şekil 2.3. Seam carving algoritması sözde kodu (dikey seam çıkarma)



Şekil 2.4. Görüntüyü üç farklı yöntem ile dikey olarak boyutunun azaltılması ve optimal seam yolu: standart ölçekleme, kırpma, %40 seam carving




Şekil 2.5. Görüntüyü üç farklı yöntem ile dikey olarak boyutunun azaltılması ve optimal seam yolu: standart ölçekleme, kırpma, %20 seam carving



Şekil 2.6. Görüntüyü üç farklı yöntem ile dikey olarak boyutunun azaltılması ve optimal seam yolu: standart ölçekleme, kırpma, %10 seam sarving

2.2. Konvolüsyon Sinir Ağları (CNN - Convolutional Neural Networks)

Makine öğrenme ve derin öğrenmedeki gelişmeler, bilgisayar görü (CV - Computer Vision) ve görüntü analizi alanlarında hızlı bir gelişime önayak olmuştur. Tüm bu gelişmeler konvolüsyonel sinir ağlarının ortaya çıkması ve ilerlemesiyle mümkün olmuştur. CNN görüntüdeki özellikleri tanıyabilen ve sınıflandırabilen bir derin öğrenme modelidir. Görüntü analizi, sınıflandırma, segmentasyon ve nesne tanıma gibi pek çok işlemi gerçekleştirmek için tasarlanmış çok katmanlı bir sinir ağıdır. CNN derin öğrenme alanında sağladıkları başarıdan dolayı günümüzde yaygın olarak kullanılmaktadır. CNN genel olarak birçok konvolüsyonel katmanı (convolutional layer), relu katmanı, havuzlama katmanı (pooling layer), tam bağlantılı katmanı (Fully Connected - FC), ve softmax ve sigmoid fonksiyonlarından oluşmaktadır. Bir CNN katman mimarisi genel olarak aşağıdaki Şekil 2.7.'teki gibi tasarlanır [27].




Şekil 2.7. CNN tasarım sıralaması

Bir CNN yapısı genel olarak bir girdi katmanı ve sırasıyla birçok konvolüsyon, relu, pool katmanları, bir FC ve bir çıktı katmanından oluşmaktadır.

2.2.1. Konvolüsyon katmanı (Convolution - layer)

Konvolüsyon, sinir ağların ilk ve ana katmanlarından biridir. Konvolüsyon, iki bilgi kümesini birleştiren matematiksel bir işlemdir. Görüntünün özelliklerini idrak etmekten sorumludur. Bu katman tüm görüntüyü tarayan bir filtre uygulayarak, görüntünün özelliklerini çıkarır. Ve uygulanan filtreler, piksel değerlerini içeren özellik haritasını oluşturur. Kullanılan filtre matrisi görüntü matrisinin sol üst köşesinde yerleştirilir. Görüntü ve filtre matrisin indeks değerleri birbirleriyle çarpılarak toplanır ve sonucu üçüncü bir matrisinde tutulur. Her defasında sağa bir piksel kaydırılarak birinci satırdan sonra ikinci satır ve görüntü matrisin sonucu satırına kadar aynı işlem tekrarlanır. Üçüncü çıktı matrisi özellik matrisini oluşturur [28]. Şekil 2.8.'de gösterilmiştir.



Şekil 2.8. Konvolüsyonel katmanın girdi görüntüyü filtreden geçirmesi

2.2.2. ReLU (Düzleştirilmiş doğrusal birim - Rectified linear unit) katmanı

Her konvolüsyon katmanının ardından, genel olarak düzleştirilmiş doğrusal birim katmanı veya diğer adıyla aktivasyon fonksiyonu kullanılır. Bu katmanın amacı, konvolüsyon katmanlarında matematiksel işlemleri yapıldığından dolayı, Ağ doğrusal yapıda olur. Ve ağı doğrusal olmayan yapıya dönüştürür. Yani kısacası konvolüsyon katmanından özellik matrisinin negatif değerlerini sıfıra dönüştürür. Böylece ağı daha hızlı öğrenmesine sebep olur. Aktivasyon fonksiyonunun (denklemi 2.5)'de gösterilmiştir [28].

$$f(x) = \begin{cases} 0 & \text{eğer } x < 0 \\ x & \text{eğer } x \geq 0 \end{cases} \quad (2.5)$$

Yukarıdaki denklemde görüldüğü gibi negatif olan değerler sıfır olur ve büyük olanlar ise aynı olarak alınır. Normalde doğrusal olmayan etkiyi sağlamak için birçok aktivasyon fonksiyonu, örneğin sigmoid ve hiperbolik tanjant gibi fonksiyonlar kullanılır. Ama Relu bu söz edilen aktivasyon fonksiyonlarına göre daha hızlı eğittiğinden dolayı çok tercih edilir.

2.2.3. Havuzlama veya örnekleme katmanı (Pooling layer)

Örnekleme veya havuzlama katmanı ReLu katmanından sonra uygulanan katmanlarından biridir. Konvolüsyon katmanında çıkarılan özellik haritasının


aktivasyon fonksiyonu uygulandıktan sonra matris kanalını sabit tutarak yükseklik ve genişlik boyutunu azaltmak için kullanılır. Özelliklerin azaltılma amacı, kendi başına öğreneme yapamazken, en önemli özellikleri koruyarak bir sonraki katmanın yükünü hafifletmek, eğitilmesi için parametre sayısını azaltır. Ve yeni bir özellik matrisi oluşturur. Özellik matrisinin boyutlarının azaltılması bilgi kaybına sebep olur. Ama avantajı ise bir sonraki kullanılacak ağ katmanının yükünü hafifletmek, modelin ezberlemesini ve karmaşıklığı önlemektir. Havuzlama katmanında kullanılan, max-pooling, average-pooling gibi birçok havuzlama katman çeşitleri bulunmaktadır. En önemli ve en çok tercih edilen max-pooling'dir. Max-pooling'de özellik matrisine, tıpkı konvolüsyon katmanı gibi bir filtre uygulanıp en yüksek değeri bulunur ve yeni bir özellik matrisi oluşturur. Kendi CNN tasarımımda max-pooling kullanma tercih edilmiştir [28].

2.2.4. Tam bağlantılı katmanı (Fully connected layer)

CNN tasarımında tam bağlantılı katman, art arada gelen konvolüsyon, relu ve havuzlama katmanlarından sonra gelir. Tam bağlantılı katman düzleştirme (flatten) katmanı ve dense katmanlarından oluşmaktadır. Düzleştirme katmanı tam bağlantılı katmanın girişini oluşturur. Havuzlama katmanların çıktısını giriş olarak alır, onları düzleştirir ve bir sonraki aşama için girdi olabilecek tek bir vektöre dönüştürür. Dense katmanı, düzleştirme katmanından çıktı vektörünü her birini noda (düğüm)'den geçirerek sınıflandırma tahmini yapmak için çıktıya (Output) sıfır ile bir arası değer atar ve hangi sınıfa ait olduğuna karar verir [28].

2.2.5. Dropout katmanı

Dropout katmanı, tam bağlantılı katmanın içerisinde yer alır, görevi ise ağı ezberleme yapmasını önlemek için kullanılır. Temel mantığı ise ağdan bazı noda (düğüm)'leri kaldırır. Böylece ezberlemeyi önlemiş olur. Şekil 2.9.'de ağı orijinal halı ve b'de ise dropout kullanılmış haldır [28].



