

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**ALGİSAL ÖZET FONKSİYONLARI TABANLI DERİN
ÖĞRENME YÖNTEMLERİ KULLANILARAK
İMGELERİN SINIFLANDIRILMASI**

Yük. Müh. Fatih ÖZYURT

Doktora Tezi
Yazılım Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Engin AVCI

OCAK-2019

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ALGISAL ÖZET FONKSİYONLARI TABANLI DERİN ÖĞRENME
YÖNTEMLERİ KULLANILARAK İMGELERİN SINIFLANDIRILMASI**

DOKTORA TEZİ

Fatih ÖZYURT

(142137203)

Tezin Enstitüye Verildiği Tarih: 24 Aralık 2018

Tezin Savunulduğu Tarih: 17 Ocak 2019

Tez Danışmanı: Prof. Dr. Engin AVCI (Fırat Ü.)
Diğer Jüri Üyeleri: Prof. Dr. İbrahim TÜRKOĞLU (Fırat Ü.)
Prof. Dr. M. Kemal LEBLEBİCİOĞLU (ODTÜ)
Prof. Dr. M. Ali AKCAYOL (Gazi Ü.)
Doç. Dr. Mehmet KARAKÖSE (Fırat Ü.)

OCAK - 2019

ÖNSÖZ

Bu tezin hazırlanmasında değerli görüş ve önerileri ile beni yönlendiren, yardımlarını ve hoşgörüsünü esirgemeyen tez danışmanım Prof. Dr. Engin Avcı ve eşi Doç. Dr. Derya Avcı'ya,

Hayatım boyunca yanımda olan ve benim bugünlere başarılı bir şekilde gelmemi sağlayan, oğulları olmaktan gurur duyduğum anne ve babama,

Bana Doktora yapabilme şansı verdikleri için Teknoloji Fakültesi Yazılım Mühendisliği Bölümündeki hocalarıma,

TEKF.16.25 no'lu proje kapsamında destek verdikleri için Fırat Üniversitesi Bilimsel Araştırma Projeleri birimine,

Sevgisi ile her zaman yanımda olan, çalışmam boyunca sabırlı ve anlayışlı tutumuyla beni rahatlatan sevgili eşime ve yorgunluklarımın arasında huzur bulduğum oğluma sonsuz teşekkürlerimi sunarım.

Fatih ÖZYURT
ELAZIĞ–2019

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	II
İÇİNDEKİLER.....	III
ÖZET.....	V
ŞEKİLLER LİSTESİ	VII
TABLolar LİSTESİ	IX
KISALTMALAR LİSTESİ	X
1. GİRİŞ.....	1
1.1. Makine Öğrenmesi Teknikleri.....	3
1.1.1. Denetimli Öğrenme	3
1.1.2. Denetimsiz Öğrenme	5
1.2. Tezin Amaç ve Organizasyonu	5
1.3. Önceki Çalışmalar	6
2. DERİN ÖĞRENME	10
2.1. Tekrarlayan Sinir Ağları.....	11
2.2. Uzun Kısa Dönem Hafıza Ağları – Kapılı Tekrarlayan Birimler.....	13
2.3. Evrişimsel Sinir Ağları	16
2.3.1. Giriş Katmanı	17
2.3.2. Evrişim Katmanı.....	18
2.3.3. Düzleştirilmiş Doğrusal Birim Katmanı.....	21
2.3.4. Havuzlama Katmanı	21
2.3.5. Tam Bağlantılı Katman	23
2.3.6. Genelleme Katmanı	23
2.3.7. Sınıflandırma Katmanı	24
2.4. Derin İnanç Ağları.....	24
2.5. Derin Yığın Ağları.....	27
3. ALGISAL ÖZET FONKSİYONU	29
3.1. Algısal Özet Fonksiyonlarının Özellikleri.....	31
3.1.1. Algısal Dayanıklılık.....	31
3.1.2. Çakışmama Yeteneği.....	32
3.1.3. Tahmin Edilemezlik	32
3.1.4. Sıkıştırma.....	33
3.2. Algısal Özet Fonksiyonların Uygulama Alanları	33
3.2.1. Veri Tabanı Alanı Küçülme	34
3.2.2. Telif Hakkı Kontrolü	34
3.2.3. Şirket Reklam Sözleşmelerine Bağlılık Kontrolü	35
3.2.4. Adli Bilişimde Kullanım	35
4. ÖNERİLEN YÖNTEMLER	36

4.1.	Ayrık Dalgacık Dönüşümü – Tekil Değer Ayırışımı Tabanlı Dayanıklı Algısal Özet Fonksiyonu.....	36
4.1.1.	Önerilen Yöntem	36
4.1.2.	Deneysel Sonuçlar	39
4.1.1.	Sonuç	44
4.2.	Renkli İmgeler için Yeni Bir Algısal Özet Fonksiyonu Tabanlı Olasılıksal Kimlik Doğrulama Yöntemi	44
4.2.1.	Önerilen Yöntem	45
4.2.2.	Deneysel Sonuçlar	50
4.2.3.	Sonuç	54
4.3.	Algısal Özet Fonksiyonu Tabanlı Evrişimsel Sinir Ağları Kullanarak Karaciğer İmge Sınıflandırması için Yeni Bir Yöntem	54
4.3.1.	Önerilen Algısal Özet Fonksiyonu	55
4.3.2.	Önerilen Yöntem	57
4.3.3.	Deneysel Sonuçlar	59
4.3.4.	Sınıflandırma Performansları	63
4.3.5.	Tartışma ve Sonuç	65
4.4.	İmge Sınıflandırması için Yeni Öznitelik Çıkarım Yöntemi: ADD-TDA Algısal Özet Fonksiyonu Tabanlı Evrişimsel Sinir Ağ.....	67
4.4.1.	Önerilen ADD-TDA-ESA Yöntemi	67
4.4.2.	Deneysel Sonuçlar	69
4.4.3.	Sonuç	71
5.	SONUÇLAR VE TARTIŞMA	72
5.1.	Tez Çıktılarının Literatüre Katkıları.....	73
	KAYNAKLAR	75

ÖZET

Endüstri ve akademik çevredeki veri bilimcileri; makine öğrenmesini, imge sınıflandırmasını, video analizini, konuşma tanıma ve doğal dil işleme süreçlerini pek çok alanda kullanmaktadırlar. İmge sınıflandırma aşamasında, özniteliklerin manuel olarak çıkartılması uzmanlık gerektiren bir alandır. Bu nedenle, öznitelik çıkarma aşaması imge sınıflandırılması için örüntü tanımada en önemli adım olarak kabul edilmektedir. Derin öğrenme algoritmaları, imgelerin manuel öznitelik çıkarma özelliğini ortadan kaldırmak için aktif bir araştırma alanı haline gelmiştir. Ancak imgelerde piksel seviyesinde işlem yapılması nedeniyle çalışma zamanını arttırmaktadır. Algısal özet fonksiyonları, imgelerin belirgin özniteliklerini tespit ederek özet değeri oluşturmaktadır. Dolayısıyla algısal özet fonksiyonu ile elde edilen öznitelik verilerine imgenin parmak izi de denilebilir.

Bu tez çalışmasında imge yapısını bozmayan algısal özet fonksiyonu kullanılarak direkt ham imgelerden belirgin öznitelikler elde edilmiştir. Seçilen algısal özet fonksiyonunun performansını değerlendirmek için Bit Hata Oranı (BHO), Ortalama Karesel Hata (OKH), Tepe Sinyal Görüntü Oranı (TSGO) gibi parametreler ile karşılaştırılarak başarımları test edilmiştir. Veri tabanı olarak Fırat Üniversitesi hastanesinden alınan karaciğer tümör verileri ve halka açık veri tabanı olan Caltech-101 verileri kullanılmıştır. Derin öğrenme mimarilerinden Evrişimsel Sinir Ağ (ESA) algoritması, Ayrık Dalgacık Dönüşümü (ADD) – Tekil Değer Ayrışımı (TDA) tabanlı algısal özet fonksiyonu ile birlikte kullanılmıştır.

Bu doktora tez çalışmasının amacı, algısal özet fonksiyonu tabanlı ESA kullanarak yüksek boyutlu imgelerin sabit diskteki kapladığı boyutu azaltan, sınıflandırma sürelerini kısaltıp sınıflandırma performansını kabul edilebilir bir eşiğin üzerinde tutmaktadır. ADD-TDA tabanlı Algısal Özet Fonksiyonu (AÖT) ile ESA birlikte ilk defa kullanılarak özniteliklerin çıkarılması amaçlanmıştır. Karaciğer ve Caltech-101 veri tabanında bulunan çeşitli imgelere uygulanan AÖT-ESA yöntemi ile çıkartılan öznitelikler önerilen yöntemin başarımlarını test etmek için Yapay Sinir Ağları (YSA), Destek Vektör Makineleri (DVM), K-en Yakın Komşu (KNN) gibi sınıflandırıcılara verilmiştir. AÖT-ESA yöntemi, bir taraftan sınıflandırma performansının gelişimine katkı sunarken diğer taraftan da uzun süren çalışma zamanı probleminin çözümüne katkıda bulunmuştur.

Anahtar Kelimeler: Derin Öğrenme, Evrişimsel Sinir Ağları, Algısal Özet Fonksiyonu, İmge Sınıflandırma

ABSTRACT

CLASSIFICATION OF IMAGES BY USING DEEP LEARNING METHODS BASED ON PERCEPTUAL HASH FUNCTIONS

Machine learning, image classification, video analysis, speech recognition and natural language processing are widely used by data scientists in both industrial and academic world for various purposes. The manual extraction of the features requires a certain expertise during the image classification stage. Thus, the feature extraction phase is considered to be the most important step in pattern recognition for image classification. Deep learning algorithms have become an active research area to remove the manual feature extraction step of images. However, image processing takes considerable long execution times as it operates at the pixel level. The salient characteristics of images are determined by perceptual hash functions which give a certain hash value. Therefore, the feature data obtained by the perceptual hash function can also be called the fingerprint of the image.

In this thesis, salient features are obtained directly from raw images by using perceptual hash function which does not distort image structure. Comparisons have been made by considering some parameters as BER, MSE, PSNR to evaluate the performance of the proposed perceptual hash function. Liver disease images obtained from Elazig University Hospital Radiology Laboratory, and Caltech-101 (publicly available database) images were used as a database. The Convolutional Neural Network (CNN) algorithm, one of the deep learning architectures, was used with the Discrete Wavelet Transform (DWT) - Singular Value Decomposition (SVD) based perceptual hash function.

The aim of this doctorate thesis is to reduce the classification time of the high-dimensional images and their sizes on hard disk while maintaining the classification performance above an acceptable threshold by using perceptual hash based CNN. It is intended to extract the features by using both DWT - SVD based perceptual hash function and the CNN for the first time together. The results obtained by applying the our proposed method to the liver and the Caltech-101 image database were evaluated by considering some known classifiers such as Artificial Neural Networks (ANN), Support Vector Machines (SVM), K-nearest Neighbor (KNN). The proposed method not only improves the classification performance but also provides a positive impact on the excessive runtime problem.

Key Words: Deep Learning, Convolutional Neural Networks, Perceptual Hash Function, Image Classification.

ŞEKİLLER LİSTESİ

	<u>Sayfa No</u>
Şekil 1.1 Makine öğrenmesindeki temel unsurlar	2
Şekil 1.2 Makine öğrenmesi teknikleri.....	3
Şekil 1.3 Bir probleme ait uzayın sınıflara bölünmesi	4
Şekil 1.4 İris bitkisinin A-setosa, B-versicolor ve C-virginica türleri	4
Şekil 2.1 MİB ile GİB arasındaki çekirdek sayılarının temsili gösterimi	10
Şekil 2.2 Derin öğrenme mimarileri.....	11
Şekil 2.3 Tekrarlayan sinir ağları	12
Şekil 2.4 UKDHA mimarisi	13
Şekil 2.5 ESA katmanlarından sonra oluşan imge temsilleri	16
Şekil 2.6 Evrimsel sinir ağlarının genel mimarisi	17
Şekil 2.7 İmgenin piksel değerleri gösterimi.....	18
Şekil 2.8 Dolgu işleminin gösterimi.....	19
Şekil 2.9 Evrişim işleminin imge üzerindeki gösterimi	20
Şekil 2.10 Öznitelik haritasından sonra uygulanan DDB fonksiyonu	21
Şekil 2.11 Havuzlama katmanı gösterimi	22
Şekil 2.12 Bir ve iki adım ilerleme ile maksimum havuzlama işleminin gösterimi	23
Şekil 2.13 Ağın orijinal yapısı ve genelleme katmanından sonraki durumu.....	24
Şekil 2.14 Kısıtlı boltzmann makinasının gösterimi	25
Şekil 2.15 Derin inanç ağları gösterimi.....	26
Şekil 2.16 Otomatik kodlama işleminin gösterimi.....	27
Şekil 2.17 Derin yığın ağlarının gösterimi	28
Şekil 3.1 Algısal özet fonksiyonu akış diyagramı.....	29
Şekil 3.2 Kriptografik özet fonksiyonları ile AÖF arasındaki farkın görsel gösterimi.....	30
Şekil 3.3 Algısal özet fonksiyonlarının özellikleri.....	31
Şekil 4.1 3x3'lük komşuluk matrisi	37
Şekil 4.2 3.seviyede ADD'nin uygulanması	38
Şekil 4.3 Önerilen yöntemin blok şeması.....	39
Şekil 4.4 SIPI veri tabanına ait kullanılan imgeler.....	40
Şekil 4.5 Önerilen yöntemin karşılaştırılması	42
Şekil 4.6 Önerilen yöntemin 32x32, 64x64 ve 128x128 boyutlu imgelerde Hamming uzaklık ölçütüyle karşılaştırılması	43

Şekil 4.7 Önerilen yöntemin filigran oluşturma ve filigran gömme diyagramı	46
Şekil 4.8 Önerilen veri çıkarma ve imge kimlik doğrulamasının blok diyagramı	47
Şekil 4.9 ADD-TDA tabanlı algısal özet fonksiyonunun blok diyagramı	48
Şekil 4.10 Önerilen yöntemin blok diyagramı	50
Şekil 4.11 SIPI imge veri tabanı test imgeleri (a) Lena (b) Baboon (c) Peppers	51
Şekil 4.12 SIPI imge veri tabanı test imgeleri - Lena	52
Şekil 4.13 (a) Saldırı yapılmış imge (b) Değiştirilmiş alan tespiti (c) İmgeyi yeniden elde etme.....	53
Şekil 4.14 Önerilen algısal özet fonksiyonunun blok diyagramı	55
Şekil 4.15 Önerilen yöntem.....	58
Şekil 4.16 İyi ve kötü huylu karaciğer tümörleri	58
Şekil 4.17 Özet fonksiyonundan sonra elde edilen karaciğer imgeleri	59
Şekil 4.18 Sınıflandırıcıların deneysel sonuçları.....	63
Şekil 4.19 ESA mimarisinin ortalama çalışma süreleri.....	63
Şekil 4.20 4096 girişe sahip 4 gizli katmanlı 2 çıkış katmanlı çok katmanlı ağ yapısı.....	64
Şekil 4.21 Karmaşıklık matrisi.....	65
Şekil 4.22 AİK eğrisi.....	65
Şekil 4.23 Önerilen ADD-TDA-ESA yöntemi	68
Şekil 4.24 Çalışmada kullanılan 7 sınıfa ait örnek imgeler.....	69
Şekil 4.25 Klasik ESA karmaşıklık matrisi.....	70
Şekil 4.26 Önerilen yöntemin karmaşıklık matrisi.....	71

TABLÖLAR LİSTESİ

	<u>Sayfa No</u>
Tablo 4.1 Önerilen yöntemin Hamming uzaklık ölçüt değerleri	41
Tablo 4.2 32x32, 64x64 ve 128x128 boyutlu imgelerde Hamming uzaklık ölçüt değerleri	43
Tablo 4.3 Filigran üretim denklemleri	45
Tablo 4.4 Filigran oluşturma ve filigran gömme adımları sözde kodu	47
Tablo 4.5 Veri çıkarma ve kimlik doğrulama algoritmasının sözde kodu.....	48
Tablo 4.6 İmgeyi yeniden elde etme algoritması sözde kodu.....	49
Tablo 4.7 Önerilen yöntemin TSGO değerleri	51
Tablo 4.8 Önerilen yöntemin görsel kalite açısından karşılaştırmalı performans tablosu..	51
Tablo 4.9 İmgeyi yeniden elde edebilme kapasitesini değerlendirme tablosu	54
Tablo 4.10 Özellik indirgeme adımları	56
Tablo 4.11 Algısal özet fonksiyonu kullanmadan temel ESA sınıflandırması.....	60
Tablo 4.12 Karaciğer kitlelerinin sınıflandırılması için 12 modelin deneysel sonuçları....	61
Tablo 4.13 Karaciğer kitlelerinin sınıflandırılması için 12 modelin deneysel sonuçları....	62
Tablo 4.14 Çalışma sürelerinin karşılaştırılması	70

KISALTMALAR LİSTESİ

ADD	: Ayrık Dalgacık Dönüşümü
AKD	: Ayrık Kosinüs Dönüşümü
TDA	: Tekil Değer Ayrıştırma
AÖT	: Algısal Özet Fonksiyonu Tabanlı
ESA	: Evrişimsel Sinir Ağ
AİK	: Alıcı İşletim Karakteristiği
YSA	: Yapay Sinir Ağı
DVM	: Destek Vektör Makinesi
KNN	: K-en Yakın Komşu algoritması
DDB	: Düzleştirilmiş Doğrusal Birim Katmanı
KBM	: Kısıtlanmış Boltzmann Makineleri
BT	: Bilgisayarlı Tomografi
BHO	: Bit Hata Oranı
OKH	: Ortalama Karesel Hata
TSGO	: Tepe sinyal gürültü oranı
İLR	: İkili Lojistik Regresyon
GİB	: Grafik İşlemci Birimi
MİB	: Merkez İşlemci Birimi
TSA	: Tekrarlayan Sinir Ağları
DİA	: Derin İnanç Ağları
UKDHA	: Uzun Kısam Dönem Hafıza Ağları
DYA	: Derin Yığın Ağları

1. GİRİŞ

Son zamanlarda, makine öğrenmesinin alt birimleri olan imge sınıflandırma ve örüntü tanıma yoğun olarak çalışılan bir alan haline gelmiştir. Temel olarak imgeler üzerine yapılan bu çalışmalar, öznitelik çıkarımı ve bu özniteliklerin eğitilmiş / eğitimsiz olarak öğrenilmesi şeklinde iki kısımdan oluşmaktadır [1-3]. Klasik olarak özniteliklerin çıkarılması için uygulanan en yaygın yöntemler SIFT (Ölçek değişmeyen özellik dönüşümleri) [1], Gabor özellikler [2] ve LBP (Yerel ikili modeli)'dir [3]. Bu yöntemler, doku sınıflandırma, yüz tanıma ve nesne tanıma gibi farklı sınıflandırma görevlerinde iyi sonuçlar elde edilebilmektedir. Bu yöntemlerin yetersiz kaldığı durumlarda farklı öznitelik çıkarımları için uzmanlığa ihtiyaç duyulmaktadır. Klasik olarak çıkartılan özniteliklere göre sınıflandırılma yapılmış birçok çalışma bulunmaktadır [1-6].