Şekil 2.9. Standart CNN ve ağı dropout uygulandıktan sonraki hali

2.2.6. Softmax katmanı

Softmax katmanı veya softmax aktivasyon fonksiyonu olarak da adlandırılır. Bu aktivasyon fonksiyonu çok sınıflı bir problemde her sınıfa ondalıklı olası değer atar. Bu ondalıklı olası değerlerin toplamı 1.0 değerine sahiptir. Bu katman ağı eğitimin normal olduğundan daha hızlı yaklaşmasına yardımcı olur. Softmax, çıktı katmanından hemen önce bir sinir ağı katmanı aracılığıyla uygulanır. Softmax katmanı, çıktı katmanı ile aynı sayıda düğüme sahip olmaktadır [28].

2.2.7. Kayıp fonksiyonu (Loss function)

CNN modelin değerlendirmek için bir yöntemdir. Tahmin edilen değer gerçek değere ne kadar farklı olduğunu anlamamıza yardımcı olur. Eğer kayıp fonksiyonu yüksekse tahmin edilen değer yanlış ve eğer 0/sıfıra'a yakın ise tahmin doğrudur [28].

2.3. Yerel İkili Örüntü (Local Binary Pattern – LBP)

Yerel ikili örüntüler (YİÖ - LBP) yöntemi, 1990'da geliştirilen Doku Spektrumu modelinin özel durumudur [29]. İlk olarak 1994 yılında Ojala ve Harward tarafından geliştirilmiştir [18]. Bu yöntem sınıflandırma için kullanılan görsel tanımlayıcılardan biridir [18]. YİÖ, merkezi bir noktayı kuşatan noktalara bakar ve kuşatan noktaların merkezi noktadan daha büyük veya daha küçük olup olmadığını test eder (yani ikili bir sonuç verir).

YİÖ çalışma şekli ilk olarak görüntüleri griye dönüştürür, görüntüler sıklıkla $n \times n$ 'lik (genellikle 3×3 'lük tercih edilir) piksellere bölünür, bütün pikseller merkezi piksel ile karşılaştırılır. Bunun sonucunda sekiz bitlik ikili sayı grubu bulunur ve böylece sekiz bitlik bir sayı elde edilir. Fakat pikselin değeri, merkez pikselinkinden yüksekse 1/bir, düşükse 0/sıfır kabul edilir. 1/Bir ve 0/sıfırlar saat yönünde dip dibe yazılarak ikili sayı grubu oluşturulur. Eğer merkez piksel tam merkezdeyse 3×3 'den başka pencereler de oluşturulabilir. Böylece, tek şart bütün komşuların merkez pikselle aynı uzaklıkta bulunmasıdır. Tez çalışması dâhilinde, (3×3) pencere kullanılmıştır. Şekil 2.10.'deki 3×3 pencere boyutunu kullanarak, seçilen piksel yoğunluğunun değerleri, örnek görüntüyü 124 değerine sahip hücresinin yerel ikili örüntünün denginin hesaplanması gösterilmiştir.

Bir görüntüye YİÖ uygulanması aşağıdaki gibi dört aşamada gerçekleşmektedir.

- Görüntüdeki her piksel (x, y) için, bir R yarıçapında P komşu pikselleri seçilir.
- P komşu pikseller ile mevcut pikselin (x, y) yoğunluk farkı hesaplanır.
- Tüm negatif farkı olanlara 0 değeri ve tüm pozitif farklara ise 1/bir atanarak bir bit vektörü oluşturacak şekilde oluşturulur.
- P -bit vektörüne karşılık gelen ondalık değere dönüştürülür ve (x, y) 'deki yoğunluk değerini bu ondalık değerle değiştirilir.

Her piksel için YİÖ tanımlayıcısı aşağıdaki (2.6 denklem) gibi tanımlanır.

$$YİÖ(P, R) = \sum_{p=0}^{P-1} (g_p - g_c) 2^p \quad (2.6)$$

Yukarıdaki denklemde g_p ve g_c sırasıyla komşu pikselin yoğunluğunu belirtir. P , bir R yarıçapında seçilen komşu piksellerin sayısıdır. (Denklem 2.7) ise komşu piksellerin değerleri 0/sıfırdan büyük ise 1/bir ve negatif değer ise 0/sıfır olarak alınır.

$$S(X) = \begin{cases} 1, & \text{eğer } x \geq 0 \\ 0, & \text{eğer } x < 0 \end{cases} \quad (2.7)$$

87	96	78	81	74	96	67	98	94
78	84	79	91	79	77	90	76	75
81	87	99	81	90	97	91	79	85
102	101	87	84	78	88	84	90	103
118	111	117	120	114	115	130	123	124
127	142	150	141	137	128	160	152	141
161	122	187	153	141	171	175	178	191
177	192	187	177	184	192	179	180	183
201	199	207	204	189	197	199	200	207


84	78	88
120	114	115
141	137	128

0	0	0
1		1
1	1	1

01111100

124

Şekil 2.10. Seçilen pikselin YİÖ dönüşümü



Şekil 2.11. Merkez pikseli kuşatan komşu piksel

Şekil 2.11. siyah veya beyaz küçük daireler, merkezi pikselden daha az veya daha fazla yoğun olan pikselleri temsil eden örnek sonuçları gösterir. Merkez pikselini kuşatan piksellerin tümü siyah veya beyaz olduğunda, görüntü bölgesi düz (özelliksiz) olarak adlandırılır. Devamlı grup halinde olan siyah veya beyaz pikseller, uniform (köşeler veya kenarlar) olarak adlandırılır. Siyah veya beyaz pikseller arası ileri-geri geçişler bulunuyorsa, non-uniform olarak adlandırılır.

Yerel ikili örüntü algoritması çeşitli alanlarda kullanılmaktadır. Bu yöntem doku analizinde önemli ilerlemeler sağlamaktadır. Hem araştırma hem de çeşitli görüntü uygulamalarda yaygın olarak kullanılmaktadır.

YİÖ Yönteminin ayırt edici gücü ve hesaplama basitliği nedeniyle, önceden doku problemleri olarak görülmeyen, yüz analizi ve duygu analizi gibi, bu tür bilgisayarla görme problemlerinin çoğunda çok başarılı olmuştur [30]. YİÖ yöntemi göz lokalizasyonu tanıma [31], iris tanıma, parmak izi tanıma, avuç içi tanıma, yürüyüş hareketi tanıma, yüz fotoğrafları ile cinsiyet ve stres tanıma tespiti [32][33][34], araç kullanıcılarının yüz şekillerinden yorgunluğunun tespiti [35], bireylerin yaşlarının yaklaşık olarak tespiti [36], manyetik rezonans görüntüleme (MRI - Magnetic Resonance Imaging) ile beyin tümörlerinin tespit etme [37], dijital mamografi kullanılarak kötü huylu kitlelerin tespiti [38], nesnelerin tespiti ve takibi [39], doku analizi ve sınıflandırılması [33], [40], [41], kelebek çeşitlerinin sınıflandırılması [42], virüslerin sınıflandırılması gibi alanlarda olumlu sonuçlar bulunmuştur [43].