Derin öğrenme, makine öğrenmesinin alt kollarından biridir. Makine öğrenmesi ile ilgili araştırmalar uzun yıllardan beri akademik ve endüstriyel çalışma alanlarını yakından ilgilendirmektedir. Makine öğrenmesi, matematiksel ve mantıksal işlemler yapabilen makinelerin, çeşitli gözlem ve ölçüm sonucu elde edilen verileri deneyim olarak kabul ederek bu tecrübelerden matematiksel algoritmalar aracılığıyla anlamlı ilişkiler üretme süreci olarak tanımlanabilir. Bu tanım kısaca bir problemin verilerini modelleyebilen bilgisayar algoritmalarının genel adıdır [7]. Literatürde makine öğrenmesi ifadesi yerine yapay öğrenme kullanılmaktadır [8]. Makine öğrenmesinde geçmiş deneyimler veri olarak değerlendirilir. Öğrenme algoritmaları bu veriler arasındaki ilişkilerden çözülmesi istenilen probleme uygun bir model oluşturulur ve problemlerin çözümü için modele başvurarak sonuçlar üretilir [7]. Bu tanıma göre literatürde bir bilgisayar programının G görevlerinde P ile ölçülen performansı deneyim D ile artıyorsa, o bilgisayar programının bazı G görevlerinin sınıflarına ve performans ölçüsü P'ye göre deneyim D'den öğrendiğini ifade etmektedir [7]. Tanımda yer alan dört ana unsur Şekil 1.1'de belirtilmiştir.



Şekil 1.1 Makine öğrenmesindeki temel unsurlar

Görev: Her eylem bir amaç doğrultusunda yerine getirilir prensibine göre matematiksel ve matematiksel işlemler yapabilen elektronik donanımı öğrenir hale getirmek için neyi öğreneceğinin ya da görevin ne olduğunun belirtilmesi gerekir. Kısaca görev, bir amaç fonksiyonun yerine getirilmesidir. Bu fonksiyon problemine örnek olarak maç sonuçlarının tahmini, hava durumu tahmini, kaza öngörüsü vb. verilebilir.

Deneyim: Öğrenmenin gerçekleşmesinde en büyük pay geçmiş deneyimlerdir. Öğrenen bir makine için deneyim tanımlanan görevi çözmesi için sunulan veridir. Algoritmalar da bu veriyi deneyim olarak kabul eder ve öğrenme için kullanırlar.


Algoritma: Bir problemin çözümü için adım adım izlenen yol anlamına gelmektedir. Makine öğrenmesi alanında sınıflandırma, kümeleme ve regresyon ana başlıkları altında pek çok algoritma geliştirilmiştir.

Performans: Problemin çözümüne ilişkin hedefe ulaşılacak en uygun algoritmanın seçilmesi ve bu algoritmanın parametrelerinin ne olacağının belirlenmesidir. Kullanılan modelin ve algoritmanın parametrelerinin optimize edilmiş olması, veri setinin eğitim ve test veri seti amacıyla bölünme yöntemi bu unsurlar arasında sayılabilir. Algoritmalar genellikle parametrelili kullanım yapısındadır. Örneğin YSA'daki katman ve nöron sayısı kurulan modelle ilgili parametreler olarak ifade edilebilir. Algoritma parametrelerinin uygun

değerlerde olması algoritmanın daha iyi öğrenmesini daha iyi performans göstermesini sağlayacaktır.

1.1. Makine Öğrenmesi Teknikleri

Makine öğrenmesi yöntemleri ikiye ayrılır. Denetimli öğrenme gelecekteki çıktıları tahmin edebilmek için bilinen girdi ve çıktı verisi üzerinde bir modeli eğiten; denetimsiz öğrenme girdi verilerindeki gizli kalıpları veya içyapıları bulup modeli eğiten yöntemlerdir [8,9]. Şekil 1.2’de makine öğrenmesi teknikleri verilmiştir.




Şekil 1.2 Makine öğrenmesi teknikleri

1.1.1. Denetimli Öğrenme

Veriler etiketlenmiş, sınıflandırılmış, giriş verisine ait çıkışların belirli olduğu durumlardır [8,9]. Denetimli öğrenme algoritmaları, bilinen bir veri giriş kümesini ve bilinen yanıtları almakta, böylece yeni verilere yanıt için makul tahminler üretmek için bir modeli eğitmektedir. Denetimli öğrenme, tahmini modeller geliştirmek için sınıflandırma ve regresyon teknikleri kullanmaktadır [9].

Sınıflandırma

Giriş verisine ait çıkışların nitel olduğu durumlarda kullanılan yöntemlerin her veri örneğinin hangi sınıfa ait olduğunun belirlenmesidir. Amaç probleme ait tüm uzayın belirli sayıda sınıfa bölünmesidir. Şekil 1.3’de her renk bir sınıfını göstermektedir. Sınıflandırma teknikleri sayesinde hiçbir veri örneğinin olmadığı bölgeler de renklendirilebilir [2-4], [6].



Şekil 1.3 Bir probleme ait uzayın sınıflara bölünmesi

Çok sayıda sınıflandırma metodu mevcuttur. Bunun sebebi: Her veri kümesi üzerinde mükemmel çalışan bir yöntem olmadığından farklı veriler için farklı sınıflandırma metotları oluşturulmuştur. Bu konuyla ilgili literatür araştırmalarında bahsedildiği gibi sınıflandırmada amaç önceden etiketlenmiş örnekleri kullanarak yeni örneklerin sınıflarını bulmaktır. En çok kullanılan sınıflandırma yöntemleri aşağıda belirtilmiştir.

- Destek Vektör Makineleri (SVM-Support Vector Machine)
- Yapay Sinir Ağları (Artificial Neural Network)
- Karar Ağaçları (Decision Tree)
- K-En Yakın Komşuluk (K- Nearest Neighbor / KNN)

Sınıflandırmanın amacını bir örnek ile açıklamak istersek Şekil 1.4’de iris bitkisinin üç türü olan A-setosa, B-versicolor ve C-virginica’nın setal(çanak yaprak) ile petal(taç yaprak) özellik verilerine göre çeşidini bulabilmek ve yeni gelecek veri ile çiçeğin hangi türe ait olabileceği sorusuna cevap verebilmektir.



Şekil 1.4 İris bitkisinin A-setosa, B-versicolor ve C-virginica türleri

Regresyon

Gelecek veriyi tahmin etmektir. Örnek olarak kredi skoru tahmin etmede yaş, maaş, geçmiş kredi ödeme durumu, borç bakiyesi vb. gibi verileri girdi olarak alıp çıktı olarak verilerle anlamlı ilişkiler kurup tahmini gerçekleştirir. CART (Classification and Regression Tree), Bayesian lojistik regresyon ve doğrusal regresyon gibi yöntemler mevcuttur [10].

1.1.2. Denetimsiz Öğrenme

Verilere ait sınıf bilgileri bulunmamaktadır. Kümeleme olarak bilinen yöntem de amaç; veriler üzerinde var olan gizli doğal kümeler bulabilmektedir [8].

Kümeleme

Kümeleme, belirli bir nesne kümesinin benzerliklerine ve karakteristik özelliklerine göre gruplandırılmasıdır. Kümelemede, bir nesnenin sabit bir gruba aitliği yoktur. Gruplar arası aitlik, uygulanacak kümeleme algoritmalarına göre belirlenebilir [11].

1.2. Tezin Amaç ve Organizasyonu

Bu tez çalışmasının 5 temel amacı bulunmaktadır. Bunlar:

1. Büyük boyutlu imgelerin belirgin özniteliklerini çıkarmak için blok tabanlı algısal özet fonksiyonu geliştirmek.
2. Geliştirilen algısal özet fonksiyonunun, algısal dayanıklılık, çakışmama yeteneği ve anahtar bağımlı güvenlik gibi özelliklerini ortaya koymak.
3. İmgelerin sabit diskte kapladığı alan boyutunu, geliştirilen algısal özet fonksiyonu ile indirgemek.
4. ESA mimarilerini öznitelik çıkarıcı olarak kullanarak manuel öznitelik çıkarımının önüne geçmek ve bu öznitelikleri çeşitli sınıflandırma algoritmalarında kullanmak.
5. İmgelerin sınıflandırılmasında doğru tanıma ve yorumlama performansını azaltmadan çalışma süresini azaltmayı amaçlayan belirgin öznitelikleri elde etmemizi sağlayan algısal özet fonksiyonu (AÖF) tabanlı ESA yöntemlerinin birlikte kullanıldığı hibrit bir yapının geliştirilmesini sağlamak.

Tez çalışması beş bölümden oluşmaktadır. Tez çalışmasının ikinci bölümünde derin öğrenme anlatılmaktadır. Üçüncü bölümde AÖF ile ilgili bilgiler verilmektedir. Dördüncü bölümde algısal özet tabanlı derin öğrenme uygulamaları anlatılmış ve bu uygulamalar sonucunda elde edilen başarımları incelenmektedir. Beşinci bölümde ise tez çalışmasının sonuçları yorumlanıp ve literatüre olan katkısı tartışılarak önerilerden bahsedilmektedir.

1.3. Önceki Çalışmalar

a) Karaciğer imgeleriyle ilgili yapılan çalışmalar

Minhas ve arkadaşlarının yaptığı çalışmada, karaciğer ultrasonografi imgelerinin dokusal analizi kullanılarak karaciğer yağlanması ve heterojen karaciğer tespiti için yeni bir yaklaşım sunulmaktadır [12]. Bu çalışmada, Dalgacık Paket Dönüşümü (DPD) kullanılarak bir dizi istatistiksel özellik elde edilmiştir. Sınıflandırma için çok sınıflı lineer DVM kullanılmış ve % 95 oranında sınıflandırma başarımları göstermiştir. Acharya ve arkadaşlarının 2012 yılında yaptığı çalışmada 100 örnek kullanmıştır [13]. Karaciğer ultrason imgelerinin doku, dalgacık dönüşümü ve daha yüksek mertebeden spektrumlarına dayanan öznitelikleri çıkartılarak karar ağacı sınıflandırıcısı ile %93.3 oranında doğruluk elde edilmiştir. Virmani ve arkadaşlarının çalışmasında, sirotik karaciğerde gelişen normal karaciğer, sirotik karaciğeri ve hepatoselüler karsinomu (HCC) karakterize eden bir sistem önerilmiştir [14]. Çalışma, 56 denekden alınan 56 gerçek ultrason imgesi (15 normal, 16 sirotik ve 25 HCC karaciğer imgesi) ile gerçekleştirilmiş SVM sınıflandırıcı ile % 88.8 oranında doğruluk elde edilmiştir. Virmani ve arkadaşlarının 2013 yılında yaptıkları başka bir çalışmada, toplamda 31 örnek kullanılmıştır [15]. Multiresolution doku tanımlayıcılar tarafından normal ve sirotik karaciğeri tanımlamak için bilgisayar destekli bir tanı sistemi önermiştir. Öznitelik çıkarma adımı DPD ve gabor dalgacık dönüşümü kullanılmıştır. DVM sınıflandırıcısı ile % 98.3 oranında doğruluk elde etmişlerdir. Roy, 2014 yılındaki çalışmasında toplam 42 örnek kullanmıştır [16]. Öznitelik çıkarım aşamasında gri seviye eş oluşum matrisleri (GSEOM) kullanarak çok katmanlı algılayıcı sinir ağı sınıflandırıcısı ve kendini düzenleyen haritalar (KDH) sınıflandırıcısıyla %81.5 oranında doğruluk elde etmiştir. Rivas ve arkadaşları 2015 yılında öznitelik çıkarım aşamasında GSEOM kullanarak toplam 108 imge kullanmışlardır [17]. İkili lojistik regresyon (İLR) modelinde, bağımlı değişken olarak hastalığın varlığı veya yokluğu, tahmini değişkenler olarak tanımlayıcı istatistiksel parametreler olarak dikkate

alınmıştır. Model, ultrason imgelerinde %95.45 sınıflandırma başarımına ulaşmıştır. Wu ve arkadaşları öznitelik çıkarım adımında ortalama alma, standart sapma, kurtosis, skew kullanmıştır [18]. Bu çalışmada, 288 örnek kullanılarak DVM ve Rastgele Orman sınıflandırıcısı ile %72.81 doğruluk elde edilmiştir. Hwang ve arkadaşları öznitelik çıkarım adımında istatistiki veriler, GSEOM, ekoseniklik kullanmıştır [19]. Bu çalışmada, 115 örnek kullanılarak Bayes sınıflandırıcısı ile %96 oranında doğruluk elde etmiştir. Son olarak, Acharya ve arkadaşları 2016 yılında, öznitelik çıkarma adımında GIST tanımlayıcısını kullanmışlardır. Bu çalışmada, 100 örnek kullanılarak probabilistic sinir ağ sınıflandırıcısı ile %98 oranında doğruluk elde edilmiştir [20].

b) Farklı ESA mimarileri ile ilgili yapılan çalışmalar

Evrişimsel sinir ağları kullanılarak gerçekleştirilen imge işleme çalışmalarında, en önemli problem, yapılan işlemlerin pikseller mertebesinde olmasından dolayı hesaplama maliyetinin yüksek olmasıdır. Fakat imge veri setinin boyutu çok büyük değilse, kabul edilebilir sınıflandırma performansı için birkaç evrişimsel ağ yeterli olabilir. Örneğin, Mallat Bruna [21] ve [22] numaralı çalışmalarında ScatNet adlı bir yöntem önerilmiştir. Önerilen yöntemde evrişim katmanı, doğrusal olmayan katman, pooling katmanı, karmaşık dalgacık, mod operatörü ve ortalama operatörü kullanılmıştır. 2015 yılında Zeng ve arkadaşlarının yaptıkları çalışmada, tensör nesne sınıflandırması için MLDANet adlı bir yöntem önerilmiştir [23]. Aynı yılda Li ve arkadaşları çalışmalarında renkli kırmızı, yeşil, mavi, derinlik (KYMD) imgeleri kullanarak insan hareketi tanıma için SAE-PCA yöntemini önermiştir [24]. Amerikan işaret dili veri kümesi üzerinde yapılan deneysel sonuçlar, önerilen öznitelik öğrenme modelinin önemli ölçüde etkili olduğunu göstermektedir. Tanıma oranını %75'ten %99.05'e kadar arttırmaktadır [24]. Yine aynı yılda Chan ve arkadaşları çalışmalarında, PCANet adlı yeni bir yöntem önermişlerdir. [25]. PCANet basit işlemleri kullanmasına rağmen, nesne imgeleri, doku imgeleri, el yazısı rakamları ve yüz imgeleri ile sınıflandırmada yüksek performans sağlamıştır. Gan ve arkadaşları yüz tanıma için GENet'i önermişlerdir [26]. GENet, grafik gömme çerçevesini çok katmanlı ağ mimarisi ile birleştirmiştir. 2016 yılında H. Qin ve arkadaşları, kombine PCANet'i uzaysal piramit havuzu ile kullanarak balık tanıma için bir yöntem önermiştir [27]. Sınıflandırma için doğrusal bir DVM sınıflandırıcısı kullanarak bir balık tanıma veri kümesinde, %98.64 oranında başarımlar elde edilmiştir. Lei ve çalışma ekibi, 2016 yılındaki çalışmalarında yüz

tanıma için derin yüz tanımlayıcıları geliştirmişlerdir [28]. Bu tanımlayıcılar ile literatürdeki diğer tanımlayıcılar karşılaştırıldığında, kompakt yüz temsiliyle yüksek oranda yüz tanıma performansı elde edilebildiği görülmektedir. Son olarak Zhao ve arkadaşları çok düzeyli bir filtreleme ağı vasıtasıyla yerel kenarların özellik gösterimi için çok seviyeli modifiye sonlu radon dönüşüm ağı önermiştir [29]. Önerilen yöntemin son yöntemler üzerindeki üstünlüğü deneysel sonuçlarda görülmektedir.

c) Algısal özet fonksiyonları alanında yapılan çalışmalar

Fridrich ve Goljan tarafından 2000 yılında önerilen çalışmada Ayırık Kosinüs Dönüşümünden (AKD) elde edilen düşük frekanslı katsayıları filigran gömerek güçlü fakat küçük açılarda bile döndürmeye karşı duyarlı olan algısal özet fonksiyonu kullanılmıştır [30]. Bu eksikliği gidermek için Kozat ve arkadaşları, imgelerin yarı küresel güçlü özniteliklerini elde etmek için yaptıkları çalışmada matris varyantları ve orijinal imgeden rastgele seçilen olası üst üste binen bloklar üzerinde iki kez TDA uygulamıştır [31]. Böylelikle küçük dereceli dönmelere karşı imgeler sağlamlaştırılmıştır. Monga ve Mihcak ilk kez negatif olmayan matris faktörünü (NMF) geometrik saldırılara karşı dirençli olan, ama parlaklık değişiklikleri gibi bazı içerik koruma operasyonlarına direnemeyen algısal özet fonksiyonu geliştirmiştir [32]. Qin ve arkadaşları önerdikleri yöntemde, ayırık fourier dönüşümü kullanarak imge kimlik doğrulaması ve imge geri alma gibi alanlarda uygulanabilecek algısal özet fonksiyonu elde etmişlerdir [33]. İmgelerin ön işlem aşamasında, yeniden boyutlandırılarak toplam varyasyon tabanlı filtreleme uygulanmıştır. Daha sonra ikincil imge, döndürme ile elde edilip ve sağlam frekans özelliği ve ayırık fourier dönüşümünden sonra ikincil imgeden çıkarılmıştır. Qin ve arkadaşları 2017 yılında yaptıkları çalışmada, ön işleme aşamasında gürültüleri azaltmışlardır [34]. Ardından elde edilen imge üzerinde, çift-çapraz desen kodlaması, yatay-dikey ve diyagonal yönlerde dokusal bilgiyi temsil eden ikili kodlanmış haritayı üretmek için histogram kullanılmıştır. Öte yandan belirgin yapısal öznitelikler, frekans katsayılarının köşe noktalarını içeren seçici örneklenmiş blokların konum bilgisinden elde edilip birleştirilerek algısal özet fonksiyonu oluşturulmuştur. Tang ve arkadaşları, imgelerin renk bilgilerini iyi bir şekilde yakalamadığını iddia ederek renk vektör açılarının (RVA) histogramı ile histogram renk vektör açısı (HRVA) denilen algısal özet fonksiyonları üzerinde çalışmışlardır [35]. Qin ve arkadaşları 2018 yılında melez öznitelik çıkarma yöntemi ile renkli imgeler için yeni bir


algısal özet fonksiyonu önermişlerdir [36]. Bu çalışmanın ön işlem aşamasında imge normalleştirme, gauss alçak geçirgen filtreleme ve TDA uygulanmıştır. Daha sonra canny operatörü yardımı ile belirgin kenar noktalarını örneklemek için çember ve blok tabanlı öznitelik çıkartılmıştır.

Bu tez çalışmasında, yukarıda verilen konularla ilgili geliştirilmiş yöntemler detaylı olarak incelenmiştir. Derin öğrenme ile öğrenme tabanlı özet fonksiyonları üzerine çalışmaların yapıldığı gözlemlenmiştir. Bu çalışmalarda daha çok ESA katmanları sonucunda çıkacak öznitelik sayılarının azaltılıp sınıflandırma performanslarının düşürülmemesi amaçlanmıştır. AÖF ile derin öğrenme mimarilerinden ESA'nın birlikte kullanıldığı hibrit yapı bu tez çalışmasında literatüre kazandırılmıştır.



2. DERİN ÖĞRENME


Bilgisayar mimarileri 70 yıldan uzun süredir varlığını sürdürdürmektedirler. Ancak yeni mimariler ve grafik işlem birimleri (GİB) yapay zeka teknolojisini günümüzde kullanım açısından en ön saflara getirmiştir. Merkez işlemci birimi (MİB) ile GİB'lerin çekirdek sayıları arasındaki farkın temsili gösterimi Şekil 2.1 de gösterilmiştir.



Şekil 2.1 MİB ile GİB arasındaki çekirdek sayılarının temsili gösterimi

Derin öğrenme yeni olmamakla birlikte, derin katmanlı sinir ağlarının kesişiminden ve uygulamalarını hızlandırmak için GİB'lerin kullanılmasından dolayı akademik ve endüstriyel çevrelerde çok hızlı bir büyüme yaşamaktadır. Bu büyümenin sebebi, nesne takip etme, nesne bulma, imge sınıflandırma, imge bölütleme ve doğal dil işleme gibi problemlerin çözümünde yardımcı olan milyarlarca parametreyi öğrenen öğrenme tabanlı sinir ağlarıdır. İnternetin yaygınlaşması ve verilerin çok fazla büyümesi öznitelik çıkartma ve bu öznitelikleri doğru olarak değerlendirme aşamasında optimizasyon yapmayı zorunlu kılmıştır. İşte bu noktada günümüzde yaygın olarak kullanılmaya başlanılan derin öğrenme mimarileri karşımıza çıkmaktadır. Günümüzde yapay zekânın kullanıldığı alanlarda derin öğrenme topolojilerinin izlerini çok rahat gözlemleyebilmekteyiz. Derin öğrenme, çeşitli verilere uygulanacak tek bir yaklaşım değil, geniş yelpazedeki problemlere uygulanabilecek

bir algoritma ve topoloji sınıfıdır. Derin öğrenme mimarileri çok çeşitli problemlerin çözümünde karşımıza çıkmaktadır. 1990 yılından bu yana en çok kullanılan derin öğrenme mimarileri Şekil 2.2’de verilmiştir.




Şekil 2.2 Derin öğrenme mimarileri

2.1. Tekrarlayan Sinir Ağları

İnsanoğlu bir düşünceye her an sıfırdan başlayamamaktadır. Örneğin bu tezi okurken her kelimenin önceki kelimelerle olan ilişkisine bakarak anlamaktayız. Düşüncelerimizin bir sürekliliği olduğu için her şeyi kenara atıp sıfırdan düşünmeye ve anlamaya başlayamamaktayız. Geleneksel sinir ağlarında, verileri birbirine bağlama yoktur. Bu durum karşımıza bir eksiklik olarak çıkmaktadır. Örneğin, bir filmin her saniyesinde ne tür bir olay olduğunu sınıflandırmak istediğinizi düşünürsek, geleneksel bir sinir ağının, filmin önceki olaylar hakkındaki muhakemesini daha sonra bilgilendirmek için nasıl kullanabileceği açık değildir.

Tekrarlayan sinir ağları (TSA)-(Recurrent Neural Network-RNN), temel derin öğrenme ağ mimarilerinden biridir. İlk olarak 1990 yılında Elman tarafından cümle yapısı simülasyonunda kullanılan her bir kelimenin kümelenmesi için öne sürülmüştür [37]. Geleneksel çok katmanlı ağ ile tekrarlayan ağ arasındaki temel fark, tamamen ileriye dönük bağlantılardan ziyade, tekrarlayan bir ağın önceki katmanlara (veya aynı katmana) geri beslenen bağlantılara sahip olabilmesidir. Bu geri bildirim, TSA’ların zaman içinde geçmiş girdileri ve model problemlerini hafızaya almasına izin verir. TSA’ların arkasındaki fikir, sıralı bilgilerin kullanılmasıdır. Geleneksel bir sinir ağında tüm girdilerin ve çıktılarının birbirinden bağımsız olduğu varsayılmaktadır. Ancak konuşma tanıma, el yazısı tanıma gibi

problemlerin çözümünde bu durum uygun değildir. Konuşma tanımada, bir cümledeki bir kelimeyi tahmin etmek istediğimizde, hangi kelimelerin o kelimedenden daha önce geldiğini bilmek isteriz. TSA’larda her bir çıktı önceki girişlere bağlı olduğu için her bir dizinin her elemanı tekrar tekrar çağrılır ve aynı görevi yaparlar. Kısacası TSA’lar bilgi toplayan bir “hafıza” şeklinde de düşünülebilir. TSA’ların mimarisine örnek olarak Şekil 2.3 gösterilebilir.



Şekil 2.3 Tekrarlayan sinir ağıları

- X_t , t zamanında sisteme verilen giriş verisidir. Örneğin, x_1 bir cümledeki ikinci kelimesine karşılık gelen bir vektör olabilir.
- S_t , t zamanındaki gizli durumu temsil etmektedir. Buna ağıın “hafızası” denir. s_t , denklem 2.1’e göre hesaplanır.

$$S_t = f(UX_t + WS_{t-1}) \quad (2.1)$$


f fonksiyonu, genellikle tanh veya relu gibi doğrusal olmayan bir fonksiyondur. S_{t-1} , ilk gizli durumu hesaplamak için kullanılır ve sıfır olarak başlatılır.

- O_t , t zamanındaki çıktıdır. Örneğin, bir cümlede bir sonraki kelimeyi tahmin etmek isteseydik, kelime dağılımımız denklem 2.2’ye göre olasılıksal bir vektör olurdu.

$$O_t = \text{Softmax}(VS_t) \quad (2.2)$$

2.2. Uzun Kısa Dönem Hafıza Ağları – Kapılı Tekrarlayan Birimler

Uzun Kısa Dönem Hafıza Ağları (UKDHA)-(Long Short Term Memory-LSTM) mimarisi Hochreiter ve Schmidhuber tarafından 1997 yılında literatüre kazandırılmıştır [38]. TSA'lar ile aynı amaç için kullanılmaktadırlar fakat TSA mimarileri, bir önceki bilgiyi kullanıma dayalı bir yaklaşım sunmaktadır. Örneğin “Gökyüzünün rengi mavidir” cümlesinde “rengi” kelimesini tahmin etmek kolaydır. Fakat uzun cümlelerde, kelimeler arası ilişkiler azaldıkça geçmişten gelen bir bilgiyi cümle içerisinde tahmin etmek gayet zordur. Örneğin, “Türkiye’de yaşıyorum. Çok iyi Türkçe konuşurum.” gibi bir metinde “Türkçe” kelimesini tahmin ederken, içinde bulunduğu cümleden yola çıkarak bir dil adı olacağı tahmin edilebilir, ancak doğru kelimenin “Türkçe” olduğunu tahmin etmek için, metnin başındaki cümleyi hafızada tutmak gerekmektedir. Bu durumdaki problemler için mimarisi geliştirilmiştir. UKDHA mimarisinin öne çıkan özelliği uzun dönem hafızaya sahip olmasıdır [39]. Şekil 2.4’te UKDHA mimarisi verilmiştir.



Şekil 2.4 UKDHA mimarisi

Burada kullanılan sembollerin anlamları şöyledir:

- a) X: Bilgilerin ölçeklendirilmesi
- b) +: Bilgi ekleme
- c) σ : Sigmoid fonksiyonu (0-1 aralığına çekerek kapı görevi görür.)
- d) tanh: tanh fonksiyonu
- e) $h(t-1)$: Bir önceki hücreden gelen çıkış değerleri
- f) $c(t-1)$: Son hafıza
- g) $X(t)$: Giriş değerleri

h) C (t): Yeni güncellenmiş hafıza

i) h (t): Çıkış değeri

Bilgi birçok UKDHA biriminden geçer. Şekil 2.4'te etiketli bir UKDHA mimarisinde üç ana bileşen bulunmaktadır. Bunlar;

1. UKDHA, gereksiz bilgileri unutmayı sağlayan özel bir mimariye sahiptir. Sigmoid katmanı, X (t) ve h (t-1) girişlerini alır ve eski çıkıştan hangi kısımların çıkarılacağına karar verir (0 çıkışıyla).
2. Bir sonraki adım, yeni giriş X (t) 'den alınan bilgiye karar vermek ve saklamaktır. Sigmoid fonksiyonu yeni bilgilerin hangisinin güncellenmesi veya yok sayılması gerektiğine karar verir. Tanh fonksiyonu, yeni girişten oluşan olası tüm değerlerin bir vektörünü oluşturur. Bu iki yeni hücre durumlarını güncelleştirmek için çarpılır. Yeni bellek daha sonra c (t) değerini alabilmek için eski belleğe c (t-1) eklenir.
3. Son olarak sigmoid fonksiyonu, hangi hücre halinin çıktılarını vereceğine karar verir. Daha sonra, hücre durumunun tüm olası değerlerini üreten bir tanh fonksiyonundan geçirerek sigmoid kapısının çıktısı ile çoğaltır.

Unutma kapısının matematiksel olarak ifadesi denklem 2.3'te gösterilmiştir. Denklem 2.3'te;

f_t , t zamanındaki hafıza kapısının çıkışını,

σ , değerleri 0 ile 1 arasında tutan (normalizasyon) sigmoid fonksiyonunu,

W_f , unutmayı öğrenecek yapay sinir ağına ait ağırlık değerlerini,

h_{t-1} , bir önceki hücreden gelen çıkış değerlerini,

x_t , giriş değerlerini,

b_f , yapay sinir ağlarına ait bias ağırlık değerlerini temsil etmektedir.

Ağın çıkışında 1 bilgiyi tutmayı, 0 ise bilgiyi unutmayı temsil etmektedir.

$$f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f) \quad (2.3)$$

Denklem 2.4'te, giriş kapısının çıkışı I_t ile gösterilmiştir.

σ , değerleri 0 ile 1 arasında tutan sigmoid fonksiyonunu,

W_i , hangi bilgilerin hafızaya gireceğini öğrenecek yapay sinir ağına ait ağırlık değerlerini,

h_{t-1} , bir önceki hücreden gelen çıkış değerlerini,

x_t , giriş değerlerini,

b_i , yapay sinir ağlarına ait bias ağırlık değerlerini temsil etmektedir.

$$I_t = \sigma(W_i * [h_{t-1}, x_t] + b_i) \quad (2.4)$$

Denklem 2.5’de $\tilde{c}_t$, değerleri -1 ile 1 arasında normalize edilmiş tanh fonksiyonlu bir yapay sinir ağı çıkışıdır.

$\tanh$, değerleri 1 ile -1 arasında tutan tanh fonksiyonunu,

W_t , hangi bilgilerin hafızaya girme ihtimalini öğrenecek yapay sinir ağına ait ağırlık değerlerini,

h_{t-1} , bir önceki hücreden gelen çıkış değerlerini,

x_t , giriş değerlerini,

b_c , yapay sinir ağlarına ait bias ağırlık değerlerini temsil etmektedir.

$$\tilde{c}_t = \tanh(W_c * [h_{t-1}, x_t] + b_c) \quad (2.5)$$

Denklem 2.3, 2.4 ve 2.5 ile yapay sinir ağları hafızada kalan veya unutulmuş, hafızaya yeni eklenen veya eklenmeye aday bilgileri öğrendikten sonra denklem 2.6 ile hafıza güncellenir. Eşitliklerdeki * ve + operatörleri her iki taraftaki değişkenin içindeki her ögenin birer birer çarpılması ve toplanması anlamına gelmektedir.

$$C_t = C_{t-1} * f_t + i_t * \tilde{c}_t \quad (2.6)$$

Çıkış kapısının çıkışı O_t ile gösterilmektedir.

σ , değerleri 0 ile 1 arasında tutan sigmoid fonksiyonunu,

W_o , hangi bilgilerin hafızaya gireceğini öğrenecek yapay sinir ağına ait ağırlık değerlerini,

h_{t-1} , bir önceki hücreden gelen çıkış değerlerini,

x_t , giriş değerlerini,

b_o , yapay sinir ağlarına ait bias ağırlık değerlerini temsil etmektedir.

Çıkış değeri h_t , O_t ile $\tanh(C_t)$ ’nin birebir çarpımından oluşmaktadır. Denklem 2.7 ve 2.8’de O_t ve h_t eşitlikleri verilmiştir.

$$O_t = \sigma(W_o * [h_{t-1}, x_t] + b_o) \quad (2.7)$$


$$h_t = O_t * \tanh(C_t) \quad (2.8)$$

Kapılı tekrarlayan birimler (KTB)-(Gated Recurrent Units-GRU), güncelleme ve sıfırlama kapısı olmak üzere iki kapı içermektedir. Güncelleme kapısı, önceki hücre içeriğinin ne kadarının korunacağını gösterirken sıfırlama kapısı, yeni girişin önceki hücre içeriği ile nasıl birleştirileceğini tanımlamaktadır. Bir KTB, standart bir TSA'yı sadece sıfırlama kapısını 1'e, güncelleme kapısını 0'a ayarlayarak modelleyebilir. KTB, UKDHA'dan daha basittir, daha hızlı eğitilebilir ve çalışmasında daha verimli olabilir. Ancak, UKDHA daha fazla veri ile daha iyi ve başarılı sonuçlar verebilmektedir.

2.3. Evrişimsel Sinir Ağları


Evrişimsel sinir ağları (ESA)-(Convolutional Neural Network CNN), imge işleme uygulamalarında orijinal imgeyi direkt olarak kullanan özel tip sinir ağlarıdır. Yapay zekâ içinde, biyolojiden ilham alan en başarılı modellerdir. Birçok farklı felsefenin yönlendirmesine rağmen, çekirdek tasarım ilkeleri nörobilimden alınmıştır. ESA, 1998 yılında Lecun ve arkadaşları tarafından geliştirilmiştir [40]. ESA, işlem katmanlarında öğrenilebilir operatörlerin (hem doğrusal hem de doğrusal olmayan) içerdiği bir dizi algoritmadan oluşmaktadır. Bu nedenle, düşük seviye katmanlardan üst düzey bilgi öğrenme yeteneğine sahiptir. Bu sayede, ayırmacı bilgi üretme süreci otomatikleştirilebilir [41]. ESA mimarileri, uygun eğitimin yapılması durumunda diğer klasik yöntemlere (elle hazırlanmış özniteliklere) göre imge sınıflandırma ve örüntü tanıma alanlarında üstün performans göstermektedir. Sonuç olarak, imge ve video tanıma için yaygın şekilde uygulanmaktadır. Ayrıca imge tanıma, segmentasyon, algılama gibi alanlarda çok ciddi performansları bulunmaktadır.

ESA mimarisi, Giriş - Evrişim – Relu Fonksiyonu - Havuzlama – Tam bağlı katman gibi katmanlardan oluşmaktadır. ESA'lar, Şekil 2.5'te görüldüğü gibi pikseller, kenar kombinasyonundan oluşan motifleri, bu motifler birleşerek imge parçalarını ve imge parçaları birleşerek imgeleri oluşturmaktadır.



Şekil 2.5 ESA katmanlarından sonra oluşan imge temsilleri

ESA yapısı temelde üç farklı katman tipinden oluşur. Bunlar evrişimsel, havuzlama ve tam bağlı katman şeklindedir. ESA mimarisinde, katmanların yapısının nasıl düzenleneceğine dair kesin kurallar yoktur. Bununla birlikte, ESA'lar tipik olarak iki bölüm halinde yapılandırılmıştır. İlk kısım, evrişim ve havuz katmanlarının kombinasyonları kullanılarak öznitelik çıkarımı olarak adlandırılır. Sınıflandırma olarak adlandırılan ikinci bölümde ise tam bağlı katmanlar kullanılmaktadır. Evrişimsel sinir ağlarının genel mimarisi Şekil 2.6'da verilmiştir.



Şekil 2.6 Evrişimsel sinir ağlarının genel mimarisi


2.3.1. Giriş Katmanı

Giriş katmanı ESA mimarisini oluşturan ilk katmandır. İmgeler, bu katmandan direkt olarak evrişim katmanına gönderilmek üzere girdi olarak verilmektedir. Giriş katmanındaki imgelerin boyutu ESA mimarisinin başarımı için önem kazanmaktadır. ESA mimarisinde imgeler piksel seviyesinde işlem gördükleri için imgelerin boyutunun artması, eğitim ve test süresini direkt olarak arttırmaktadır. Fakat buna paralel olarak başarıım oranı da artabilmektedir. Diğer taraftan giriş katmanına verilecek imge boyutunun küçük olması, kullanılacak olan bellek ihtiyacının az olmasına dolayısıyla eğitim ve test sürelerinin azalmasına neden olmaktadır. Bu durumda da ESA mimarisinde çıkan başarıım oranı düşük olabilmektedir. Uygulanacak ESA mimarisinin derinliği ve donanımsal hesaplama maliyetinin optimizasyonu için uygun boyutlara sahip imgelerin uygun ESA mimarilerine verilmesi gerekmektedir.

2.3.2. Evrişim Katmanı

Adından da anlaşılacağı üzere, bu katmanda evrişim işlemi uygulanmaktadır. ESA katmanının ilk girişi olarak bilinmektedir. Evrişim işlemi, çekirdek denilen özel filtreler ile girdi olarak verilen imge üzerinde gerçekleştirilir. Evrişim işleminin çıktısı öznitelik haritası olarak adlandırılmaktadır. Öznitelik haritası her bir filtreye özgü özniteliklerin keşfedildiği bölgelerdir. Evrişim katmanlarına, ilk olarak direkt ham imgeler daha sonra ise kendinden önceki evrişim katmanlarından çıkan öznitelikler verilmektedir. Filtreler 3x3, 5x5, 11x11 gibi kare şeklinde farklı boyutlarda olabilmektedir. Ayrıca, bir önceki katmandan gelen imgelere evrişim işlemini uygulayarak çıkış verisini oluşturmaktadır [42].


İmgeler, piksellerden oluşmaktadır. Her pikselin bir sayısal değeri bulunmaktadır. Bu piksel değerleri imgenin türüne göre değişmektedir. Örneğin; renkli bir imgede bir pikselin üç farklı sayısal değeri bulunmaktadır. Bu değerler, kırmızı, yeşil ve mavi renklerine aittir. Bunun yanı sıra gri tonlu (grayscale) sayısal imgelerin sadece bir sayısal değeri bulunmaktadır. Sayısal imge dosyaları, bu sayısal değerleri matris biçiminde tutar. Örneğin; 32x32 boyutundaki bir imgeyi, 32 satır ve 32 sütundan oluşan bir matrise benzetmektedir. İmgenin piksel değerleri gösterimi Şekil 2.7'deki gibidir.



Şekil 2.7 İmgenin piksel değerleri gösterimi

Evrişim sırasında kullanılan filtreler ve dolgu (padding) tercihlerine bağlı olarak girdiden farklı boyutta öznitelik haritası oluşabilmektedir. Evrişim katmanından sonra çıktının boyutunu kontrol edebilmek için sıfır dolgu işlemi gerçekleştirilmektedir. Dolayısıyla dolgu işlemi, imgenin piksel değerlerinin etrafına yeterli miktarda sıfır ekleme işlemidir. 32 x 32 x 3 boyutundaki girişe 5 x 5 x 3 filtre uyguladığımızda çıkış boyutu 28 x 28 x 3 olacaktır.