Seam carving yöntemi ile uygulanmış görüntülerde yerel ikili örüntünün kullanılmasının amacı; seam carving, teker teker piksellerin çıkarılması istenilen

boyuta ulaşılan denkleştirilir. Bulunan piksel yolunun sağ tarafındaki pikseller (altındaki pikseller yukarı) bir birim kaydırılır. Böylelikle, meydana gelebilecek bozukluklar çıkarılan seam'ın komşu piksellerinde meydana gelir. Bunun anlamı şudur ki, görüntünün bütününde değil de lokal alanlarda bozukluklar oluşacaktır. Bu halde yerel doku tanımlayıcı oluşacak, bozuklukları görünür duruma getirecektir, böylece görüntüden çıkarılan seam'ı belirginleştirir [17].



Kullanılan görüntü veri setlerinde %10, %20 ve %40 dikey olarak seam carving ile boyutları azaltılmış görüntüler YİÖ yöntemine dönüştürülerek, CNN modelimizde eğitilmiştir. Şekil 2.12. gri tonlu görüntülerin YİÖ yöntemine dönüştürüldüğünü göstermektedir.




Gri Tonlu Görüntü



YİÖ Uygulanan Görüntü



Şekil 2.12. Gri görüntü (soldaki) YİÖ uygulanan görüntü (sağdaki)



Şekil 2.13. Gri görüntü (soldaki) YİÖ uygulanan görüntü (sağdaki)

2.4. Performans Ölçüme ve Değerlendirme Matrisleri

Derin öğrenme ve makine öğrenmede, geliştirilen modelin sınıflandırma performansını ölçmek, analiz yapmak ve değerlendirmek için performans ölçme matrisleri kullanılır. Geliştirilen modelimizde, karmaşıklık matris (confusion matrix), kesinlik (precision), recall, F1-score matrisleri kullanılmıştır. Karmaşıklık Matrisi, doğru pozitif (DP), yanlış negatif (YP), doğru negatif (DN) ve yanlış negatif (YN) değerlerinden oluşan bir olasılık matrisidir. Her satırı, tahmin edilecek bir sınıfın örneklerini temsil ederken, her sütunu gerçek bir sınıftaki örnekleri temsil eder veya tam tersidir. Aşağıdaki Şekil 2.14. örneği gösterilmiştir.

		Gerçek Sınıflar	
		Pozitif (1)	Negatif (0)
Tahmin edilen sınıflar	Pozitif (1)	DP	YP
	Negatif (0)	YN	DN

Şekil 2.14. Karmaşıklık matris örneği

Kesinlik matrisi, doğru tahmin edilen pozitif gözlemlerin toplam tahmin edilen pozitif gözlemlere oranıdır.

$$\text{Kesinlik (Precision)} = \frac{DP}{DP+YP} \quad (2.6)$$

Recall matrisi, doğru tahmin edilen pozitif gözlemlerin gerçek sınıftaki tüm gözlemlere oranıdır.

$$\text{Recall} = \frac{DP}{DP+YN} \quad (2.7)$$

F1-score matrisi, kesinlik (precesion) ve recall'ın ağırlık oranıdır.

$$\text{F1-score} = \frac{2*Precision*Recall}{Precision+Recall} \quad (2.8)$$

2.5. ImageNet Görsel Veri Seti


ImageNet, Wordnet [44] hiyerarşisine göre düzenlenmiş milyonlarca görüntülerden oluşan, sınıflandırılmış büyük bir görsel veri tabanı veya veri kümesidir. 20000'den fazla görsel kategori ve 14-milyondan fazla görüntüyü içermektedir. Ücretsiz olarak kullanılabilir. Akademisyenler tarafından bilgisayar görme (Computer Vision – CV) araştırması için tasarlanmıştır. Görüntüler hiyerarşi içerisinde düzenlenir ve etiketlenir [45]. ImageNet bilgisayar görme ilerlemesinde ve gelişmesinde önemli rol oynamaktadır. Özellikle makine öğrenme ve derin öğrenme alanlarında, nesne tanıma, görsel sınıflandırma, nesne yerleştirme ve birçok bilgisayar görüme uygulamaları için kullanılmaktadır [46]. 14-milyondan fazla görüntüyü içeren ImageNet görsel data seti 21841 alt kategorileri içermektedir. Ortalama olarak alt kategori başına 500'den fazla görüntü mevcuttur. Örneğin, en çok olanı hayvan ve cihaz kategorisidir. Hayvan kategorisi, 3822 alt kategori ve 2799K görseli kapsamaktadır. ImageNet'te bilgisayar görüşünde kullanılan, görüntüdeki yerel özelliklerin tespit edilmesine yardımcı olan SIFT yöntemi bulunmaktadır. 1000 alt kategorisi bulunan SIFT özelliklerine sahip 1.2 milyon görüntüyü içerir. ImageNet'teki görüntüler çözünürlük açısından değişiklik gösterir, ancak derin öğrenme modellerinde görüntüleri eğitmek için genellikle 256×256 ve alt boyutları tercih edilir. Birçok derin öğrenme modeli örneğin: VGG [47], ResNet [48], Xception [49], AlexNet [50], LeNet [51], GoogleNet [52], ZFNet vb modeller kullanırlar [53].

BÖLÜM 3. GELİŞTİRİLEN MODEL

Bu bölümde geliştirilen CNN modelini, görsellere uygulanan seam carving tespit etmek için önerilen derin öğrenme ağı ve kullanılan katmanları açıklanmıştır.

3.1. Geliştirilen Konvolüsyon Sinir Ağı (CNN)

CNN modeli sağladıkları başarıdan dolayı bilgisayar görmesinde yaygın olarak kullanılmaktadır. CNN tasarımı ve yapısı ikinci bölümde detaylı olarak açıklanmıştır. Seam carving tespiti için geliştirdiğimiz CNN modeli, 5 konvolüsyon katmanı, 5 max_pooling katmanı ve 1 tam bağlantılı (FC) katmanından Şekil 3.1.'de gösterildiği gibi oluşmaktadır. Geliştirilen Ağ iki şekilde eğitilmiştir. Birincisi RGB tabanlı seam carving uygulanmış görüntüler üzerinde, ikincisi ise YİÖ + Seam carving uygulanan görüntülerdir.




Şekil 3.1. Seam carving uygulanan RGB + geliştirilen CNN yapısı

Geliştirilen CNN modelinde ağ filtrelerinin görüntü boyunca hareketi iki boyutta gerçekleştiği için 2D konvolüsyon katmanları uygulanmıştır. Birinci konvolüsyon katmanında (Conv2d_1) 32 filtre kullanılmaktadır. Ağa giriş görüntüleri (input_ship) $500 \times 500 \times 3$ (en x boy x kanal) boyutunda ve kullanılan çekirdek boyut matrisi ise (kernel-size) 3×3 'tür. Çıktı özellik haritalarının boyutunun giriş özellik haritaları ile aynı olduğu anlamına gelen Same-Padding parametresi kullanılmıştır. Piksellerin giriş matrisi üzerindeki kayma işlemini gerçekleştiren Stride, 1×1 olarak seçilmiştir. Konvolüsyon katmanlarında, tıpkı birinci katman gibi parametreleri aynıdır. Sırasıyla ikinci konvolüsyon katmanına (Conv2d_2) 64 filtre, üçüncü konvolüsyon katmanına (Conv2d_3) 64 filtre, dördüncü konvolüsyon katmanına (Conv2d_4) 128 filtre ve beşinci konvolüsyon katmanına (Conv2d_5) 256 filtre uygulanmıştır.