Burada ilk evrişim katmanından sonra boyutun azaldığı görülmektedir. Evrişim katmanlarının ard arda kullanılması imge boyutunun hızlı bir şekilde küçülmesine sebebiyet vermektedir. Bu durum orijinal imgeden gerekli özniteliklerin çok hızlı şekilde kaybolmasına yol açmaktadır. Bunun önüne geçebilmek için imgeye dolgu işlemi yapılmakta ve ilk girişe verilen imge hakkında daha fazla bilgi alınabilmektedir. Örneğin; 32 x 32 x 3 boyutundaki girişe 5 x 5 x 3 filtre uyguladığımızda ilk evrişim katmanından sonra yine 32 x 32 x 3 boyutunda kalmasını istiyorsak o katman 2’li 0 (sıfır) dolgu işlemi yapmalıyız. Sıfır dolgu işleminden sonra giriş boyutumuz 36x36x3 yükselecek ve ilk evrişim katmanında 32x32x3 boyutuna inecektir. Dolgu işleminin gösterimi Şekil 2.8’de verilmiştir.



Şekil 2.8 Dolgu işleminin gösterimi


Filtrenin ne kadar kaydırılacağı adım sayısı (Stride) ile belirtilmektedir. Adım sayısı 1 olduğunda, evrişim katmanındaki filtre matrisi 1 piksel kaydırılarak işlem yapılacaktır. Aynı şekilde adım sayısı 2 olur ise evrişim katmanındaki filtre matrisine 2 piksel kaydırılarak işlem yaptırılacaktır [43]. Sıfır dolgu işlemi ve adım sayısına göre filtrenin ilerlemesi çıktı boyutunun belirlenmesindeki parametrelerdir.

Parametrelerden girdi boyutu (i), filtre boyutu (k), adım sayısı (s), dolgu işlemi (p), çıktı boyutu (o) ile temsil edildiğinde; Çıktı boyutunun matematiksel ifadesi denklem 2.9’da verilmiştir.

$$o = \frac{(i - k) + 2p}{s} + 1 \quad (2.9)$$

Şekil 2.8'deki gösterime göre; $i = 32$, $k = 5$, $p = 2$, $s = 1$ olduğundan 2.9'daki formüle göre $o = \frac{(32 - 5) + 2 \cdot 2}{1} + 1$, ilk evrişim katmanından sonra $32 \times 32 \times 3$ boyutu elde edilmektedir.

Bir evrişim işleminin imge üzerindeki gösterimi Şekil 2.9'da gösterilmiştir. Şekil 2.9'da görüldüğü gibi girişi renkli olan bir imgeye 3×3 'lük filtre uygulaması yapılmıştır. 3×3 'lük filtre 1 adım kaydırılarak tüm matrisi dolaşmaktadır. Matris sonuna gelindiğinde 1 basamak aşağı kayarak dolaşımına devam etmektedir. Filtre katsayıları her kanalın matris değerleri ile çarpılıp toplamı alınarak yapılmaktadır. Filtre katsayıları farklı olabilmektedir. Bu katsayıların değerleri tamamen uygulanacak ESA modelinin tasarımına göre yapılmaktadır. Aktivasyon haritasındaki değerler, giriş ve çıkış boyutu arasında aynı yoğunluk aralığını sağlamak için normalize edilir. Bu normalize için her bir renk kanalı için hesaplanan değerler filtre katsayılarının toplamına bölünür. Şekil 2.9'da gösterilen örnekte filtre katsayılarının toplamı sıfır olduğu için bu işlem yapılmamıştır.




Şekil 2.9 Evrişim işleminin imge üzerindeki gösterimi

2.3.3. Düzleştirilmiş Doğrusal Birim Katmanı

Derin öğrenmenin popüler olmasıyla birlikte (Rectified Linear Unit-ReLU)-Düzleştirilmiş Doğrusal Birim Katmanı (DDB) fonksiyonu, dünyada en çok kullanılan aktivasyon fonksiyonlarından biri haline getirmiştir. Hemen hemen tüm evrimsel sinir ağlarında veya derin öğrenmede kullanılmaktadır. Matematiksel gösterimi denklem 2.10'daki gibidir.

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (2.10)$$

DDB katmanı evrişim katmanlarından sonra gelmekte ve kullanılan ağı doğrusal olmayan bir yapıya çevirmektedir. DDB aktivasyon fonksiyonu daha önce kullanılan tanh ve sigmoid aktivasyon fonksiyonlarından daha hızlı olduğu için tercih edilmektedir. DDB, her piksel başına uygulanmakta ve öznetelik haritasındaki tüm negatif piksel değerlerini sıfır olarak değiştirmektedir. DDB aktivasyon fonksiyonunun öznetelik haritasında yaptığı işlem Şekil 2.10'da gösterilmiştir.




Şekil 2.10 Öznetelik haritasından sonra uygulanan DDB fonksiyonu

2.3.4. Havuzlama Katmanı


ESA mimarilerinin önemli katmanlarından biri olan havuzlama (pooling) katmanı, DDB katmanından sonra ESA mimarisine eklenmektedir. Havuzlama katmanı, ağıdaki hesaplamaların sayısını ve hesaplama miktarını azaltmak ve dolayısıyla aşırı öğrenmeyi (ezberleme) kontrol etmek için temsili mekânsal boyutunu kademeli olarak azaltmaktadır.

Diğer bir deyişle doğrusal olmayan alt örnekleme yapmaktadır. Alt örnekleme sonucu giriş verisinde oluşan boyut kaybı bilgi kaybına da yol açmaktadır. Bu bilgi kaybı ağız ezberleme yeteneğini azalttığından dolayı faydalıdır. Havuzlama işlemi imge üzerinde belli bir adım atma değerine göre gezdirilerek yapılmaktadır. ESA mimarilerinde, havuzlama katmanının hiç görülmemesiyle birlikte maksimum havuzlama ve ortalama havuzlama şeklinde de görölmesi mümkündür. Şekil 2.11’de maksimum havuzlama ve ortalama havuzlamanın gösterimi mevcuttur.



Şekil 2.11 Havuzlama katmanı gösterimi

4x4’lük boyuta sahip bir imgenin bir adım ve iki adım kaydırılarak elde edilen 3x3’lük imgenin aşamaları Şekil 2.12’de gösterilmiştir. Bu şekilde 2x2’lik havuzlama filtresi kullanılmıştır.



Şekil 2.12 Bir ve iki adım ilerleme ile maksimum havuzlama işleminin gösterimi

2.3.5. Tam Bağlantılı Katman

Tam Bağlantılı Katman (Fully Connected Layer); Evrişim katmanları, DDB katmanı ve havuzlama katmanlarından sonra sınıflandırma katmanından ise önce gelmektedir. YSA gibi çalışmaktadır. Bu katman, ESA mimarisinde bulunan diğer katmanlara bağlıdır. Bundan dolayı bu katmana tam bağlantılı katman denilmektedir. Tam bağlantılı katmandaki matris boyutu sınıflandırma işleminden önce sınıflandırıcıya girdi olarak verilmektedir.

2.3.6. Genelleme Katmanı

Temel olarak eğitim sırasında bir katman üzerindeki nöronların belirli bir kısmı devre dışı bırakılır. Bu durum eğitim sırasında gerekli olan genelleştirme durumunu iyileştirmektedir. Böylelikle farklı nöronlar ile aynı kavram öğrenilmeye çalışılır. Genelleme katmanı, (Drop-Out Layer), tam bağlı katmanlar üzerinde kullanılacağı gibi maksimum havuz katmanlarından sonra da kullanılması mümkündür. Şekil 2.13'te ağıın orijinal yapısı ve genelleme katmanından sonraki durumu gösterilmektedir.



Şekil 2.13 Ağın orijinal yapısı ve genelleme katmanından sonraki durumu

2.3.7. Sınıflandırma Katmanı


Bu katman, ESA mimarisinin verimliliğini ölçen son katmandır. Tam bağlantılı katmandan sonra gelmektedir. Bu katmanın çıkış değeri, sınıflandırması yapılacak nesne sayısına eşittir. Örneğin iyi huylu ve kötü huylu karaciğer imgelerini sınıflandıracak bir çalışmada sınıflandırma katmanının çıkış değeri 2 olmalıdır. ESA mimarisinde Alexneti kullandığımızda 4096x2 ağırlık matrisi elde edilmektedir. ESA mimarisinde softmax sınıflandırıcısı tercih edilmektedir. Softmax, çıkışın sınıflara ait olma olasılığının dağılımını vermektedir. Dolayısıyla 0-1 arasında değer üretmektedir. Üretilen değerlerin 1'e yakın olması ağın tahmin ettiği nesnenin doğru olma olasılığını arttırmaktadır.

2.4. Derin İnanç Ağları

Kısıtlamış Boltzman Makineleri (KBM) ilk olarak 1986 yılında Smolensky tarafından Harmonium adıyla literetüre kazandırılmıştır [44]. Hinton ve Salakhutdinov tarafından 2000 yılı ortalarında hızlı öğrenme algoritmaları geliştirdikten sonra öne çıkmıştır [45].

KBM'ler, boyut küçültme [45], sınıflandırma [6], işbirlikçi filtreleme [46], özellikli öğrenme [28] ve konu modelleme [47] gibi çalışmalarda kullanılmaktadırlar. Ayrıca yapılacak çalışmaların türüne göre denetimli veya denetimsiz olarak çalışabilmektedirler. KBM, boltzmann makinalarının bir türüdür. Girdi seti üzerinde olasılık dağılımını öğrenebilen üretken bir rastgele yapay sinir ağıdır [48]. Görünür ve gizli olmak üzere aralarında simetrik bağlantı bulunan iki parçalı graflardan oluşmaktadır. Boltzmann

makineleri, enerji fonksiyonunun serbest parametrelerinde doğrusal olduğu, log-linear Markov rastgele alanının özel bir şeklidir. Gizli değişkenlerin daha fazla olması (gizli birimler olarak da adlandırılır) boltzmann makinesinin modelleme kapasitesini artırmaktadır. KBM'nin gösterimi Şekil 2.14'te verilmiştir.



Şekil 2.14 Kısıtlı boltzmann makinasının gösterimi


KBM'nin enerji fonksiyon denklemi 2.11'deki gibidir.

$$E(v, h) = -b'v - c'h - h'Wv \quad (2.11)$$

Burada W gizli ve görünür katmanları bağlayan ağırlıkları, b ve c ise, görünür ve gizli katmanlar arasındaki uzaklıkları ifade etmektedir. Serbest enerji formülü, denklem 2.12'deki gibidir.

$$\mathcal{F}(v) = -b'v - \sum_i \log \sum_{h_i} e^{h_i(c_i + W_i v)}. \quad (2.12)$$

Şekil 2.15'te DİA'ların temsili görüntüsü verilmiştir.



Şekil 2.15 Derin inanç ağları gösterimi


Derin İnanç Ağları (DİA), yeni eğitim algoritması içeren klasik bir ağ mimarisidir. DİA, her bağlı katman çiftinde KBM'nin olduğu birçok gizli katman içeren katmanlı bir ağıdır. Bundan dolayı DİA'lar KBM'lerden oluşan bir yığın olarak temsil edilmektedir. DİA'larda giriş katmanı ham veriyi alırken, her gizli katman ise ham veriden öğrenilen özetleri temsil etmektedir. Çıktı katmanı, diğer katmanlardan biraz daha farklı bir şekilde ağ sınıflandırmasını gerçekleştirir. DİA'lar imge tanıma, bilgi geri alma, doğal dil işleme, başarısızlık tahmini gibi alanlarda kullanılmaktadırlar. Eğitim denetimli veya denetimsiz olmak üzere iki adımda gerçekleşir.

Şekil 2.15'te görüldüğü üzere, denetimsiz öğrenme her bir KBM bloğu giriş verisini yeniden yapılandırmak üzere eğiterek ilk gizli katmana göndermektedir. Bir sonraki katman olan Gizli₂ katmanı, KBM'nin gizli katmanındaki veriyi girdi olarak kabul edip eğitime başlamaktadır. Bu durum bir önceki katmanın sonraki katmanı besleyerek devam etmesiyle sürmektedir. Bu eğitim tamamlandıktan sonra en iyi performansı elde edebilmek için küçük

ayarlamalar yapılmaktadır. Daha sonra, çıkış düğümlerine (ağ bağlamında temsil ettikleri) etiketleme uygulanmaktadır.

2.5. Derin Yığın Ağları

Otomatik kodlayıcılar, giriş katmanı, gizli katman (kodlama) ve kod çözme katmanları olmak üzere üç katmana sahip özel bir yapay sinir ağıdır[49]. Derin Yığın Ağlarında (DYA) gizli katman, giriş katmanından verilen girdilerin iyi bir şekilde temsil edildiğini öğrenmek için yeniden yapılandırmak üzere eğitilmiştir. Bir oto-kodlayıcı sinir ağı, hedef değerlerin girişlere eşit olmasını sağlayacak şekilde, geri yayılımı uygulayan denetimsiz bir makine öğrenme algoritmasıdır [50]. Şekil 2.16'da otomatik kodlama işleminin gösterimi mevcuttur.




Şekil 2.16 Otomatik kodlama işleminin gösterimi

Otomatik kodlayıcılar yapay sinir ağı ailesine aittir, fakat aynı zamanda TBA (temel bileşenler analizi) ile de yakından ilişkileri mevcuttur. Otomatik kodlayıcılar, TBA'ya benzeyen denetlenmeyen bir makine öğrenme algoritmasıdır. TBA gibi öznetelik sayısını indirgenmesi amaçlanmıştır. Otomatik kodlayıcılar, TBA'ya çok benzer olsa da, TBA'dan çok daha esnektirler. Hem doğrusal hem de doğrusal olmayan dönüşümü temsil edebilir, ancak TBA sadece doğrusal dönüşüm yapabilmektedir.

DYA' lar ise, ardışık otomatik kodlayıcılardan oluşan bir sinir ağıdır. Şekil 2.17'de ard arda yerleştirilmiş iki otomatik kodlayıcı verilmiştir. Bu gösterimde kod çözme kısımları verilmemiştir. İlk otomatik kodlayıcı giriş kısmından verileri alarak indirgenmiş öznetelik

verilerini sonraki otomatik kodlayıcıya girdi olarak vermiştir. 2. Otomatik kodlayıcı yine verileri indirgeyerek yeni bir öznitelik verisi oluşturmuştur. Bu öznitelik verileri ise sınıflandırma işlemi için softmax sınıflandırıcısına verilmiştir.



Şekil 2.17 Derin yığın ağlarının gösterimi


3. ALGISAL ÖZET FONKSİYONU

Algısal özet fonksiyonları (AÖF) geleneksel kriptografik fonksiyonlara göre tamamen farklı bir kavramdır. Ancak, algısal özet fonksiyonu da kriptografik bir özet fonksiyonu gibi, bir iletiyi girdi alarak özet değer olarak adlandırılan sabit uzunluklu bir çıktı üretmek için tasarlanmıştır. Fakat AÖF kullanımının ana fikri mesajdaki bireysel bitlere çok duyarlı olmak değil, bunun yerine mesajın “algısal özellikleri” arasındaki farklılıklara duyarlı olmasıdır.

Kriptografik özet fonksiyonlarından farklı olarak, AÖF’ler iki veri arasında algısal benzerlik görüntüsü vermektedir. Mesajın içeriğine dayalı özet değer üreten geleneksel kriptografik özet fonksiyonlarından farklı olarak, algısal özet fonksiyonları “öznitelik çıkarma” işlemi sırasında çıkarılan “öznitelik vektörüne” dayalı özet değer üretmektedir. Başka bir deyişle, algısal özet fonksiyonları, veri akışının kendisi yerine çoklu ortam nesnesinin ayırt edici özniteliklerine dayanan özet değer üretmektedir. Bununla birlikte, mesaj herhangi bir multimedya nesnesi olabilir, ancak öznitelik çıkarımı için tamamen farklı algoritmalar gerekmektedir. Algısal özet fonksiyonları, imgelerin belirgin özniteliklerini tespit ederek özet fonksiyonu oluşturmaktadır. Dolayısıyla algısal özet fonksiyonu ile elde edilen bilgilere imgenin parmak izi de denilebilir. Bu tip özet fonksiyonları 3 aşamadan oluşmaktadır. Bunlar;

- Ön işleme
- Öznitelik çıkarma
- Özet fonksiyonu oluşturma aşamalarıdır.


Şekil 3.1’de Algısal Özet Fonksiyonunun akış diyagramı gösterilmiştir.



Şekil 3.1 Algısal özet fonksiyonu akış diyagramı

Kriptografik özet fonksiyonları, hassas bilgileri yüksek dağılımlı karmaşık değerlerle eşleştirmektedir. Bu durum, kaynak bilgisindeki en ufak değişikliklerin bile, tamamen farklı

sonular retmesine sebep olmaktadır. Bu nedenle, aynı kaynaktan retilen kriptolojik zet fonksiyonlarının benzerlięinin tespit edilmesi imknsızdır. Dięer taraftan AF’ler, kaynak verileri arasındaki benzerlięi lmek iin zet deęerleri arasında anlamlı karřılařtırmalar yapmamıza izin vermektedir. Kriptografik zet fonksiyonları ile AF arasındaki farkın grsel gsterimi řekil 3.2’de verilmiřtir.



řekil 3.2 Kriptografik zet fonksiyonları ile AF arasındaki farkın grsel gsterimi

AF’ler, byk veri tabanlarında oklu ortam nesnesinin tanımlanması / aranmasında, telif hakkı ihlallerinin saptanması vb. gibi alanlarda kullanılmaktadır. AF’lerin bařka bir pratik kullanımı da ierik tabanlı grnt eriřimidir (CBIR). İnternette pornografik imge algılama srecinde filtreleme algoritmaları geliřtirmek iin birok zet fonksiyonu kullanılmaktadır. Ayrıca, AF’ler yardımıyla imge kimlik doęrulaması iin imge filigran teknikleri geliřtirilmektedir. Filigranlama iřleminin temel fikri, uygulamaya baęlı olarak grnmez ikincil verileri (filigranlar) dijital imgelere yerleřtirmektir. Sonu olarak, filigran ieren imgelerin tm kopyaları, imgenin gerek olup olmadıęını veya sahiplięini kanıtlamak iin kullanılmaktadır. İmgenin “algısal zellikleri”, yalnızca imge gvenlięini artırmakla kalmayıp aynı zamanda daha kolay geerlilik doęrulaması yapabilmektedir.

3.1. Algısal Özet Fonksiyonlarının Özellikleri

Algısal özet fonksiyonlarının verimli ve güvenli olmasını sağlamak için Şekil 3.3’de verilen algısal dayanıklılık, çakışmamama yeteneği, tahmin edilemezlik ve sıkıştırma gibi dört temel unsuru korumalıdır.



Şekil 3.3 Algısal özet fonksiyonlarının özellikleri

Bu unsurların önemini anlatabilmek için O 'nun orijinal imge olduğunu, $\hat{O}$ 'nun ise orijinalin algısal özelliklerini koruyan değiştirilmiş bir versiyon olduğunu varsayalım. Başka bir deyişle, O ve $\hat{O}$, insan gözüyle bakıldığında aynı imgelerdir ancak kriptografik olarak farklıdır. M 'nin ise orijinal olandan (O) tamamen farklı bir imge olduğunu varsayalım. θ_1 ve θ_2 , $0 < \theta_1, \theta_2 < 1$ 'i eşitsizliklerini sağlayan iki pozitif değer olsun. Algısal özet fonksiyonu H , K anahtarına bağlı olarak sabit bir parmak izi denebilecek benzersiz bir özet değeri üretir [51].

3.1.1. Algısal Dayanıklılık

Algısal dayanıklılık, aynı anahtar kullanıldığında, algısal olarak benzer imgelerin benzer bir özet değeri oluşturması anlamına gelmektedir [52]. Bu özellik denklem 3.1’deki gibi ifade edilebilir.

$$P (H (O,K)=H (\hat{O},K)) \approx 1 \quad (3.1)$$

Denklem 3.1’de, P olasılığı ifade etmektedir. H , giriş imgesi O ‘ya ve gizli anahtar K ’ye bağlı algısal özet fonksiyonudur. $\hat{O}$ ise O imgesinin algısal özelliklerine sahip değiştirilmiş halidir. O imgesinin değiştirilmiş halinin özet değeri, aynı veya çok küçük farklılıkları

olmalıdır. Bu deęişiklięin olasılık deęeri 1'e eřit veya çok yakın olmalıdır. Dolayısıyla grsel olarak benzer imgelerin zet deęerleri de benzer olması gerekmektedir. Bu sebepten dolayı zellik ıkarma ařamasında belirgin ve dayanıklı zelliklerin elde edilmesi gerekir.

Algısal dayanıklılık, algısal olarak zdeř iki imgenin benzer zet deęerlerine sahip olmasını saęlamaktır. İmgenin deęiřtirilmiř hali sıkıřtırmaya, grltye ve farklı bozulmalara sahip olabilir. Algısal olarak benzer imgelerin ana amacı, JPEG kayıplı dnřm, dndrme, grlt, bulanıklařtırma gibi farklı ierik iřleme operasyonlarına yeterince dayanıklı olmasıdır. Bir imgede bazı bitlerin deęiřmesi insan grme sistemi iin deęiřiklik oluřturmamaktadır. Yani grme sistemimiz bu deęiřiklięi algılayamamaktadır. İmgelerde algısal zet fonksiyonun algısal dayanıklılıęı, benzer imgelerde benzer zet deęerleri retmesini ifade etmektedir.

3.1.2. akıřmama Yeteneęi

akıřmama yeteneęi, aynı anahtar kullanıldığında, algısal olarak farklı imgelerin farklı zet deęerleri oluřturduęu anlamına gelmektedir. Bu zellik denklem 3.2'deki gibi ifade edilebilir.

$$P (H (O,K)=H (M, K)) \approx 0 \quad (3.2)$$

Denklem 3.2'de, P olasılıęı ifade etmektedir. H, giriř imgesi O 'ya ve gizli anahtar K'ye baęlı algısal zet fonksiyonudur. M, farklı bir imgeyi ifade etmektedir. Farklı imgelerin zet deęerleri ok farklı olmalıdır. Bu durumda, iki farklı imgenin algısal zet fonksiyonundan ıkan zet deęerinin benzerlik oranı 0'a ok yakın olmalıdır. Yani, grsel aıdan farklı olan imgelerin zet fonksiyonlarının da farklı olması beklenmektedir. akıřmama yeteneęi, algısal olarak birbirinden ayrı iki imgenin farklı zet deęerlere sahip olmasını ifade etmektedir.

3.1.3. Tahmin Edilememelik

Tahmin edilemezlik, orijinal imgede bazı bitlerin deęiřtirildięi zaman orijinal imge ile bit deęiřiklięi yapılmıř imge iin farklı zet deęerlere sahip olması gerektięini ifade etmektedir. Bylelikle saldırgan tarafından gizli anahtarın tahmin edilebilme olasılıęı azaltılır. Bu zellik denklem 3.3'teki gibi ifade edilebilir.

$$H(O,K); f_h(1) \approx f_h(0) \approx 0.5 \quad (3.3)$$

Denklem 3.3'te, H , giriş imgesi O 'ya ve gizli anahtar K 'ye bağlı algısal özet fonksiyonunu ifade etmektedir. f_h , h özet değerleri olasılıksal kütle fonksiyonu ile değerlerin eşit olarak dağıtıldığını ifade etmektedir. İmgelerde özet fonksiyonlarının anahtar bilgisi olmadan elde edilememesi gerekmektedir. Bu sebepten dolayı, yeterli boyutta anahtar uzayı ve güvenilir bir şifreleme yöntemi kullanılması gerekmektedir. Güvenlik, AÖF'ler için önemli bir sorundur. Olasılıksal kütle fonksiyonu ile h değerlerinin eşit olarak dağıtılması, saldırganın gizli anahtarı ve doğru özet değerini tahmin etme olasılığını azaltmaktadır.

3.1.4. Sıkıştırma

Sıkıştırma, hemen hemen bütün özet fonksiyonlarının önemli bir özelliğidir. Bu özellik denklem 3.4'teki gibi ifade edilebilir.

$$\text{Boyut}(H(O,K)) < \text{Boyut}(O) \quad (3.4)$$

Denklem 3.4'te, H , giriş imgesi O 'ya ve gizli anahtar K 'ye bağlı algısal özet fonksiyonunu ifade etmektedir. Boyut ifadesi toplam bit miktarını ifade etmektedir. Orijinal imgeyle kıyaslandığında özet değeri daha küçük olmalıdır. Sıkıştırma özelliği, büyük veri tabanlarında imge arama sürecini iyileştirmektedir. Ayrıca, orijinal imgeyi özet değerden tekrar orijinal imgeye çevirmeye gerek yoktur, sadece “algısal özellikleri” dikkate alınarak arama işlemi yapılabilmektedir.

3.2. Algısal Özet Fonksiyonların Uygulama Alanları

Algısal özet fonksiyonları, imge ve video arama sitelerinde benzer imge veya videoların tanınması, yüklenen imge veya videoların yüklendikten sonra kullanılmasını engelleyerek, olası bir telif hakkı arayışını önüne geçilmesini sağlayabilmektedir. İmge ve videoların sık kullanıldığı tüm web sitelerinde benzer imgelerin veya videoların AÖF kullanılarak tanınmasının temel iki temel avantajı bulunmaktadır.

- Video ve imge dosya formatlarının orijinal boyutlarından ciddi oranda küçültülerek (1/1000 oranında) saklanıp web sitesi sunucularında az yer kaplaması,
- Web sitesi sunucularında aranacak imgeyi imge boyutunun çok küçülmesinden dolayı daha hızlı bulabilme,

Günümüzden örnek vermek gerekirse; Google imge arama motoru [53] ve TinEye [54], aranan imgeleri veri tabanlarında algısal özet fonksiyonları kullanarak saklamaktadır. Sakladıkları imgeler orijinal boyutlarından hem daha az yer kaplamakta hem de aranan imgenin bulunup bulunmadığı ile ilgili daha çabuk cevap verebilmektedirler.

Teknolojideki ilerlemeler ile imge ve video içeriğinin kullanımı, son yıllarda ciddi bir ivme yakalamıştır. Bu durum imge ve video alanlarında daha fazla araştırma yapılmasına yol açmıştır. AÖF'lerin kullanım açısından sağladıkları avantajlar aşağıdaki gibi sıralanabilir.

3.2.1. Veri Tabanı Alanı Küçülme

Günlük yaşantımızda internet kullanımı, yaşantımızın öncelikli alanlarından birini oluşturmaktadır. Web hizmeti veren şirketler tarafından yapılması gereken başlıca konulardan biri internette karşılaştığımız imgelerin, saklama alanı kontrolünün yapılmasıdır. Tüm imge dosyalarının veri tabanlarında saklanması ciddi bir depolama alanı gerekliliğini ortaya çıkarmıştır. Bu durumu, Google, Yahoo, Yotube, Facebook gibi günde yüz binlerce terabaytlık multimedya verisi depolamak zorunda kalan büyük şirketler açısından düşündüğümüzde ciddi bir depolama problemi ortaya çıkmaktadır. AÖF'ler kullanılan algoritmaların gücü, imge küçültme oranı gibi parametreler göz önüne alındığında mevcut imge veya video boyutunu binde bir oranına kadar azaltabilmektedir [55] .

3.2.2. Telif Hakkı Kontrolü

İmge tanıma sistemi kullanımının en gerekli olduğu yerlerden biri telif hakkı kontrol gerekliliği denebilir. Video ve imge yükleme siteleri için yaygın bir sorun olarak karşımıza çıkmaktadır. Çünkü yüklenen multimedya verisinin farklı telif hakkına sahip olması, şirket için yasal işlem tehdidi ile karşılaşmasına sebebiyet vermektedir. Bu nedenle, bu sitelerin telif hakkı ihlallerini durdurabilecek bir çözüme ihtiyacı vardır. Bu tür bir sistem için en iyi örnek, YouTube içerik kimliği'dir [56]. Yüklenen her video veya imge, telif hakkıyla korunan materyaller içeren bir veri tabanında eşleştirilir. Bir eşleşme bulunursa, video veya imge engellenebilir.

3.2.3. Şirket Reklam Sözleşmelerine Bağlılık Kontrolü

Şirketler verdikleri reklamları; TV, sosyal medya gibi alanlarda belirli bir zaman dilimi içerisinde belirli adette yapılmak üzere anlaşılmaktadırlar. Bundan dolayı, reklam şirketlerinin TV veya sosyal medya alanlarında kullandıkları reklamları takip etmeleri gerekmektedir. Bu durumun kontrolü için ilgili multimedya verisini kendi veri tabanına eşleştirerek, reklamların nasıl ve ne zaman kullanıldığına dair ayrıntılı istatistikler yapabilmektedirler. Bu bilgi daha sonra yayıncının sözleşmeye bağlı olup olmadığının kontrolü için gerekebilmektedir.

3.2.4. Adli Bilişimde Kullanım

İmge tanıma, adli bilişim alanında da kullanılmaktadır. Çoğaltılmış imgeyi algılamak ve imge içeriğini doğrulamak için algısal özet fonksiyonları, verimli bir çözümdür. Örneğin, çocuk pornografisi ile ilgili imge veri tabanı bulunan kolluk kuvvetlerinin, sosyal medya ortamına çocuk pornografisi ile ilgili bir paylaşımda bulunmak isteyen kişiye bu paylaşımından ötürü ulaşabilmesi kolaydır. Çünkü neredeyse aynı veya benzer imgelere ait algısal özet değerleri birbirine çok benzemektedir.

4. ÖNERİLEN YÖNTEMLER

Bu tez çalışmasında derin öğrenme mimarilerinden biri olan ESA mimarisinin çalışma süresi dezavantajını gidermek amacıyla algısal özet fonksiyonu geliştirilmiştir. Kullanılan algısal özet fonksiyonları imgenin dayanıklı özniteliklerini çıkartmakta ve imge boyutunu indirgemektedir. Algısal özet fonksiyonları kullanılarak, derin öğrenme yöntemlerinde var olan hesaplama maliyetinin indirgenmesi sağlanmıştır. Amaca uygun algısal özet fonksiyonu oluşturmak için ADD-TDA fonksiyonlarından yararlanılmıştır. Ayrıca derin öğrenme mimarilerinden ESA mimarisi öznitelik çıkarmada kullanılmıştır. Öznitelik çıkarımı sonucunda çeşitli sınıflandırıcılar ile sınıflandırma işlemi yapılmıştır. Geliştirilen uygulamalar aşağıdaki gibidir.

4.1. Ayırık Dalgacık Dönüşümü – Tekil Değer Ayırışımı Tabanlı Dayanıklı Algısal Özet Fonksiyonu

Algısal özet fonksiyonları multimedya teknolojilerinde yaygın olarak kullanılmaktadır. Bu fonksiyonlar tanımlama, imge indeksleme, kopyalama, hareketli nesne algılama ve adli bilişim alanlarında kullanılmaktadır. Bu çalışmada Ayırık Dalgacık Dönüşümü (ADD) ve Tekil Değer Ayırışımı (TDA) yöntemleri kullanılarak dayanıklı algısal özet fonksiyonu önerilmiştir. Ön işleme aşamasında imge, renkli formattan gri formata dönüştürülerek gauss filtresi uygulanmıştır. Daha sonra imgeye merkezi simetrik yerel ikili desen (MSYİD) uygulanarak özet değeri 8 bitten 4 bite düşürülmüştür. Bu imgelere 3 seviyede ADD uygulanmış ve LL_3 bandı elde edilmiştir. Bu LL_3 bandına, 4×4 boyutunda örtüşmeyen blok kullanılarak TDA uygulanmış ve U, S ve V matrisleri elde edilmiştir. Elde edilen özellik seti, 256 bit uzunluğundaki algısal özet değeri hesaplamak için basamaklandırılmıştır. Önerilen yöntemin performansını hesaplamak için çeşitli saldırılar uygulanmıştır. Deneysel sonuçlar önerilen algısal özet fonksiyonunun saldırılara karşı dayanıklı olduğunu göstermiştir.

4.1.1. Önerilen Yöntem

Bu çalışmada, saldırılara dayanıklı ADD-TDA tabanlı bir algısal özet fonksiyonu önerilmiştir. Önerilen algısal özet fonksiyonu 3 aşamadan oluşmaktadır;

- Ön işleme
- Öznitelik çıkarma

- Özet fonksiyonu üretme

Ön işlem aşamasında, imgeye sırasıyla 3 işlem adımı uygulanmaktadır. Öncelikle, renkli formatta olan imgeler gri formata dönüştürülmektedir. Daha sonra 256 bit uzunluğunda bir özet değer elde etmek için imgeler 514x514 şeklinde yeniden boyutlandırılmaktadır. Özet değeri oluşumu sırasında yumuşaklık veya gürültü işlemlerinden kaynaklanan problemleri en aza indirmek için gauss filtresi kullanılmaktadır.

Öznitelik çıkarma aşamasında, özniteliklerin parlaklık saldırılarına karşı dayanıklı olmasını sağlamak için MSYİD uygulanmaktadır. MSYİD kullanarak, dayanıklı öznitelikler elde edilip 514 x 514 x 8 boyutundaki bir imgeden 512 x 512 x 4 bit boyutunda bir özellik kümesi elde edilir. MSYİD özelliklerini hesaplamak için, 3 x 3 üst üste komşu matris kullanılır ve bu matris Şekil 4.1'de gösterilmiştir.

P_1	P_2	P_3
P_4	P_0	P_5
P_6	P_7	P_8

Şekil 4.1 3x3'lük komşuluk matrisi

$$b_1 = s(p_2 - p_7) \quad (4.1)$$

$$b_2 = s(p_3 - p_6) \quad (4.2)$$

$$b_3 = s(p_5 - p_4) \quad (4.3)$$


$$b_4 = s(p_8 - p_1) \quad (4.4)$$

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (4.5)$$

$$MSYİD_{i,j} = \sum_{k=1}^4 b_k * 2^{k-1} \quad (4.6)$$

İmge üzerinde gezdirilen 3x3'lük matrisler ile elde edilen değerler, sırasıyla eşitlik 4.1-4.6'daki işlemler uygulanarak MSYİD değerleri hesaplanmaktadır.

MSYİD özelliklerini elde ettikten sonra, LL₃ bant görüntüsünü elde etmek için 3. seviyede 2 boyutlu ADD uygulanmıştır. Şekil 4.2'de, örnek imgeye uygulanmış ADD hali gösterilmiştir.



Şekil 4.2 3.seviyede ADD'nin uygulanması

LL₃ matrisini elde etmek için uygulanan denklem 4.7, 4.8 ve 4.9 sırasıyla aşağıda gösterilmiştir.

$$[LL \ LH \ HL \ HH] = DWT2(CSLBP, wt) \quad (4.7)$$


$$[LL2 \ LH \ HL \ HH] = DWT2(LL, wt) \quad (4.8)$$

$$[LL3 \ LH \ HL \ HH] = DWT2(LL2, wt) \quad (4.9)$$

Yukarıdaki denklemlerde ifade edilen LL alçak-alçak filtresini, LH alçak-yüksek filtresini, HL yüksek-alçak filtresini, HH yüksek-yüksek geçişli filtrelerinin alt bantlarını temsil etmektedir. DWT₂ 2 boyutlu ayrık dalgacık dönüşümünü, wt dalgacık tipini temsil etmektedir. Burada LL₃ alt bant katmanı, algısal özet değeri elde etmek için kullanılmaktadır. Elde edilen LL3 bandı 64 x 64 boyutundadır. Son aşamada elde edilen LL3 bandı, 4x4 örtüşmeyen bloklara ayrılıp ve tekil değerler elde etmek için her bloğa TDA uygulanmıştır. Daha sonra denklem 4.10'daki gibi tekil değerlerden oluşan 16x16 boyutlu bir özellik matrisi oluşturulmaktadır.

$$D(LL3_{i:i+3,j:j+3}) = \begin{bmatrix} u_{11} & u_{12} & u_{13} & u_{14} \\ u_{21} & u_{22} & u_{23} & u_{24} \\ u_{31} & u_{32} & u_{33} & u_{34} \\ u_{41} & u_{42} & u_{43} & u_{44} \end{bmatrix} * \begin{bmatrix} s_{11} & 0 & 0 & 0 \\ 0 & s_{22} & 0 & 0 \\ 0 & 0 & s_{33} & 0 \\ 0 & 0 & 0 & s_{44} \end{bmatrix} * \begin{bmatrix} v_{11} & v_{12} & v_{13} & v_{14} \\ v_{21} & v_{22} & v_{23} & v_{24} \\ v_{31} & v_{32} & v_{33} & v_{34} \\ v_{41} & v_{42} & v_{43} & v_{44} \end{bmatrix} \quad (4.10)$$

Son olarak, elde edilen matrisin değerleri ile 256 bitlik bir özet değer elde edilir. Önerilen yöntemin blok şeması Şekil 4.3'te verilmiştir [57].



Şekil 4.3 Önerilen yöntemin blok şeması

4.1.2. Deneysel Sonuçlar

Bu bölümde, önerilen yöntemin performansını ölçmek için çeşitli saldırılar yapılarak elde edilen deney sonuçları gösterilmiştir. Algısal özet fonksiyonundan sonra çıkan imgeler arasındaki benzerlikler, hamming mesafesi kullanılarak ölçülmüştür. Hamming mesafe ölçüm denklemi 4.11'de verilmiştir.

$$\text{Dis}(Z'_1, Z'_2) = \frac{1}{S} = \sum_{i=1}^S |Z_1(i) - Z_2(i)| \quad (4.11)$$

Burada, Z_1' ve Z_2' , iki imgenin algısal özet fonksiyonundan sonraki halini ifade etmektedir. S , özet uzunluğunu temsil etmektedir. $Z_1(i)'$ ve $Z_2(i)'$, sırasıyla Z_1' ve Z_2' imgelerinin i . bitlerini göstermektedir. Önerilen algoritmanın performansını test edebilmek için SIPI imge veri tabanından seçilmiş 512 x 512 boyutunda 20 adet RGB imge kullanılmıştır [58]. RGB imgelerine uygulanan MSYİD, ADD, TDA yöntemleri ile imgeler 16x16 boyutuna indirgenmiştir [57]. Kullanılan imgeler Şekil 4.4'te gösterilmiştir.