Havuzlama veya örnekleme katmanı, CNN'de en yaygın olarak kullanılan max_pooling katmanı kullanılmıştır. Konvolüsyon katmanından çıkan özellik haritasının en yüksek piksel değerlerini alır. Max_pooling katmanı parametre olarak, özellik haritasını, pool_size 2×2 filtre ile tarayarak en yüksek değerlerini bularak yeni bir matris oluşturur. Tüm diğer max_pooling katmanlar da pool_size 2×2 parametresini kullanmaktadır. Her bir konvolüsyon katmanı ile havuzlama katmanının arasında bir Relu katmanı (aktivasyon fonksiyonu) kullanılmaktadır.


Tam bağlantılı katmanı, düzleştirme (flatten) katmanı ve dense katmanlarından oluşturmaktadır. Flatten katmanı, tam bağlantılı katmanın giriş katmanıdır. Havuzlama katmanından gelen 2/iki boyutlu özellik matrisini giriş olarak alır. Çıktıyı, vektöre (bir boyuta) çevirir. İlk dense katmanı 512 düğüm (node) olarak belirlenmiştir. Flatten katmanı, çıktı vektörünü her bir düğüm 'den geçirerek sınıflandırma tahmini yapmak için çıktı katmanına verir. En son çıktı (Dense_2) katmanı çoklu sınıflandırma (multi_class) 4 olarak belirlenmiştir. Girilen görüntülerin seam carving uygulanıp uygulanmadığını tahmin etmek için, çıktı katmanı 0/sıfır ile 1/bir arasında bir değer üretir. Bir değerine yaklaştıkça doğruluk oranı artmaktadır. Çıktı katmanında çoklu sınıflandırma için kullanılan softmax aktivasyon fonksiyonu kullanılmıştır. Dense_1 katmanı ile çıktı katman arasında 0.2 değerine sahip dropout fonksiyonu kullanılmıştır. Görevi ise daha önce bahiseldiği gibi ağı ezberleme yapmasını önlemektir.

Şekil 3.2.'de seam carving uygulanan görüntülere YİÖ algoritmasını uygulayarak aynı model katmanlarında eğitilmiştir.



Şekil 3.2. Seam carving + YİÖ + geliştirilen model yapısı

Aşağıdaki Şekil 3.3.'de geliştirilen genel ağı katmanları ve katmanların aldığı parametreleri açıkça göstermektedir



Şekil 3.3. Geliştirilen ağın genel yapısı

BÖLÜM 4. DENEYSEL ALTYAPISI

Bu tez çalışmamız da açık kaynak Keras [54] kütüphanesi ve Python programlama dili kullanılarak derin öğrenme modeli gerçekleştirilmiştir. Derin öğrenme modeli CNN, bilgisayar görmesinde yaygın olarak başvurulmuş iki boyutlu konvolüsyonel katmanı ve tam bağlantılı katmanları kullanılarak oluşturulmuştur. Çoklu sınıflandırmada kullanılan categorical_crossentropy kayıp fonksiyonu ve RMSprop [55] optimize edici (optimizer) fonksiyonu kullanılmıştır.


Geliştirilen derin öğrenme ağı eğitiminde, ILSVRC2012 versiyonu olan ImageNet açık kaynak görüntü seti kullanılmıştır. ImageNet veri tabanındaki bazı örnek görüntüler Şekil 4.1.'de gösterilmiştir. Görüntü eğitim (train) ve test (validation) setlerin boyutları 500×500 (en×boy) oranına eşit ve daha küçük olan görseller kullanılarak elde edilmiştir.

Kullanılan tüm resimler RGB JPEG formatında olup, Enterpolasyon yönteminin en yakın (nearest) metodu ile 500×500 olarak ölçeklendirilmiştir. Orijinal görüntüler ve yeniden boyutlandırılan görüntüler eğitim verileri olarak kullanıldı. Train klasörü 30000-orjinal resim içerirken ve validation klasörü de 10000 orijinal resim içermektedir. Orijinal resim klasörleriyle birlikte train ve validation klasörleri her biri dört klasörden oluşan resim içermektedir.

Orijinal görüntülere dikey olarak seam carving ile %10, %20 ve %40 ölçeklendirme oranlarında uygulanmıştır. Böylece train klasöründe toplam $4 \times 30000 = 120000$ resim ve validation klasöründe de toplam $4 \times 10000 = 40000$ resim içermektedir. Aynı görsel veri setine, orijinal ve seam carving ile yeniden boyutlandırılmış görüntülere YİÖ algoritması uygulanmıştır.

Böylece YİÖ uygulanan train klasöründe toplam $4 \times 30000 = 120000$ görüntü ve YİÖ uygulanan validation klasöründe de 4×10000 görüntü içerir. Tüm görüntü (Seam Carving ve YİÖ) algoritma işlemleri ve modelin eğitilmesi, Intel Coffee Lake Core i5-9300H, CPU @ 2.40-4.1GHz, 8 GB sahip RAM ve NVIDIA GeForce GTX1650 grafik işlemcisiyle kişisel bilgisayar kullanılarak gerçekleştirilmiştir.






Şekil 4.1. ImageNet veritabanından örnek resimler


4.1. Test Görüntülerin Seam Carving Tespit Sonuçları

RGB JPEG formatında olan orijinal ve %10, %20, %40 dikey olarak seam carving uygulanmış görüntüler, Şekil 2.10 de geliştirilen CNN modelinde eğitilmiştir. Eğitilen CNN modelinin seam carving tanıma performansı aşağıdaki gösterilen Şekil 4.2.'de doğruluk değeri %84 ve geçerleme doğruluğu %84 kadar çıkmıştır. Kayıp fonksiyonları train_loss 0.34 iken inerken val_loss fonksiyonda 0.36 kadar azalmıştır.



Şekil 4.2. Doğruluk, geçerleme doğruluğu ve kayıp fonksiyonların grafiği

Sınıflandırma modelinin performans ölçümlerini doğruluk (accuracy) ve kayıp fonksiyonlarıyla ölçmek ve değerlendirmek genellikle çok anlaşılır olmadığından, onun yerine matris fonksiyonları kullanılarak detaylı olarak açıklanabilir. Geliştirilen modelin testi için ImageNet data set’den 360 tane rastgele fotoğraf seçilerek karmaşıklık matrisi, kesinlik, recall ve F1-score metris değerlerini scikit-learn açık kaynak kütüphanesini kullanılarak bulunmuştur. Aşağıdaki Şekil 4.3.’te karmaşıklık matrisi gösterilmiştir.



Şekil 4.3. Test görüntülerin karmaşıklık matrisi

Karmaşıklık matrisi modelin her bir sınıfa ait olduğu doğru ve yanlış sınıflandırma sonuçlarını ayrıntılı olarak açıklamaktadır. Sınıflandırma modeli 4 sınıftan oluştuğu için, karmaşıklık matrisi de 4×4 (satır ve sütun) yukarıdaki Şekil 4.3. gibi doğru etiket ve tahmin edilebilir etiketlerinden oluşmaktadır. Sayısal değerleri incelendiğinde sınıfa ait olan seam carving uygulanmış görüntülerin sonuçları, diğer hatalı sonuçlara göre daha yüksek değere sahip olduğu görülmektedir. Örneğin, %40 uygulanan seam carving oranı için 360 görüntüden 303'ü doğru bir şekilde sınıflandırılmıştır. Ancak bu görsellerden 47-tanesi seam carving uygulanmamış yani 0 sınıfa ait, 1 tanesi %10 ve 9 tanesi ise %20 seam carving uygulanan sınıfa ait olarak sınıflandırılmıştır. 360 görüntüden 345, en yüksek tanımlanan, 0. yani orijinal görüntüler içeren sınıf ve en azı tanımlanan %10 seam carving uygulanan sınıftır.


Matriste gerçek seviye (True level) ile tahmin edilebilir seviye (predicted level) kesiştiği koyu renkli olan noktalar gerçek tahmin edilen değeri göstermektedir. Modelin sınıflandırma sonuçları ayrıca Tablo 4.1.'de gösterildiği gibi doğru pozitif (DP veya True Positive), yanlış pozitif (YP veya False Negative), doğru negatif (DN veya True Negative) ve yanlış negatif (YN veya False Negative) terim oranları açısından değerlendirilerek, kesinlik, recall ve F1-score matris değerleri hesaplanmıştır.

Tablo 4.1. Önerilen modelin performans matrisleri

Sınıf	DP	YP	DN	YN	Kesinlik	Recall	F1-Score
0	345	176	864	55	0.66	0.96	0.78
10	270	6	939	225	0.98	0.75	0.85
20	291	29	918	202	0.91	0.81	0.86
40	303	20	906	211	0.94	0.84	0.89
Matrislerin Ortalaması					0.87	0.84	0.85
Doğruluk (Accuracy) Değeri					0.84		
Geçerleme Doğruluk (Val_ Accuracy) Değeri					0.84		


4.2. YİÖ Tabanlı Seam Carving Tespit Sonuçları

Bu tespit yönteminde seam carving ile %10, %20, %40 ölçeklendirilmiş ve orijinal görüntülere YİÖ uygulanarak, geliştirilen CNN modelinde eğitildikten sonra seam carving tespit performansı Şekil 4.4.'de gösterildiği gibi validation_accuracy %88 kadar çıkmış olup ve kayıp fonksiyonu ise 0.33 değerine düşmüştür.



Şekil 4.4. YİÖ doğruluk, geçerleme doğruluğu ve kayıp fonksiyonların grafiği

Bu tür çalışmalarda geçerleme doğruluk değeri %88 çıkması iyi bir sonuç olduğunun göstergesidir. Seam carving uygulanmış görüntülere YİÖ tabanlı tespiti performansı detaylı olarak aynı RGB de kullanılan matrislerle gösterilmiştir. Karmaşıklık matrisini hesaplamak için RGB'deki gibi 360 rasgele ImageNet data setinden seçilen resimlere YİÖ uygulayarak Şekil 4.5.'de gösterilmiştir.



Şekil 4.5. YİÖ uygulanmış örnek görüntülerin karmaşıklık matrisi

Yukarıdaki karmaşıklık matrisinde görüldüğü gibi her bir sınıfa ait tespit edilen görüntüler örneğin, %20 seam carving uygulanan YİÖ görüntülerin 360'tan 314'ü doğru sınıflandırılmış olup, yanlış olarak sınıflandırılan görüntüler, 20 tane resim orijinal, 11 tane resim %10 ve 15 tane resim de %40'lık olarak sınıflandırılmıştır. En yüksek tanımlanan görüntüler ise %40'lık görüntülerdir. En düşüğü ise 360'den 314 görüntüyü doğru tanıyan %20 seam carving uygulanmış sınıfa aittir. Aşağıdaki tablo 4.2.'de detaylı olarak DP, YP, DN ve YN terimleri ve diğer matris değerleri scikit-learn açık kaynak kütüphanesi kullanılarak bulunmuştur.

Tablo 4.2. YİÖ tabanlı önerilen modelin performans matrisleri

Sınıflar	DP	YP	DN	YN	Kesinlik	Recall	F1-Score
0	319	44	954	123	0.88	0.89	0.88
10	318	25	955	142	0.93	0.88	0.90
20	314	59	959	108	0.84	0.87	0.86
40	322	39	951	128	0.89	0.89	0.90
Matrislerin Ortalaması					0.89	0.88	0.88
Doğruluk (Accuracy) Değeri					0.88		
Geçerleme Doğruluk (Val_ Accuracy) Değeri					0.88		

Kesinlik, recall ve F1-score matrisleri 0/sıfır ile 1/bir arasında değer almaktadır, matrislerin değerleri sıfıra yaklaştıkça kötü sonuç üretirken ve bire yaklaştıkça da iyi sonuçlar üretmeye başlamaktadır. Bu iki yöntemi karmaşıklık matrisine bakarak karşılaştırıldığında, örneğin, YİÖ %20'lik seam carving uygulanan görüntülerde 360'tan 314 doğru tespit etmişken, RGB görüntü eğitilen model de ise 360'tan 291'i doğru tespiti edildiği gözlemlenmiştir.

Kesinlik, recall ve F1-score matrislerini karşılaştırıldığında, sınıflara ait matris ortalamaları YİÖ uygulanan görüntülerde, RGB görüntülere göre biraz yüksek olduğu gözükmemektedir. Genel olarak YİÖ seam carving uygulanmış görüntüler, RGB seam carving uygulanmış görüntülere göre etkili ve iyi sonuç vermektedir.

4.3. Görüntülerin Katmanlar Arası Görünümü

Derin öğrenme modelleri, çoğu kişi tarafından okunabilir bir biçimde çıkarılması ve sunulması zor olan öğrenme temsillerine, genellikle kara kutular olarak söylenir. Bu, belirli türdeki derin öğrenme modelleri için kısmen doğru olsa da, konvolüsyon ağları için kesinlikle doğru değildir.

Konvolüsyon ağları tarafından öğrenilen temsilleri görselleştirme oldukça uygundur. Çünkü bu Ağ katmanları büyük ölçüde görsel kavramları temsil eder. 2013 yılından beri, öğrenilen temsilleri görselleştirmek ve yorumlamak için birçok teknik geliştirilmiştir. Bu çalışmamızda Ara Aktivasyonları Görselleştirme (VIA - Visualizing Intermediate Activations) ile gösterilmiştir [56].


4.3.1. Ara aktivasyonları görselleştirme

Bu görselleştirme yöntemi ardışık konvolüsyon katmanlarının girdilerini nasıl dönüştürdüğünü anlamak için elverişlidir. Her bir konvolüsyon filtrelerinin anlamı hakkında fikir sahip olmamızı sağlar.


Bu yönteme belirli bir girdi verildiğinde, bir ağdaki çeşitli konvolüsyon ve havuzlama katmanları tarafından çıkarılan özellik haritalarının görüntülenmesinden oluşmaktadır. Bu yöntem bir girdinin ağ tarafından öğrenilen farklı filtrelere nasıl ayrıştırıldığına dair bir görünüm verir. Görselleştirmek istediğimiz bu özellik haritalarının genişlik, yükseklik ve derinlik (kanallar) olmak üzere 3 boyuttan oluşmaktadır. Her kanal, nispeten bağımsız özellikleri kodlar. Bundan dolayı bu özellik haritalarını görselleştirmenin uygun yolu, her kanalın içeriğini 2D görüntü şeklinde bağımsız olarak çizmektir. Aşağıda Şekil 4.6.'da örnek olarak bir köpek resminin, geliştirilen ağın, konvolüsyon, aktivasyon ve havuzlama katmanlarında görselleştirilmesi gösterilmektedir.