Şekil 4.4 SIPI veri tabanına ait kullanılan imgeler

Algısal olarak dayanıklı olan özet fonksiyonlarından beklenen, saldırılardan sonra görüntü manipülasyonlarını tespit etmesi ve bu manipülasyonlar sonucu dayanıklı olmasıdır. Dolayısıyla, algısal özet fonksiyonundan sonra çıkan aynı 2 imgeden saldırıya uğrayan imge ile saldırıya uğramamış imgenin arasındaki hamming mesafesi yeterince küçük olmalıdır. Bu çalışmada algısal dayanıklılığı ölçmek için, Şekil 4.4'te verilen 20 standart test imgesi kullanılmıştır [58]. Bu imgelere ortalama filtre, Gauss filtresi, Jpeg sıkıştırma, ölçeklendirme ve döndürme gibi saldırılar uygulanmıştır. Bu saldırılara karşı dayanıklılığı ölçmek için hamming uzaklığı kullanılmıştır. Ölçümler, Tang ve arkadaşlarının [59], Choi ve Park'ın çalışması [60] ayrıca Davarzani ve arkadaşlarının [61] çalışmalarından daha üstün olan Qin [62] ve arkadaşlarının yöntemi ile karşılaştırılmıştır. Önerilen yöntemin algısal sağlamlığı, Qin ve meslektaşlarının ölçümlerinden daha iyi sonuçlar vermiştir. Elde edilen sonuçlar Tablo 4.1'de gösterilmiştir.

Tablo 4.1 Önerilen yöntemin Hamming uzaklık ölçüt değerleri

	Qin ve arkadaşları [62]			Önerilen Yöntem 16x16 İmge Boyutu [57]		
	Ort.	Maks.	Min.	Ort.	Maks.	Min.
JPEG sıkıştırma=50	0.0257	0.0521	0.0089	0.003705	0.0117	0
JPEG sıkıştırma=80	0.0225	0.0402	0.0060	0.003705	0.039	0
Gaussian filtreleme =0.6	0.0257	0.0551	0.0104	0.00273	0.0156	0
Gaussian filtreleme =1.6	0.0280	0.0639	0.0119	0,00702	0.0195	0
Ortalama filtreleme =3	0.0369	0.0814	0.0179	0.046875	0.0781	0.0117
Ortalama filtreleme =7	0.0307	0.0833	0.0744	0.06387	0.1133	0.0195
Orta filtreleme =3	0.0342	0.0640	0.0119	0.01289	0.043	0
Orta filtreleme =7	0.0560	0.0997	0.0104	0.02683	0.0938	0.0039
Ölçeklendirme =0.6	0.0144	0.0268	0.0045	0.01151	0.0352	0
Ölçeklendirme =2.0	0.0123	0.0253	0	0.00117	0.0078	0
Döndürme =-1	0.1792	0.2485	0.1235	0.12501	0.2148	0.0664
Döndürme =0.5	0.1112	0.1592	0.0625	0.10371	0.1523	0.0586

Önerilen algısal özet fonksiyonu imge boyutlandırma, gaussian filtreleme, merkezi simetrik yerel ikili desenler, 3 seviyeli ADD, TDA ve basamaklandırma aşamalarından oluşmaktadır. Bu yöntemin temel amacı saldırılara karşı dayanıklı bir özet fonksiyonu elde etmektir. MSYİD literatürde sıklıkla kullanılan imge tanımlayıcılardan birisidir. Bu tanımlayıcının en önemli özelliği dokusal özellik çıkartma yöntemlerinde yüksek başarıma sahip olmasıdır. MSYİD işaret fonksiyonu ve 3 x 3 boyutundaki yerel bloklar kullanarak 8 bitlik imgeyi 4 bite indirgemektedir. Önerilen yöntemi test etmek için literatürde bulunan 20 gri seviyeli test imgesi kullanılmıştır. Dayanıklılığın ölçümü için ise Qin ve ark.'nın kullandığı bir atak seti kullanılmıştır. Bu atak seti sayısal damgalama yöntemlerinde de kullanılmaktadır. Sonuçları elde etmek için bir atak birden fazla kez uygulanmış ve hamming uzaklığı kullanılarak ölçümler yapılmıştır. Tablo 4.1'de minimum maksimum ve ortalama hamming uzaklıkları verilmiştir. Bu iki yöntemin karşılaştırılmasının en önemli amacı her iki yöntemin 16x16 boyutunda yani 256 bit uzunluğunda özet değeri üretmesidir. Qin ve ark.'nın önerdiği yöntem ile önerdiğimiz yöntemin karşılaştırılması Şekil 4.5'te verilmiştir.



Şekil 4.5 Önerilen yöntemin karşılaştırılması

Şekil 4.5'te verilen karşılaştırma grafiğinde önerilen yöntem, toplam 12 atağın 10'unda daha başarılı sonuçlar elde etmiştir. Bu sonuçlar önerilen yöntemin, AÖF temel bileşenlerini optimum şekilde kullanarak başarılı bir yöntem olduğunu göstermektedir.


Literatürde yapılan çalışmalar incelendiğinde [59-62], imgelerin algısal dayanıklılığını arttırmak için boyutları 16x16'ya indirildiği görülmektedir. Fakat önerdiğimiz yöntemin dayanıklılığını test edebilmek için 32x32, 64x64 ve 128x128 boyutlarındaki algısal özet fonksiyonlarına da aynı ataklar yapılmış ve ortalama, maksimum ve minimum hamming uzaklıkları hesaplanmıştır. 32x32, 64x64 ve 128x128 boyutlarındaki imgelerdeki hamming uzaklık değerleri Tablo 4.2'de verilmiştir.

Tablo 4.2 32x32, 64x64 ve 128x128 boyutlu imgelerde Hamming uzaklık ölçüt değerleri

	32x32 İmge Boyutu			64x64 İmge Boyutu			128x128 İmge Boyutu		
	Ort.	Maks.	Min.	Ort.	Maks.	Min.	Ort.	Maks.	Min.
JPEG sıkıştırma=50	0.0064	0.0146	0,0000	0.0075	0.0186	0,0000	0.0113	0.0320	0,0000
JPEG sıkıştırma=80	0.1158	0.1709	0.0742	0.0030	0.0071	0,0000	0.0050	0.0107	0,0000
Gaussian filtreleme =0.6	0.0030	0.0098	0	0.0038	0.0103	0.0002	0.0076	0.0198	0.0010
Gaussian filtreleme =1.6	0.0087	0.0234	0,0000	0.0165	0.0405	0.0024	0.0350	0.0719	0.0060
Ortalama filtreleme =3	0.06387	0.1133	0,0000	0.0801	0.1699	0,0000	0.0228	0.0473	0.0107
Ortalama filtreleme =7	0.1037	0.1699	0,0000	0.1158	0.1709	0,0000	0.0647	0.1208	0.0206
Orta filtreleme =3	0.0282	0.0469	0.0078	0.0206	0.0364	0.0081	0.0228	0.0469	0.0078
Orta filtreleme =7	0.1172	0.1709	0.0918	0.0433	0.0789	0.0244	0.0811	0.1133	0.0060
Ölçeklendirme =0.6	0.0173	0.0303	0.0009	0.0256	0.0503	0.0015	0.0416	0.1029	0.0034
Ölçeklendirme =2.0	0.0010	0.0029	0,0000	0.0021	0.0034	0,0000	0.0029	0.0052	0.0006
Döndürme =-1	0.1154	0.1699	0.0752	0.1367	0.2197	0.0735	0.1560	0.2930	0.0727
Döndürme =0.5	0.0801	0.1133	0.0576	0.0864	0.1340	0.0479	0.1085	0.1966	0.0467

Şekil 4.6, Tablo 4.2’de verilen hamming uzaklık ölçümünün ortalama değerlerinin grafiğidir.

Algısal özet boyutunun artması genel olarak dayanıklılığın düşmesine neden olduğundan Hamming uzaklık ölçütlerinin artmasına sebebiyet vermektedir. Bu durum Şekil 4.6’da görülmektedir.



Şekil 4.6 Önerilen yöntemin 32x32, 64x64 ve 128x128 boyutlu imgelerde Hamming uzaklık ölçütüyle karşılaştırılması

4.1.1. Sonuç

Bu yöntemde, ADD-TDA tabanlı dayanıklı bir algısal özet fonksiyonu önerilmiştir. Önerilen algısal özet fonksiyonu 3 aşamadan oluşmaktadır. Bu aşamalar; ön işleme, öznetelik çıkarımı ve özet değeri üretme aşamalarıdır. Ön işleme aşamasında, renkli imgeleri griye dönüştürme, imge yeniden boyutlandırma ve gauss filtre uygulama adımları yapılmıştır. Öznetelik çıkarma aşamasında, MSYİD, 3. seviyede ADD ve TDA yöntemleri kullanılmıştır. Özet değeri oluşturma aşamasında, özellik kümesi basamaklandırılarak elde edilmiştir. Önerilen yöntem çeşitli saldırılar yapılarak dayanıklılığı ölçülmüş ve dayanıklı olduğu görülmüştür. Önerilen yöntem, literatürde bulunan en başarılı yöntem ile karşılaştırılmış ve daha başarılı sonuçlar elde etmiştir. MSYİD operatörü kullanımıyla parlaklık ve kontrast ataklarına karşı güçlü olduğu, ADD kullanımıyla jpeg sıkıştırmaya karşı dayanıklı olduğu, TDA kullanımı sayesinde ise rotasyon saldırılarına karşı dayanıklı olduğu görülmüştür.

4.2. Renkli İmgeler için Yeni Bir Algısal Özet Fonksiyonu Tabanlı Olasılıksal Kimlik Doğrulama Yöntemi

İmge içeriklerini korumak için birçok imge kimlik doğrulama yöntemi kullanılmıştır. İmgelerde kimlik doğrulamasını sağlamak için yaygın olarak kullanılan yöntemlerden biri de kırılğan damgalamadır. Bu çalışmada, KYM imgeleri için yeni bir özet fonksiyonu tabanlı imge kimlik doğrulaması önerilmiştir. İlk olarak K, Y ve M katmanlarına göre evrensel özet fonksiyonu değiştirilerek filigran oluşumu için 3 farklı fonksiyon elde edilmiştir. Bu yöntemde, filigranı imgeye gömebilmek için bir katman kullanılmıştır. Mod tabanlı veri gizleme yöntemi filigran gömmek için kullanılmaktadır. Önerilen yöntemin gizliliğini sağlamak için, lojistik harita olan kaotik rastgele sayı üretici kullanılmıştır. Gömme katmanı ve filigran oluşturma fonksiyonu, lojistik harita kullanılarak seçilip filigran çıkartılmasında, mod operatörü kullanılmaktadır. Değiştirilmiş alan tespiti için filigran oluşturma adımı tekrarlanmaktadır. Çıkarılan filigran ve oluşturulan filigran birbiriyle karşılaştırılır. Bu filigranlar eşitse, imge doğrulanır, aksi halde değiştirilmiş alan tespiti algılanır. Önerilen metotta, ADD ve TDA imgelerin algısal özet değerlerini oluşturmak ve imgeleri tekrar geri çıkartmak için kullanılmaktadır. Deneysel sonuçlar, önerilen yöntemin ADD-TDA tabanlı algısal özet fonksiyonu kullanımıyla minimum bozulma ile yüksek imge kimlik doğrulama yeteneği sağladığını göstermektedir.

4.2.1. Önerilen Yöntem

Önerilen yöntemin amacı, yüksek görüntü kalitesi ve değiştirilen alan tespiti yeteneği ile renkli imgelerde imge kimlik doğrulamasıdır. Önerilen yöntemde 3 katmanlı imgeler kullanılmıştır, ancak minimum bozulmuş filigranlı imgeler elde etmek için sadece bir katmana gömme işlemi uygulanmıştır. Önerilen yöntem aşağıdaki gibi 5 bölümden oluşmaktadır.

- Filigran oluşturma,
- Filigran gömme,
- Filigran çıkarma,
- Değiştirilen alan tespiti,
- İmgeyi yeniden elde etme,

Filigran oluşturma aşamasında, evrensel özet fonksiyonunun parametreleri sırasıyla R, G ve B katmanlarından elde edilmektedir. Gömme katmanına göre elde edilen filigran üretim denklemleri tablosu Tablo 4.3'te gösterilmiştir.

Tablo 4.3 Filigran üretim denklemleri

Gömme Katmanı	Filigran üretim denklemleri
R	$GB + \left\lfloor \frac{R}{l} \right\rfloor (mod p)(mod l)$
G	$RB + \left\lfloor \frac{G}{l} \right\rfloor (mod p)(mod l)$
B	$RG + \left\lfloor \frac{B}{l} \right\rfloor (mod p)(mod l)$

Tablo 4.3'te gösterilen denklemler gömülebilir değerleri belirlemek için kullanılmaktadır. Bu denklemde R , G ve B sırasıyla R, G, B katmanlarındaki piksel değerlerini, l mod değerini, p , $l < p < 255^2 + \left\lfloor \frac{255}{l} \right\rfloor + 1$ denkleminde verilen aralığa göre asal sayıyı ifade etmektedir. Bu denklemler filigran üretimi için kullanılmaktadır. Bu çalışmada, yerleştirme katman seçimi ve filigran üretimi için lojistik harita kullanılmıştır. Lojistik harita kaotik bir haritadır. Lojistik harita denklemi denklem 4.12'de verilmiştir.


$$x_{i+1} = hx_i(1 - x_i) \quad (4.12)$$

Denklemden 4.12’de h , kaos katsayısını ifade etmektedir. h , $3.57 \leq h \leq 4$ aralığındadır. x_1 , başlangıç değeridir ve $0 < x_1 < 1$ aralığındadır. Ayrıca $x_1 \neq \{0.25, 0.5, 0.75\}$ şartını sağlamalıdır. h ve x_1 , lojistik haritanın çekirdek değerlerini ifade etmektedir. Denklem 4.13 ve 4.14, filigran oluşturma ve gömme katmanını seçmek için kullanılmaktadır.

$$x_i = \text{round}(x_i 7^5) \pmod{3} \quad (4.13)$$

$$\text{round}(x_i) = \begin{cases} \lfloor x_i \rfloor, & x_i \pmod{1} < 0.5 \\ \lceil x_i \rceil, & x_i \pmod{1} \geq 0.5 \end{cases} \quad (4.14)$$

Filigran oluşturma ve veri gizleme blok şeması Şekil 4.7’de gösterilmiştir.



Şekil 4.7 Önerilen yöntemin filigran oluşturma ve filigran gömme diyagramı

Önerilen yöntemin filigran oluşturma ve filigran gömme adımlarının sözde kodu Tablo 4.4’te verilmiştir.


Tablo 4.4 Filigran oluřturma ve filigran gmme adımları szde kodu

```

Giriř: W x H x 3 boyutundaki orijinal imge OI, l mod deęeri ( $2 \leq l \leq 16$ ), asal sayı p ( $p > 1$ ), h kaos katsayısı,
bařlangıç deęeri x (1)
1: WI=OI;
2: Denklem. 4.13'ü kullanarak x üret
3: for i= 1 to W do
4:   for j=1 to H do
5:     R= OI(i,j,1); G= OI(i,j,2); B=OI(i,j,3);
6:      $wm(1) = GB + \left\lfloor \frac{R}{l} \right\rfloor \pmod{p} \pmod{l}$ 
7:      $wm(2) = RB + \left\lfloor \frac{G}{l} \right\rfloor \pmod{p} \pmod{l}$ 
8:      $wm(3) = RG + \left\lfloor \frac{B}{l} \right\rfloor \pmod{p} \pmod{l}$ 
9:     watermark= wm(x(i,j) + 1);
10:    ob=OI(i,j,x(i,j)+1) (mod l);
11:    if OI(i,j,x(i,j)+1)+watermark-ob $\geq 0$  and OI(i,j,x(i,j)+1)+watermark-ob $\leq 255$  then
12:      WM(i,j,x(i,j))= WM(i,j,x(i,j)+1)+ watermark-ob;
13:    elseif OI(i,j,x(i,j)+1)+watermark-ob<0
14:      WM(i,j,x(i,j)+1)= WM(i,j,x(i,j)+1)+ watermark-ob+ l;
15:    else
16:      WM(i,j,x(i,j+1))= WM(i,j,x(i,j)+1)+ watermark-ob- l;
17:    endif
18:  endfor
19: endfor
Output: W x H x 3 boyutundaki filigranlı imge

```

Bu alıřmada, filigran gmme iin mod tabanlı veri gizleme yntemi kullanılmıřtır. Filigran gmme ařamaları Tablo 4.4'ün 10 ile 16 satırları arasında gsterilmiřtir. nerilen veri ıkarma ve imge kimlik doęrulamasının blok řeması řekil 4.8'de verilmiřtir.



řekil 4.8 nerilen veri ıkarma ve imge kimlik doęrulamasının blok diyagramı

Önerilen veri çıkarma ve kimlik doğrulama algoritmasının sözde kodu Tablo 4.5'te verilmiştir.


Tablo 4.5 Veri çıkarma ve kimlik doğrulama algoritmasının sözde kodu

```

Giriş: W x H x 3 boyutundaki orijinal imge OI, l mod değeri ( $1 \leq l \leq 16$ ), asal sayı p ( $p > 16$ ),
1: Denklem. 4.14'ü kullanarak x üret
2: for i= 1 to W do
3:   for j=1 to H do
4:     Tablo 4.4'teki 5-9 adımlarını kullanarak filigran üret.
5:      $exW(i,j) = WI(i,j, x(i,j) + 1) \pmod{l}$ 
6:     if watermark(i,j) != exW(i,j) then
7:       tampered_image(i,j)=1;
8:     else
9:       tampered_image(i,j)=0;
10:    endif
11:  endfor
12: endfor
Çıkış: W x H boyutunda, alan değişikliğine uğrayan imge, W x H boyutunda çıkartılan filigran (ExW)

```

ADD ve TDA, imgenin algısal özet değerini oluşturmak için kullanılmaktadır. Bu özet fonksiyonu imgeyi geri çıkartmak için kullanılır. Önerilen ADD-TDA tabanlı algısal özet fonksiyonunun blok şeması Şekil 4.9'da verilmiştir.



Şekil 4.9 ADD-TDA tabanlı algısal özet fonksiyonunun blok diyagramı

ADD-TDA algısal özet fonksiyonunun aşamaları aşağıda verilmiştir.
 Adım 1: LL alt bandını elde etmek için örtü imgesine ADD uygulayın.

Adım 2: LL alt bandının katsayılarına 2 x 2 blok TDA uygulayın ve maksimum S katsayıları elde edin.

Adım 3: Maksimum S katsayılarına nicemleme yapın.

Adım 4: Gizli bir anahtarla şifreleyin.

Önerilen yöntemin imgeyi yeniden elde etme algoritması Tablo 4.6’da gösterilmiştir.