Şekil 4.6. Örnek görüntü



Şekil 4.7. Birinci konvolüsyon katmanının görselleştirilmesi



Şekil 4.8. Birinci aktivasyon katmanının görselleştirilmesi



Şekil 4.9. Birinci max_pooling katmanının görselleştirilmesi

Geliştirilen ağın diğer katmanlarındaki örnek görüntü görünüşleri görselleştirilmesi aşağıdaki Ek1’de gösterilmiştir. Geliştirilen ağın ilk katmanı, çeşitli kenar dikdörtlerinin bir koleksiyonu görevini üstlenmektedir. Mevcut durumda, aktivasyonlar hala ilk resimde bulunan bilgilerin hemen hemen tamamını muhafaza etmektedir. Ağ katmanları ilerledikçe, aktivasyon katmanları giderek daha soyut ve görsel olarak daha az yorumlanabilir hale gelmektedir. Resim, ağ katmanlarında ilerledikçe görüntünün görsel içeriği hakkında giderek daha az bilgi içerirken ve görüntünün hangi sınıfa ait olduğu ile ilgili daha fazla bilgi taşımaya başlar. Katmanın derinliği aktivasyon sıklığı ile artmaktadır. İlk katmanda, tüm filtreler giriş görüntüsünden etkinleştirilir. Fakat sonraki katmanlarda giderek daha fazla filtre boş olur. Bu filtre tarafından kodlanan modelin giriş görüntüsünde bulunmadığı anlamına gelir.

BÖLÜM 5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında günümüzde popüler olan içeriğe duyarlı olarak bilen seam carving görüntü yeniden boyutlandırma algoritması ile boyutları değiştirilmiş görüntülerin derin öğrenme modeli konvolüsyon sinir ağları kullanılarak tespiti gerçekleştirilmiştir. Standart yeniden boyutlandırma yöntemlerine göre seam carving tespit etmek oldukça zordur. Çünkü seam carving’de görüntülerin geometrik değil de piksel değerlerinin önemine göre ele alınıyor olmasındandır.

Tez çalışmasında geliştirilen derin öğrenme CNN modelinde iki tür görüntü üzerinde seam carving miktarının tespiti gerçekleştirilmiştir. Birincisi RGB JPEG formatındaki orijinal görüntüler dâhil olmak üzeri %10, %20 ve %40 dikey olarak azaltılmış görüntülerin tespiti gerçekleştirilmiştir.

İkincisi ise Yerel İkili Örüntü algoritması, kullanılan RGB görüntülere uygulanarak seam carving tespiti gerçekleştirilmiştir. Ağın eğitiminde ImageNet data set’den 500×500 ve küçük olan görüntüler kullanılmıştır. Eğitilen modelin sonuçlarına göre RGB görüntülerde doğruluk oranı (validation accuracy) %84 kadar çıkmıştır. YİÖ uygulanan görüntülerde ise doğruluk oranı %88’e çıkmıştır. Modelin doğruluk analizleri daha iyi anlaşılması için, görüntüler üzerinde model test edilerek, karmaşıklık matrisi, kesinlik, recall matrislerinin sonuçları ve doğruluk değeri detaylı olarak gösterilerek yapılmıştır. YİÖ tabanlı seam carving tespiti RGB görüntülere göre iyi sonuç vermektedir.

Bu tez çalışmasının literatüre katkısı, yeniden boyutlandırılan görüntüler üzerinde ilk olarak seam seviyesinin tespitini gerçekleştirilmesidir. Eğitim ve test için kullanılan görseller toplam 40000 orijinal görüntüden oluşan büyük bir görsel veri setidir. Görüntülerin en küçüğünün boyutu 180×160 ve en büyüğünün ise 500×500 ’dır. Görüntüler bu iki görüntü boyutu arasında farklı boyutlarda olması ve eğitilmesi daha

sonra doğruluk oranlarının bahsedilen değere ulaşması modelin iyi performans gösterdiğinin sonucudur. Görüntüler 500×500 boyutuna yaklaştıkça modelin seam carving tespit etme performansı daha çok artmaktadır. Bu tez çalışmasında ImageNet görsel veri tabanından elde edilen tespit doğruluğu seam carving uygulanan %10, %20 ve %40 görüntülerde, önemli ölçüde iyileştirilmiştir. Fakat daha büyük boyutlardaki görüntülerde yüzdelik oranlarının karıştırılmasında ve daha sık aralıklarda tespiti gerçekleştirilebileceği beklenmektedir. Örnek olarak %3, %5, %8...%50 gibi seam carving uygulanan görüntüleri tespit etmek ve daha iyi performansa sahip, gelişmiş özellikli bir model tasarlamak amaçlanmıştır. Bu konuda gelecekte önemli bir akademik çalışma olabileceğine inanmaktayım. Gelecek çalışmada önerilen ağ modeli seam carving uygulanıp uygulanmadığının tespiti için 2 sınıflı olarak test edilecektir. Ayrıca, farklı veri setlerindeki sabit boyutlardaki görüntüler üzerinde de önerilen ağın performansı değerlendirilecektir.

KAYNAKLAR

- [1] S. Avidan and A. Shamir, "Seam carving for content-aware image resizing," *ACM Trans. Graph.*, vol. 26, no. 99, p. 10, 2007, doi: 10.1145/1239451.1239461.
- [2] K. Li, B. Yan, J. Li, and A. Majumder, "Seam carving based aesthetics enhancement for photos," *Signal Process. Image Commun.*, vol. 39, pp. 509–516, 2015, doi: 10.1016/j.image.2015.07.005.
- [3] T. Cook, R. Sutton, and K. Buckley, "Automated flexion crease identification using internal image seams," *Pattern Recognit.*, vol. 43, no. 3, pp. 630–635, 2010, doi: 10.1016/j.patcog.2009.08.012.
- [4] A. Sarkar, L. Nataraj, and B. S. Manjunath, "Detection of seam carving and localization of seam insertions in digital images," *MMandSec'09 - Proc. 11th ACM Multimed. Secur. Work.*, pp. 107–116, 2009, doi: 10.1145/1597817.1597837.
- [5] C. Fillion and G. Sharma, "Detecting content adaptive scaling of images for forensic applications," *Media Forensics Secur. II*, vol. 7541, p. 75410Z, 2010, doi: 10.1117/12.838647.
- [6] W. Lu and M. Wu, "Seam carving estimation using forensic hash," *MM Sec'11 - Proc. 2011 ACM SIGMM Multimed. Secur. Work.*, pp. 9–14, 2011, doi: 10.1145/2037252.2037255.
- [7] S. J. Ryu, H. Y. Lee, and H. K. Lee, "Detection of content-aware image resizing using seam properties," *Appl. Mech. Mater.*, vol. 284–287, pp. 3074–3078, 2013, doi: 10.4028/www.scientific.net/AMM.284-287.3074.
- [8] G. Stich, M. and Schaefer, "UCID - Uncompressed Colour Image Database," *Proc. SPIE 5307, Storage Retr. Methods Appl. Multimedia.*, vol. 5307, pp. 472–480, 2004.
- [9] W. L. Chang, T. K. Shih, and H. H. Hsu, "Detection of seam carving in JPEG images," *2013 Int. Jt. Conf. Aware. Sci. Technol. Ubi-Media Comput. Can We Realiz. Aware. via Ubi-Media?, iCAST 2013 UMEDIA 2013*, pp. 632–637, 2013, doi: 10.1109/ICAwST.2013.6765516.