Tablo 4.6 İmgeyi yeniden elde etme algoritması sözde kodu

Input: W x H x 3 boyutunda saldırıya uğramış imge (AI), W x H bayt boyutuna sahip alan değişikliğine uğramış imge (TI), $\frac{W \times H \times 5}{16} \times 3$ bit büyüklüğüne sahip ile algısal özet değeri (PH).

```
1: row=0;
2: for i= 1 to W step by 4 do
3:   col=0;
4:   for j=1 to H step by do
5:     sum=0;
6:     for k=0 to 3 do
7:       for l=0 to 3 do
8:         sum=sum+TI(i+k,j+l);
9:       end
10:    end
11:    if sum≠0 then
12:      for h=1:3 do
13:        RI(i,j,h)=PH(row+1,col+1,h)*
           $\begin{bmatrix} 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 \end{bmatrix} * 8$ 
14:      endfor
15:    else
16:      RI(i,j,:)= AI(i,j,:);
17:    endif
18:    col=col+1;
19:  endfor
20:  row=row+1;
21: endfor
```

Output: W x H x 3 boyutunda yeniden elde edilmiş imge (RI)

Önerilen yöntemin blok diyagramı Şekil 4.10'da verilmiştir.



Şekil 4.10 Önerilen yöntemin blok diyagramı

4.2.2. Deneysel Sonuçlar

Önerilen yöntemin performansını değerlendirmek için üç değerlendirme parametresi kullanıldı. Kullanılan parametreler aşağıda verilmiştir.

- Görsel kalite
- İmge kimlik doğrulama yeteneği
- İmge yeniden elde etme


Görsel kalite: Görsel kaliteyi ölçmek için ortalama karesel hata (OKH) ve TSGO değerleri kullanılır. OKH ve TSGO denklemleri 4.15 ve 4.16’da verilmiştir.

$$OKH = \frac{1}{WHK} \sum_{k=1}^K \sum_{i=1}^W \sum_{j=1}^H (CI_{i,j,k} - WI_{i,j,k})^2 \quad (4.15)$$

$$TSGO = 10 \log_{10} \left(\frac{\max(CI)^2}{OKH} \right) \quad (4.16)$$

CI örtü imgesini, WI filigranlı imgeyi, W imgenin genişliğini, H ise imgenin yüksekliğini temsil etmektedir.

USC-SIPI [58] imge veri tabanı, önerilen algoritmanın performansını test etmek için kullanılmıştır. Test imgeleri 512 x 512 x 3 boyutunda renkli imgelerden oluşmaktadır. Çalışmada kullanılan imgeler Şekil 4.11’de gösterilmiştir.



Şekil 4.11 SIPI imge veri tabanı test imgeleri (a) Lena (b) Baboon (c) Peppers

Her bir mod değeri için önerilen yöntemin tepe sinyal gürültü oranları (TSGO) değerleri Tablo 4.7’de verilmiştir.

Tablo 4.7 Önerilen yöntemin TSGO değerleri

İmge	TSGO			
	l=2	l=4	l=8	l=16
Lena	56.05	48.94	42.71	36.47
Pepper	56.09	48.90	42.72	36.89
Baboon	56.05	48.89	42.67	36.61

Önerilen yöntem yüksek görsel kaliteye sahiptir. Tablo 4.7’deki TSGO değerleri bu durumu doğrulamaktadır. İdeal TSGO değeri $10 \log_{10} 255^2 = 48.13$ desibel (dB) olarak hesaplanmıştır. Tablo 4.7 l=2 değeri için önerilen yöntemin yaklaşık 56 dB TSGO değerine ulaşmaktadır.

Önerilen yöntem Tablo 4.8’de verilen ve literatürde yaygın olarak kullanılan 6 yöntemle karşılaştırılmıştır ve görsel kalite başarımları karşılaştırmalar kullanılarak da doğrulanmıştır.


Tablo 4.8 Önerilen yöntemin görsel kalite açısından karşılaştırmalı performans tablosu

	[63]	[64]	[65]	[66]	[67]	[68]	Önerilen yöntem [69]
Lena	43.82	46.11	42.28	47.59	51.10	52.91	56.05
Pepper	43.78	46.14	42.30	47.53	51.10	52.91	56.09
Baboon	43.81	46.14	42.31	47.55	51.10	52.91	56.05

Kimlik Doğrulama Yeteneği: Önerilen yöntemin kimlik doğrulama yeteneğini test etmek için, imgelere saldırılar uygulanmıştır. Literatürde, kimlik doğrulama özelliğini değerlendirmek için BHO (Bit Hata Oranı) kullanılmıştır. Denklem 4.17’de verilmiştir.

$$BHO = \frac{\#Değişen\ bit\ sayısı}{\#Toplam\ bit} \quad (4.17)$$

BHO, önerilen yöntemin sağlamlığını değerlendirmek için kullanılmıştır. Şekil 4.12’de, Lena filigranlı görüntünün sol üst köşesine saldırılmış Lena görüntüsü eklenerek BHO değerleri verilmiştir.



Şekil 4.12 SIPI imge veri tabanı test imgeleri - Lena

Şekil 4.12 önerilen yöntemin yüksek filigran gizleme kapasitesi elde edebildiğini göstermektedir. Kapasite l sayısı ile doğru orantılıdır. Önerilen yöntemin imge kimlik doğrulama yeteneğini test etmek için literatürde sıklıkla kullanılan saldırı filigranlanmış imgeye uygulanmıştır. İmge kimlik doğrulama yeteneği BHO kullanılarak ölçülmüş ve l=16

için 0.94 BHO değeri elde edilmiştir. Filigran kapasitesi arttıkça BHO oranının da arttığı görülmektedir.

İmge yeniden elde etme: Önerilen yöntemin imgeyi yeniden elde edebilme kapasitesini değerlendirmek için test imgelerine çeşitli saldırılar uygulanmıştır. İmgeyi yeniden elde etme yeteneğini değerlendirmek için, Şekil 4.13’de gösterilen saldırılar filigranlı Lena görüntüsüne uygulanmıştır. İmge yeniden elde edebilme yeteneğini değerlendirmek TSGO değerleri Tablo 4.9’da verilmiştir.



Şekil 4.13 (a) Saldırı yapılmış imge (b) Değiştirilmiş alan tespiti (c) İmgeyi yeniden elde etme

Tablo 4.9 İmgeyi yeniden elde edebilme kapasitesini değerlendirme tablosu

	%5	%10	%15	%20	%25	%30	%35	%40	%45	%50
Lena	40.33	35.16	33.41	32.69	31.62	30.52	29.63	29.08	28.57	27.99
Baboon	42.32	36.75	34.82	33.79	32.71	31.58	30.94	30.39	29.87	29.38
Pepper	43.66	40.11	37.52	35.90	34.64	33.99	32.70	31.85	31.10	30.34

AÖF tabanlı yeni bir imge kurtarma algoritması önerilmiştir. Bu yöntemin başarımını test etmek için 10 adet atak uygulanmıştır ve sonuçlar AÖF’ün imge kimlik doğrulamada atak yapılmış alanları kurtarabilecek bir yöntem olduğunu doğrulamaktadır. Önerilen yöntemin sınırlılığı ise görsel kalite ve imge kimlik doğrulama yeteneğinin ters orantılı olmasıdır. Literatürdeki birçok yöntemde de aynı durumla karşılaşılmaktadır.

4.2.3. Sonuç

Önerilen yöntem, imge kimlik doğrulaması için filigran oluşturma, filigran gömme, filigran çıkarma, değiştirilmiş alan tespiti ve imgeyi yeniden elde etme adımlarından oluşmaktadır. Evrensel algısal özet fonksiyonları 3 katmanlı renkli imgelerde filigran oluşturma adımı için kullanılmaktadır. Filigran oluşturma fonksiyonu seçimi için lojistik harita kullanılmaktadır. Çıkarılan öznitelikler, mod tabanlı filigran gömme denklemi kullanılarak gömülmüştür. Mod işlemi, veri çıkarma adımıyla kullanılmaktadır. Değiştirilmiş alan tespiti adımıyla, çıkarılan filigran ile oluşturulan filigran karşılaştırılır. Karşılaştırmada bir fark tespit edilirse, orijinal imgeyi kurtarmak için imge kurtarma adımı kullanılır. İmgenin yeniden elde edilmesi adımıyla ADD-TDA tabanlı algısal özet fonksiyonu kullanılmaktadır. Önerilen yöntemin test edilmesi için görüntü kalitesi, imge yeniden elde etme ve kimlik doğrulama yeteneği gibi ölçümler kullanıldı. Deneysel sonuçlar önerilen yöntemin başarılı olduğunu ve yüksek derecede imge kimlik doğrulama özelliğine sahip olduğunu göstermiştir.


4.3. Algısal Özet Fonksiyonu Tabanlı Evrimsel Sinir Ağları Kullanarak Karaciğer İmge Sınıflandırması için Yeni Bir Yöntem

Karaciğer kitlelerinin sınıflandırılması, hastaların erken teşhisinde önemli rol oynamaktadır. Bu makalede, Karaciğer Bilgisayarlı Tomografi (BT) imgelerinin sınıflandırma süresinin kısaltılması ve sınıflandırma performansının ESA kullanılarak kabul edilebilir bir eşiğin üzerinde tutulması için yeni bir yöntem önerilmektedir. Algısal Özet

Tabanlı Evrişimsel Sinir Ağı (AÖT-ESA) adı verilen bir hibrit model, ESA ile birlikte algısal bir özet fonksiyonu kullanılarak önerilmiştir. Önerilen yöntem BT imgelerini kullanarak iyi huylu ve kötü huylu kitleler arasındaki ayırıcı tanı için tasarlanmıştır. Algısal özet fonksiyonlarının en önemli özelliği, imgelerin belirgin özelliklerini elde etmektir. Önerilen AÖT-ESA yönteminde, ADD-TDA tabanlı algısal özet fonksiyonları kullanılmıştır. Çalışma kapsamında, Fırat Üniversitesi Hastanesi'nden alınan 41 iyi huylu ve 34 kötü huylu Karaciğer BT imgeleri kullanılmıştır. Bu imgeler, veri artırma teknikleriyle 112 örneğe kadar arttırılmıştır. Deneysel sonuçlar, ESA öznetelikleri ile YSA kullanılarak ortalama % 96.7 oranında başarımla elde edildiğini göstermektedir.

4.3.1. Önerilen Algısal Özet Fonksiyonu

Bu çalışmada, imgenin belirgin özelliklerini elde edebilmek için ADD ve TDA tabanlı yeni bir algısal özet fonksiyonu önerilmiştir. Bu yöntemde, bilineer interpolasyon uygulanarak imge yeniden boyutlandırılır ve ardından renkli imge gri seviyeye dönüştürülür. Gri seviyeye dönüştürülen imgeye 2. seviyede 2 boyutlu ADD uygulanarak LL_2 (Düşük-Düşük 2) bandı elde edilmektedir. LL_2 bandı elde edildikten sonra bu band 2×2 boyutunda örtüşmeyen bloklara ayrılır ve her bir bloğa TDA uygulanır. TDA sonucunda tekil değerler elde edilir. Elde edilen tekil değerler normalize edilerek algısal özet değeri elde edilir. Bu yöntemde 2 seviyede ADD'nin uygulanmasının sebebi, sıkıştırma ataklarına dayanıklılığın sağlanması, TDA'nın uygulanması ise geometrik ataklara karşı dayanıklılığın sağlanmasıdır. Önerilen algısal özet fonksiyonunun blok diyagramı Şekil 4.14'de verilmiştir.



Şekil 4.14 Önerilen algısal özet fonksiyonunun blok diyagramı

Önerilen algısal özet fonksiyonunun adımları aşağıdaki gibidir.

Adım 1: İmge 256 x 256 boyutunda yeniden boyutlandırılır.

Adım 2: Renkli imge, gri seviyeye dönüştürülür.

$$R = im(:, :, 1), G = im(:, :, 2), B = im(:, :, 3) \quad (4.18)$$

Adım 3: 2 boyutlu 2 seviyede ADD uygulanarak LL2 bandı elde edilir.

$$\begin{aligned} [LL \ LH \ HL \ HH] &= dwt2(gri, 'filter') \\ [LL2 \ LH2 \ HL2 \ HH2] &= dwt2(LL, 'filter') \end{aligned} \quad (4.19)$$

Adım 4: LL2 bandı 2 x 2 örtüşmeyen bloklara ayrılır.

Adım 5: Her bir bloğa TDA uygulanarak tekil değerler elde edilir. S1 değeri algısal özet değeri olarak kaydedilir.

$$TDA(LL2_{i:i+1,j:j+1}) = \begin{bmatrix} u_{11} & u_{12} \\ u_{21} & u_{22} \end{bmatrix} \begin{bmatrix} s_1 & 0 \\ 0 & s_2 \end{bmatrix} \begin{bmatrix} v_{11} & v_{12} \\ v_{21} & v_{22} \end{bmatrix} \quad (4.20)$$

$$S_{max} = s_1 \quad (4.21)$$

$$PH_{k,l} = S_{max} \quad (4.22)$$

$$i = \{1, 2, \dots, W\}, j = \{1, 2, \dots, H\}, k = \left\{1, 2, \dots, \frac{W}{2}\right\}, l = \left\{1, 2, \dots, \frac{H}{2}\right\} \quad (4.23)$$

Adım 6: Minimum ve maksimum değerler Pmin ve Pmax elde edilir.

Adım 7: PH matrisi normalize edilerek özet değeri elde edilir.

$$PH = round\left(\frac{PH - P_{min}}{P_{max} - P_{min}} (2^8 - 1)\right) \quad (4.24)$$

Tablo 4.10'da özellik indirgeme adımları verilmiştir.

Tablo 4.10 Özellik indirgeme adımları


Adım	İmge
Yeniden boyutlandır	256 x 256 x 3
Griye çevir	256 x 256
2 ADD	64 x 64
TDA	32 x 32

Bu çalışmada 256 x 256 x 3 boyutundaki bir imgeden 16x16, 32 x 32, 64x64, 128x128 boyutunda algısal özet değerleri elde edilmiştir. Önerilen yöntemle her bir imge için sırasıyla 16x16=2.048, 32x32=8.192, 64x64=32.768, 128x128=131.072 bitlik özet değeri üretilmektedir. Bu özet değerleri, imge için belirgin öznitelikleri temsil etmektedir.

4.3.2. Önerilen Yöntem


Bu çalışmada, ADD-TDA tabanlı algısal özet fonksiyonu kullanılarak imgelerin boyutu indirgenmiştir. Orijinal imgeye, 2. seviyede 2 boyutlu ADD uygulanarak 2 x 2 boyutunda örtüşmeyen bloklara ayrılmıştır. Daha sonra ham imgelerden belirgin özelliklerin çıkarılması için her bir bloğa TDA uygulanmıştır. TDA sonucunda elde edilen tekil değerler normalize edilerek algısal özet değeri elde edilmiştir. Önerilen ADD-TDA algısal özet fonksiyonu, Fırat Üniversitesi hastanesinden alınan 2 sınıfa (iyi huylu, kötü huylu) toplam 112 imgeye uygulanmıştır. ESA mimarisine girdi olarak verilen 16 x 16, 32 x 32, 64 x 64 ve 128 x128 boyutlu imgeler, algısal özet fonksiyonundan çıkan boyutları indirgenmiş imgelerdir. Daha sonra sırasıyla YSA, DVM ve KNN sınıflandırıcılarıyla sınıflandırılmışlardır.

Önerilen AÖT-ESA yönteminde [70], derin öğrenmenin önde gelen mimarilerinden Alexnet mimarisi kullanılmıştır. Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton tarafından geliştirilen mimari, 2012 imge sınıflandırma yarışmasını (ILSVRC) kazanmıştır [72]. Bu tezde öznitelik çıkarımı için Alexnet'in ESA mimarisinde bulunan ve birbirlerini takip eden beş evrişim katmanı ve bu katmanları takip eden 2 tam bağlı katman kullanılmıştır. Daha sonra bu katmanlardan elde edilen ve her bir imgeye ait 4096 öznitelik, YSA, DVM ve KNN sınıflandırıcılarına verilerek sınıflandırılmıştır. Önerilen metot Şekil 4.15'te gösterildiği gibidir.




Şekil 4.15 Önerilen yöntem

Bu çalışmada iyi huylu ve kötü huylu karaciğer BT imgelerinin sınıflandırması yapılmıştır. Çalışmamızda, kötü huylu karaciğer kitleleri sadece hepatoselüler karsinomdan (HCC) oluşmaktadır. Her tümör için BT imgelerinin örnekleri Şekil 4.16'da verilmiştir. Karaciğer hastalıkları veri seti Fırat Üniversitesi Hastanesi Radyoloji Laboratuvarı'ndan elde edilmiştir.



Şekil 4.16 İyi ve kötü huylu karaciğer tümörleri

380x520x3 boyutu ile 663x650x3 boyutları arasında olan karaciğer BT imgeleri ADD-TDA kullanılarak sabit 16x16, 32x32, 64x64 ve 128x128 boyutlarına indirilerek ESA mimarisine verilmiştir. Özet fonksiyonu tabanlı karaciğer BT imgeleri Şekil 4.17’de gösterilmektedir.



Şekil 4.17 Özet fonksiyonundan sonra elde edilen karaciğer imgeleri

4.3.3. Deneysel Sonuçlar

Önerilen AÖT-ESA algoritması, Intel Core i7 - 4510U işlemci, 8 GB RAM ve Windows 10 işletim sistemi olan bir dizüstü bilgisayarda uygulanmıştır. Uygulamanın kodları MatConvnet Kütüphanesi kullanılarak MATLAB R2016a programında yazılmıştır. Önerilen ADD-TDA tabanlı algısal özet fonksiyonu kullanarak, sırasıyla 16x16, 32x32, 64x64 ve 128x128 boyutlarında karaciğer imgeleri elde edilmiştir. Bu imgeler, imgelerin belirgin özelliklerini temsil etmektedir. 2 sınıfa ait toplam 112 BT karaciğer imgesinin % 70'i eğitim, %30'u test için kullanılmıştır. Ortalama bir değer elde etmek için her sınıflandırıcı 5'er defa çalıştırılmış ve ortalama doğruluk, duyarlılık, özgüllük değerleri elde edilmiştir.

Sınıflandırıcı Karşılaştırmaları

YSA, KNN [73] ve DVM [74] sınıflandırıcıları kullanılarak doğruluk oranları karşılaştırıldı. YSA, KNN ve DVM sınıflandırıcılarında en iyi performans deneme yanılma yoluyla elde edildi. Öznitelik çıkarma aşamasında 5 adet evrişimsel katman ve 2 adet tam bağlı katmandan her bir imge için toplam 4096 öznitelik çıkartılarak YSA, DVM ve KNN

sınıflandırıcılarına verilmiştir. Algısal özet fonksiyonu kullanmadan temel ESA sınıflandırması Tablo 4.11’de verilmiştir.