- [10] K. Wattanachote, T. K. Shih, W. L. Chang, and H. H. Chang, "Tamper Detection of JPEG Image Due to Seam Modifications," *IEEE Trans. Inf. Forensics Secur.*, vol. 10, no. 12, pp. 2477–2491, 2015, doi: 10.1109/TIFS.2015.2464776.
- [11] Q. Liu and Z. Chen, "Improved approaches with calibrated neighboring joint density to steganalysis and seam-carved forgery detection in JPEG images," *ACM Trans. Intell. Syst. Technol.*, vol. 5, no. 4, 2015, doi: 10.1145/2560365.
- [12] J. Fridrich and J. Kodovsky, "Rich models for steganalysis of digital images," *IEEE Trans. Inf. Forensics Secur.*, vol. 7, no. 3, pp. 868–882, 2012, doi: 10.1109/TIFS.2012.2190402.
- [13] Q. Liu, "Exposing seam carving forgery under recompression attacks by hybrid large feature mining," *Proc. - Int. Conf. Pattern Recognit.*, vol. 0, pp. 1041–1046, 2016, doi: 10.1109/ICPR.2016.7899773.
- [14] Q. Liu, "An approach to detecting JPEG down-recompression and seam carving forgery under recompression anti-forensics," *Pattern Recognit.*, vol. 65, no. August 2016, pp. 35–46, 2017, doi: 10.1016/j.patcog.2016.12.010.
- [15] J. Da Wei, Y. J. Lin, and Y. J. Wu, "A patch analysis method to detect seam carved images," *Pattern Recognit. Lett.*, vol. 36, no. 1, pp. 100–106, 2014, doi: 10.1016/j.patrec.2013.09.026.
- [16] S. J. Ryu, H. Y. Lee, and H. K. Lee, "Detecting trace of seam carving for forensic analysis," *IEICE Trans. Inf. Syst.*, vol. E96-D, no. 5, pp. 1304–1311, 2014, doi: 10.1587/transinf.E97.D.1304.
- [17] T. Yin, G. Yang, L. Li, D. Zhang, and X. Sun, "Detecting seam carving based image resizing using local binary patterns," *Comput. Secur.*, vol. 55, pp. 130–141, 2015, doi: 10.1016/j.cose.2015.09.003.
- [18] T. Ojala, M. Pietikäinen, and D. Harwood, "A comparative study of texture measures with classification based on feature distributions," *Pattern Recognit.*, vol. 29, no. 1, pp. 51–59, 1996, doi: 10.1016/0031-3203(95)00067-4.
- [19] Z. K. Senturk and D. Akgun, "Seam Carving Based Image Retargeting: A Survey," in *2019 1st International Informatics and Software Engineering Conference (UBMYK)*, 2019, pp. 1–6.
- [20] Z. Karapinar Senturk and D. Akgun, "Seam Carving Tespitinde G{ö}r{ü}nt{ü} Boyutunun Karşılaştırmalı Analizi," *ASYU 2016 (Akıllı Sist. Yenilikler ve Uygulamaları Sempozyumu)*, pp. 268–271, 2016.
- [21] D. Zhang, Q. Li, G. Yang, L. Li, and X. Sun, "Detection of image seam carving by using weber local descriptor and local binary patterns," *J. Inf. Secur. Appl.*, vol. 36, pp. 135–144, 2017, doi: 10.1016/j.jisa.2017.09.003.


- [22] Y. Chan and R. P. Walmsley, "Learning and understanding the Kruskal-Wallis one-way analysis-of- variance-by-ranks test for differences among three or more independent groups," *Phys. Ther.*, vol. 77, no. 12, pp. 1755–1762, 1997, doi: 10.1093/ptj/77.12.1755.
- [23] J. Ye and Y. Q. Shi, "An effective method to detect seam carving," *J. Inf. Secur. Appl.*, vol. 35, pp. 13–22, 2017, doi: 10.1016/j.jisa.2017.04.003.
- [24] L. F. S. Cieslak, K. A. Da Costa, and J. Paulopapa, "Seam carving detection using convolutional neural networks," *SACI 2018 - IEEE 12th Int. Symp. Appl. Comput. Intell. Informatics, Proc.*, pp. 195–199, 2018, doi: 10.1109/SACI.2018.8441016.
- [25] J. Ye, Y. Shi, G. Xu, and Y. Q. Shi, *A convolutional neural network based seam carving detection scheme for uncompressed digital images*, vol. 11378 LNCS. Springer International Publishing, 2019.
- [26] S. H. Nam, W. Ahn, I. J. Yu, M. J. Kwon, M. Son, and H. K. Lee, "Deep Convolutional Neural Network for Identifying Seam-Carving Forgery," *arXiv*, vol. XX, no. XX, pp. 1–18, 2020, doi: 10.1109/tcsvt.2020.3037662.
- [27] D. C. He and L. Wang, "Texture Unit, Texture Spectrum, and Texture Analysis," *IEEE Trans. Geosci. Remote Sens.*, vol. 28, no. 4, pp. 509–512, 1990, doi: 10.1109/TGRS.1990.572934.
- [28] I. Goodfellow, Y. Bengio, A. Courville, and Y. Bengio, "Deep learning," in *Deep Learning*, vol. 1, no. 2, MIT press Cambridge, 2016, p. 196.
- [29] L. Wang and D. C. He, "Texture classification using texture spectrum," *Pattern Recognit.*, vol. 23, no. 8, pp. 905–910, 1990, doi: 10.1016/0031-3203(90)90135-8.
- [30] M. Pietikäinen, A. Hadid, G. Zhao, and T. Ahonen, *Local Binary Patterns for Still Images*. 2011.
- [31] I. Choi and D. Kim, "A variety of local structure patterns and their hybridization for accurate eye detection," *Pattern Recognit.*, vol. 61, pp. 417–432, 2017, doi: 10.1016/j.patcog.2016.08.009.
- [32] B. Patel, R. P. Maheshwari, and R. Balasubramanian, "Multi-quantized local binary patterns for facial gender classification," *Comput. Electr. Eng.*, vol. 54, pp. 271–284, 2016, doi: 10.1016/j.compeleceng.2015.11.004.

- [33] A. Hadid, J. Ylioinas, M. Bengherabi, M. Ghahramani, and A. Taleb-Ahmed, "Gender and texture classification: A comparative analysis using 13 variants of local binary patterns," *Pattern Recognit. Lett.*, vol. 68, pp. 231–238, 2015, doi: 10.1016/j.patrec.2015.04.017.
- [34] N. Sharma, A. Dhall, T. Gedeon, and R. Goecke, "Thermal spatio-temporal data for stress recognition," *Eurasip J. Image Video Process.*, vol. 2014, no. 1, pp. 1–12, 2014, doi: 10.1186/1687-5281-2014-28.
- [35] Y. Zhang and C. Hua, "Driver fatigue recognition based on facial expression analysis using local binary patterns," *Optik (Stuttg.)*, vol. 126, no. 23, pp. 4501–4505, 2015, doi: 10.1016/j.ijleo.2015.08.185.
- [36] V. V. Nabiyev and G. Asuman, "LBP Yardımıyla G " or " unt " udeki Ki , sinin Ya , sının Bulunması," vol. 8, no. 1, pp. 27–41, 2011.
- [37] S. Abbasi and F. Tajeripour, "Detection of brain tumor in 3D MRI images using local binary patterns and histogram orientation gradient," *Neurocomputing*, vol. 219, pp. 526–535, 2017, doi: 10.1016/j.neucom.2016.09.051.
- [38] S. V. da Rocha, G. Braz Junior, A. C. Silva, A. C. de Paiva, and M. Gattass, "Texture analysis of masses malignant in mammograms images using a combined approach of diversity index and local binary patterns distribution," *Expert Syst. Appl.*, vol. 66, pp. 7–19, 2016, doi: 10.1016/j.eswa.2016.08.070.
- [39] R. Rai, S. Shukla, and B. Singh, "Reactive Power Based MRAS for Speed Estimation of Solar Fed Induction Motor with Improved Feedback Linearization for Water Pumping," *IEEE Trans. Ind. Informatics*, vol. 16, no. 7, pp. 4714–4725, 2020, doi: 10.1109/TII.2019.2950094.
- [40] F. Bianconi, E. González, and A. Fernández, "Dominant local binary patterns for texture classification: Labelled or unlabelled?," *Pattern Recognit. Lett.*, vol. 65, pp. 8–14, 2015, doi: 10.1016/j.patrec.2015.06.025.
- [41] R. Mehta and K. Egiazarian, "Dominant Rotated Local Binary Patterns (DRLBP) for texture classification," *Pattern Recognit. Lett.*, vol. 71, pp. 16–22, 2016, doi: 10.1016/j.patrec.2015.11.019.
- [42] Y. Kaya, L. Kayci, and M. Uyar, "Automatic identification of butterfly species based on local binary patterns and artificial neural network," *Appl. Soft Comput. J.*, vol. 28, pp. 132–137, 2015, doi: 10.1016/j.asoc.2014.11.046.
- [43] Z. Wen, Z. Li, Y. Peng, and S. Ying, "Virus image classification using multi-scale completed local binary pattern features extracted from filtered images by multi-scale principal component analysis," *Pattern Recognit. Lett.*, vol. 79, pp. 25–30, 2016, doi: 10.1016/j.patrec.2016.04.022.


- [44] C. Fellbaum, "WordNet," *Encycl. Appl. Linguist.*, 2012, doi: 10.1002/9781405198431.wbeal1285.
- [45] Y. Takamitsu and Y. Orita, "Effect of glomerular change on the electrolyte reabsorption of the renal tubule in glomerulonephritis (author's transl)," *Japanese J. Nephrol.*, vol. 20, no. 11, pp. 1221–1227, 1978.
- [46] L. Beyer, O. J. Hénaff, A. Kolesnikov, X. Zhai, and A. van den Oord, "Are we done with ImageNet?," *arXiv*, 2020.
- [47] H. Ke, D. Chen, X. Li, Y. Tang, T. Shah, and R. Ranjan, "Towards Brain Big Data Classification: Epileptic EEG Identification with a Lightweight VGGNet on Global MIC," *IEEE Access*, vol. 6, no. Mi, pp. 14722–14733, 2018, doi: 10.1109/ACCESS.2018.2810882.
- [48] S. Li, J. Jiao, Y. Han, and T. Weissman, "Demystifying ResNet," pp. 1–18, 2016, [Online]. Available: <http://arxiv.org/abs/1611.01186>.
- [49] F. Chollet, "Xception: Deep learning with depthwise separable convolutions," *Proc. - 30th IEEE Conf. Comput. Vis. Pattern Recognition, CVPR 2017*, vol. 2017-January, pp. 1800–1807, 2017, doi: 10.1109/CVPR.2017.195.
- [50] Y. Zhang, J. Gao, and H. Zhou, "Breeds Classification with Deep Convolutional Neural Network," *ACM Int. Conf. Proceeding Ser.*, pp. 145–151, 2020, doi: 10.1145/3383972.3383975.
- [51] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, "A B7CEDGF HIB7PRQTSUDGQICWVYX HIB edCdSISIXvg5r ` CdQTW XvefCdS," *proc. IEEE*, 1998, [Online]. Available: <http://ieeexplore.ieee.org/document/726791/#full-text-section>.
- [52] G. Zeng, Y. He, Z. Yu, X. Yang, R. Yang, and L. Zhang, "Preparation of novel high copper ions removal membranes by embedding organosilane-functionalized multi-walled carbon nanotube," *J. Chem. Technol. Biotechnol.*, vol. 91, no. 8, pp. 2322–2330, 2016, doi: 10.1002/jctb.4820.
- [53] K. Chandrasekhar, "Histopathologic Cancer Detection," *Kaggle*, vol. 6, no. 04, pp. 102–124, 2019, [Online]. Available: <https://www.kaggle.com/c/histopathologic-cancer-detection/overview>.
- [54] F. Chollet, "keras." GitHub, 2015, [Online]. Available: <https://github.com/fchollet/keras>.
- [55] M. C. Mukkamala and M. Hein, "Variants of RMSProp and adagrad with logarithmic regret bounds," *34th Int. Conf. Mach. Learn. ICML 2017*, vol. 5, pp. 3917–3932, 2017.
- [56] F. Chollet, *Deep Learning with Python using Keras*. MITP-Verlags GmbH & Co. KG, 2018.

EKLER


EK 1: Şekil 4.6.'deki örnek görüntünün, geliştirilen modelin katmanlar arası görünümünün görselleştirilmesinin devamı.




Şekil 4.10. İkinci konvolüsyon katmanının görselleştirilmesi




Şekil 4.11. İkinci aktivasyon katmanının görselleştirilmesi




Şekil 4.12. İkinci max_pooling katmanının görselleştirilmesi




Şekil 4.13. Üçüncü konvolüsyon katmanının görselleştirilmesi




Şekil 4.14. Üçüncü aktivasyon katmanının görselleştirilmesi




Şekil 4.15. Üçüncü max_pooling katmanının görselleştirilmesi




Şekil 4.16. Dördüncü konvolüsyon katmanının görselleştirilmesi




Şekil 4.17. Dördüncü aktivasyon katmanının görselleştirilmesi




Şekil 4.18. Dördüncü max_pooling katmanının görselleştirilmesi



Şekil 4.19. Beşinci konvolüsyon katmanının görselleştirilmesi



Şekil 4.20. Beşinci aktivasyon katmanının görselleştirilmesi



Şekil 4.21. Beşinci max_pooling katmanının görselleştirilmesi

ÖZGEÇMİŞ

Hamidullah Nazari, İlk, orta ve lise eğitimini Afganistan'da tamamladı. 2014'de Yurtdışı Türkler ve Akrabalar Bursunu kazanarak Harran Üniversitesi Bilgisayar Mühendisliğinde okuma başladı. Lisansini 2018 yılında tamamladı. Eğitim hayatı boyunca çeşitli yazılım firmaların da staj yapma imkânı buldu. 2018 yılında Sakarya Üniversitesi Bilgisayar ve Bilişim mühendisliğinde yüksek lisansa başladı. Bildiği diller: İngilizce, Türkçe, Farsça, Türkmençe (Ana Dili).