Performans Ölçümleri

Bu çalışmanın geçerliliğinin ölçülmesi; duyarlılık, özgüllük ve doğruluk ile ilişkili olarak TP ile doğru pozitif, TN ile doğru negatif, FP ile yanlış pozitif, FN ile yanlış negatif ifade edilmektedir [75] .

$$\text{Duyarlılık} = \frac{(TP)}{(TP+FN)} \quad (4.25)$$

$$\text{Özgüllük} = \frac{(TN)}{(TN+FP)} \quad (4.26)$$

$$\text{Doğruluk} = \frac{(TP+TN)}{(TP+FN)+(FP+FN)} \quad (4.27)$$

$$\text{Youden indeksi} = \text{Duyarlılık} + \text{Özgüllük}-1 \quad (4.28)$$

- ✓ TP, kötü huylu olarak sınıflandırılan kötü huylu tümörlerin sayısını temsil eder.
- ✓ TN, iyi huylu olarak sınıflandırılan iyi huylu tümörlerin sayısını temsil eder.
- ✓ FP, kötü huylu olarak yanlış sınıflandırılan iyi huylu sayısını temsil eder.
- ✓ FN, iyi huylu olarak yanlış sınıflandırılan kötü huylu tümörlerin sayısını temsil etmektedir.

Tablo 4.11 Algısal özet fonksiyonu kullanmadan temel ESA sınıflandırması

İmge Boyutları	Sınıflandırıcı	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	Youden İndeksi	Çalışma Süresi	Sabit Diskteki Boyut
Ham BT İmgeleri (≈600x60x3)	Softmax	94.8±0.4	94.6±1.5	95±1.3	89.60	18.56 sn.	8.27 MB

Algısal özet fonksiyonu kullanılmadan ham imgelerin sınıflandırmasının sonuçları Tablo 4.11’de verilmiştir. Softmax sınıflandırıcısı, lojistik regresyonun ikili formunu genelleştiren temel ESA sınıflandırıcısıdır. Softmax sınıflandırma katmanının amacı, son çıktı katmanındaki tüm net aktivasyonlarını olasılıksal olarak yorumlanabilecek değerler setine dönüştürmektir.

Tablo 4.12 Karaciğer kitlelerinin sınıflandırılması için 12 modelin deneysel sonuçları

İmge Boyutları	AÖT-ESA Method	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	Youden İndeksi (%)	Çalışma Süresi	Sabit Diskteki Boyut	Küçültme Oranı %
Boyut=16x16 16x16x8 = 2048 bit	YSA	89.99±1.1	91.41±2.8	88.92±4.2	80.33	8.82 sn.	0.046 MB	0.56
	DVM	85.00±3.4	85.00±4.1	85.00±2.6	70.00	7.85 sn.		
	KNN	85.36±2.5	87.50±1.8	83.21±3.2	70.71	8.93 sn.		
Boyut =32x32 32x32x8 = 8192 bit	YSA	96.70±1.6	96.70±2.6	97.50±0.8	94.20	9.08 sn.	0.073 MB	0.88
	DVM	94.10±1.8	92.50±2.08	95.70±2.14	88.20	8.25 sn.		
	KNN	93.03±2.9	91.40±2.8	93.03±3.9	84.43	9.44 sn.		
Boyut =64x64 64x64x8 = 32768 bit	YSA	93.93±2.9	95.00±2.7	91.52±3.6	86.52	9.2 sn.	0.154 MB	1.86
	DVM	91.25±3.4	92.86±2.5	90.18±3.2	83.04	8.92 sn.		
	KNN	92.50±2.7	95.00±0.7	89.73±3.4	84.73	10.03 sn.		
Boyut =128x128 128x128x8 = 131072 bit	YSA	94.82±1.4	96.07±1.3	93.45±1.2	89.52	10.89 sn.	0.403 MB	4.87
	DVM	93.93±1.7	94.29±1.1	94.64±0.9	88.93	9.32 sn.		
	KNN	94.46±1.2	95.00±0.9	93.75±1.8	88.75	9.48 sn.		

Önerilen yöntemin sonuçları Tablo 4.12’de verilmiştir. Ham imgelerle yapılan temel ESA sınıflandırması ile elde edilen sonuçlar Tablo 4.11’de verilmiştir. Tablo 4.12 önerilen AÖT-ESA yönteminin ortalama daha yüksek bir doğruluk sağladığını göstermektedir. Öte yandan, önerilen yöntemin çalışma süresinin temel ESA sınıflandırma yönteminden çok daha hızlı olduğu görülmektedir. BT karaciğer imge boyutlarının 380x520x3 ile 663x650x3 arasında olduğundan dolayı temel ESA sınıflandırma yönteminin daha yüksek bir çalışma süresine sahip olduğu görülmektedir.

Ayrıca önerilen AÖF’nin sıkıştırmanın yanında belirgin özellikleri de tuttuğunu gösterebilmek için karaciğer görüntüleri bilineer interpolasyon ile belirli oranlarda küçülterek ESA mimarisine verilmiştir. Bu görüntülerin öznelilikleri de ESA mimarisi kullanılarak elde edilmiştir. Elde edilen sonuçlar Tablo 4.13’de verilmiştir.


Tablo 4.13 Karaciğer kitlelerinin sınıflandırılması için 12 modelin deneysel sonuçları

Bilineer İnterpolasyon Method	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	Youden İndeksi (%)	Çalışma Süresi (sn)	Sabit Diskteki Boyut	Küçültme Oranı %
YSA	69.3±2.2	67.85±1.8	71.4±1.7	39.2	7.88 sn.	0.075 MB	1
DVM	66.43±4.9	67.85±4.1	64.28±2.6	32.14	8.05 sn.		
KNN	67.85±3.2	71.42±2.8	64.28±1.7	35.71	8.59 sn.		
YSA	72.5±1.95	71.4±1.07	73.2±0.8	44.6	9.55 sn.	0.084 MB	2
DVM	68.75±1.33	71.42±0.9	66.07±1.2	37.5	9.07 sn.		
KNN	69.64±3.85	71.42±2.56	67.85±3.02	39.28	8.69 sn.		
YSA	80±2.92	78.57±2.54	82.14±1.4	60.71	11.53 sn.	0.359 MB	10
DVM	77.67±4.9	73.21±4.5	82.14±3.1	55.35	10.8 sn.		
KNN	76.78±5.2	73.21±4.7	80.35±1.3	53.57	11.47 sn.		
YSA	84.1±5.82	85.71±3.21	83.9±5.63	69.6	12.39 sn.	0.651	20
DVM	83.03±4.68	80.35±6.21	85.71±2.9	66.07	13.19 sn.		
KNN	81.25±3.46	76.78±4.18	85.71±2.53	62.5	13.88 sn.		


Tablo 4.13'te orijinal karaciğer imgelerinin küçültme oranları sırasıyla %1, %2, %10 ve %20 şeklinde verilmiştir. Orijinal imgelerin sıkıştırılması, çalışma süresini düşürürken, sınıflandırma performanslarını da büyük oranda düşürmüştür. Önerilen AÖF-ESA yönteminde küçültme oranı % 4.87 iken sınıflandırma doğruluğu ortalama %93 seviyelerindedir. Fakat bilineer interpolasyon ile imge küçültme oranı %20 olmasına rağmen sınıflandırma doğruluğu ortalama %83 seviyelerinde kaldığı görülmektedir. Diğer taraftan AÖF-ESA yönteminde küçültme oranı %0.56 seviyesinde iken ortalama sınıflandırma başarımları %85 oranındadır. Tablo 4.13, önerilen yöntemin AÖF temel bileşenlerini optimum şekilde kullanarak başarılı bir yöntem olduğunu göstermektedir. Tablo 4.12 ve Tablo 4.13'te verilen sonuçlar bu başarımları doğrulamaktadır.

4.3.4. Sınıflandırma Performansları

Şekil 4.18'deki sınıflandırma sonuçları, en iyi modelin ortalama % 96.7'lik oranında doğruluk elde ettiğini göstermektedir. Ayrıca Tablo 4.12'de bu doğruluk oranının % 96.7'lik oranında duyarlılık ve % 97.5'lik oranında özgüllük elde ettiğini göstermektedir.



Şekil 4.18 Sınıflandırıcıların deneysel sonuçları




Şekil 4.19 ESA mimarisinin ortalama çalışma süreleri

Şekil 4.19'da gösterildiği gibi, YSA sınıflandırıcısı kullanılarak en yüksek doğruluk 32x32x8 = 8192 bitten elde edilmiştir. İleri beslemeli bir YSA kullunılarak ve geri yayılım ile eğitilmiştir. Ayrıca, hesaplama verimliliği nedeniyle Levenberg-Marquardt optimizasyon yöntemi kullanılmıştır [76].


En başarılı sonuca ulaşmak için YSA birkaç kez eğitilmiştir. Sonuç olarak, gizli katman

için nöron sayısı sırasıyla 20, 10, 5, 2 olarak seçilmiştir. Maksimum iterasyon 100 ve hata hedefi 0.01 olarak belirlenmiştir. YSA için öğrenme oranı 0.001'dir. İlk ağırlıklar ve ön ağırlıklar MATLAB 2016a'da YSA tarafından otomatik olarak türetilmiştir. YSA yapısının mimarisi Şekil 4.20'de verilmiştir.




Şekil 4.20 4096 girişe sahip 4 gizli katmanlı 2 çıkış katmanlı çok katmanlı ağ yapısı

32x32 imge boyutuna indirgenmiş en yüksek doğruluğa sahip sınıflandırıcı için karmaşıklık matrisi ve alıcı işlem karakteristiği (AİK) eğrisi örnek analizi, sırasıyla Şekil 4.21 ve Şekil 4.22'de verilmiştir. Kullanılan imgeleri çoğaltabilmek için çevirme, döndürme ve kesme gibi temel imge çoğaltma teknikleri kullanılmıştır. İmgeler genelde dikdörtgen boyutlarında oldukları için döndürme işlemi 180 derece döndürülerek yapılmıştır. Böylece imgelerin orijinal boyutu indirgenmemiştir. Ayrıca imgeyi 180 derece döndürmeye eş değer olduğu için dikey imge çevirme işlemi yapılmıştır. Buna ek olarak, imgelerle orantılı bir miktarda dikey doğrultma ile kesme işlemi uygulanmıştır. Kötü huylu BT karaciğer imgelerinden daha fazla imge çoğaltma işlemi yapılması kötü huylu karaciğer imgelerinin doğruluk oranını arttırmaktadır. Bundan dolayı BT karaciğeri imgelerinden her iki sınıfa ait imge çoğaltma uygulanması, yanlış sınıflandırma hatalarını azaltarak yöntemin doğruluğunu arttırmaktadır.



Şekil 4.21 Karmaşıklık matrisi



Şekil 4.22 AİK eğrisi

4.3.5. Tartışma ve Sonuç

Bu çalışmada, iyi ve kötü huylu tümöre sahip karaciğer imgelerinin sınıflandırması için yeni bir özet fonksiyonu tabanlı derin öğrenme mimarisi sunulmuştur. Önerilen AÖT-ESA

yöntemi, ESA ve algısal özet fonksiyonunu birlikte kullanarak sınıflandırma performansını kabul edilebilir bir seviyenin üzerinde tutarken, imge sınıflandırma süresini azaltmaktadır. Bu yöntem, algısal özet fonksiyonu, evrimsel öznitelikler ve sınıflandırma şeklinde üç adımdan oluşmaktadır. Önerilen AÖT-ESA yönteminde ADD-TDA tabanlı algısal özet fonksiyonu kullanılmıştır. Bu aşama aynı zamanda bir ön işlem aşaması olarak da adlandırılabilir. İkinci aşamada, ESA'nın evrim metodunu kullanarak bir öznitelik seti elde edilmiştir. Elde edilen öznitelikler YSA, DVM ve KNN kullanılarak sınıflandırılmıştır. Önerilen AÖT-ESA yönteminin performansını ölçmek için sınıflandırma doğruluk oranı, duyarlılık, özgüllük, Youden indeksi ve çalışma süresi parametreleri kullanılmıştır. Sınıflandırma performans karşılaştırmaları ve öznitelik çıkarımı için ESA mimarisinin çalışma süresi Şekil 4.18 ve Şekil 4.19'da gösterildiği gibidir. Çalışma süresinin düşük olduğu çalışmada doğruluk, duyarlılık, özgüllük ve youden indeksi en yüksek doğrulukta sonuç vermemiştir. Uygulama süresi en düşük olmamakla birlikte, YSA sınıflandırıcısı kullanılarak algısal özet fonksiyonundan geçirilerek 32x32 boyutuna indirgenmiş karaciğer imgelerinin en yüksek doğruluğa sahip olduğu görülmektedir. Ayrıca, yüksek görüntü boyutunun doğruluk, duyarlılık, özgüllük ve youden indeksi gibi parametreler üzerinde pozitif bir etkiye sahip olmadığı da gözlemlenmiştir. Dolayısıyla, şekillerde verilen karşılaştırma tabloları, uygulanan algısal özet fonksiyonunun imge boyut indirgemesi yaparken belirgin öznitelikleri aldığını ve sınıflandırma performansını arttırdığını göstermektedir.

Bu çalışmada, karaciğer BT görüntülerinin özniteliklerini öğrenip sınıflandıran yeni bir AÖF tabanlı ESA önerilmiştir. Deneysel sonuçlar, algısal özet fonksiyonundan geçirilerek 32x32 boyutuna indirgenmiş karaciğer imgelerinin, ESA mimarisinden geçirildikten sonra çıkan belirgin özniteliklerle ortalama %96.7 sınıflandırma doğruluğuna ve 9.08 saniyelik çalışma süresine ulaştığını göstermektedir. Öte yandan, hiçbir ön işlem yapılmadan ESA mimarisine verilen karaciğer imgelerinde ortalama %94.8 sınıflandırma başarısı ve 18.56 saniyelik çalışma süresi elde edilmiştir. Bu nedenle, önerilen AÖT-ESA yöntemi, diğer gelişmiş derin öğrenme ağlarının çalışma süresi ve sınıflandırma başarısını incelemek için değerli bir temel oluşturabilir.

4.4. İmge Sınıflandırması için Yeni Öznitelik Çıkarım Yöntemi: ADD-TDA Algısal Özet Fonksiyonu Tabanlı Evrişimsel Sinir Ağ


Bu çalışmada, ESA kullanarak, imge sınıflandırma süresini azaltan, sınıflandırma performansını kabul edilebilir değerde tutabilen bir metot önerilmektedir. Ayrık Dalgacık Dönüşümü - Tekil Değer Ayırıştırma'ya dayalı algısal özet fonksiyonu kullanarak Evrişimsel Sinir Ağı (ADD-TDA-ESA) adlı hibrit modelde, sınıflandırma süresini azaltmak için ESA ile birlikte ADD-TDA tabanlı algısal özet fonksiyonu kullanılmıştır. Algısal özet fonksiyonlarının en önemli özelliği imgelerin belirgin özniteliklerini elde etmektir. Bu yöntemde, ilk olarak imgelerin belirgin özniteliklerini elde etmek için ADD-TDA algısal özet fonksiyonu uygulanmıştır. Daha sonra belirgin özniteliklerden oluşan 32x32 boyutundaki imgeler ESA'ya girdi olarak verilerek öznitelikler çıkartılıp Destek Vektör Makinesine sınıflandırma için verilmiştir. ADD-TDA-ESA yöntemi, Caltech-101 veri tabanında bulunan imgeler için uygulanmıştır. Deneysel sonuçlar önerilen ADD-TDA-ESA yönteminin ortalama %94.4 doğruluk oranına sahip olduğunu göstermiştir. Ayrıca kullanılan bu yöntem ile klasik yöntemde 241.21 saniye olan çalışma süresi 83.08 saniyeye düşmüştür. Deney sonuçları ADD-TDA-ESA yönteminin, imge sınıflandırma doğruluğunu yüksek tutarak klasik ESA'ya göre çok daha hızlı performans sergilediğini göstermektedir.

4.4.1. Önerilen ADD-TDA-ESA Yöntemi

Bu çalışmada, ADD-TDA tabanlı algısal özet fonksiyonu kullanılarak imgeler 32x32 boyutuna indirgenmiştir[71]. Orijinal imgeye, 2. seviyede 2 boyutlu ADD uygulanarak 2 x 2 boyutunda örtüşmeyen bloklara ayrılmıştır. Daha sonra ham imgelerden belirgin özniteliklerin çıkarılması için her bir bloğa TDA uygulanmıştır. TDA sonucunda elde edilen tekil değerler normalize edilerek algısal özet değeri elde edilmiştir. Önerilen ADD-TDA algısal özet fonksiyonu, Caltech-101 veri tabanından 7 sınıfa (uçak, araba, araba arka planı, yüzler, gitarlar, evler, motosikletler) toplam 3150 imgeye uygulanmıştır. 3150 imge, algısal özet fonksiyonunun sonucu olarak 32x32 boyutundaki imgelere dönüştürülüp ESA mimarisine girdi olarak verilmiştir. Daha sonra DVM ile sınıflandırılmıştır.


Önerilen ADD-TDA-ESA yönteminde derin öğrenmenin önde gelen mimarilerinden Alexnet mimarisi kullanılmıştır. Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton tarafından geliştirilen mimari, 2012 imge sınıflandırma yarışmasını (ILSVRC) kazanmıştır [72]. Bu makalede öznitelik çıkarımı için Alexnet'in ESA mimarisinde bulunan ve

birbirlerini takip eden beş evrişim katmanı kullanılmıştır. Daha sonra bu katmanlardan elde edilen ve her bir imgeye ait 4096 öznitelik, destek vektör makinesine verilerek sınıflandırılmıştır. Önerilen metot Şekil 4.23'te gösterildiği gibidir.



Şekil 4.23 Önerilen ADD-TDA-ESA yöntemi

Caltech-101 veri setinde 101 farklı kategoride çeşitli imgeler bulunmaktadır. Fei-Fei ve arkadaşları tarafından google imge arama ile toplanan bir arka plan kategorisi vardır [77]. Bu makalede, ADD-TDA-ESA yöntemi; Caltech-101 imge veri tabanında bulunan uçaklar, arabalar, araba arka planları, yüzler, gitarlar, evler ve motosikletlerden oluşan 7 farklı sınıfa uygulanmaktadır. ADD-TDA-ESA yönteminde kullandığımız 7 sınıfın örnek gösterimi Şekil 4.24'de gösterilmiştir.



Şekil 4.24 Çalışmada kullanılan 7 sınıfa ait örnek imgeler

4.4.2. Deneysel Sonuçlar


Önerilen ADD-TDA-ESA yöntemi, Intel Core i7 - 4510U işlemci, 8 GB RAM ve Windows 10 işletim sistemli bir dizüstü bilgisayarda gerçekleştirilmiştir. Uygulamanın kodları MATLAB R2016a'da MatConvnet Kütüphanesi kullanılarak yazılmıştır. Caltech-101 veri tabanına ait imgelerin boyutları 400x600x3 ile 280x186x3 arasında değişmektedir. Her sınıfa ait 450 imge kullanılmıştır. Bu imgelerin %70'i eğitim, %30'u test olarak kullanılmıştır. Algısal özet fonksiyonu kullanılmadan elde edilen başarı oranı %95.2, çalışma süresi ise 241.21 saniyedir.

Her imgenin $32 \times 32 \times 8 = 8192$ bit 'ten oluşan belirgin öznitelikleri ADD-TDA tabanlı algısal özet fonksiyonu kullanılarak elde edilmiştir. Bu özet değer 32×32 boyutlu imgeye dönüştürülerek, %70'i eğitim, %30'u test olarak kullanılmıştır. Bu imgelerin sınıflandırılmasındaki başarı oranı %94.4, çalışma süresi ise 83.08 saniyedir. Ortalama bir değer elde etmek için sınıflandırıcı 5'er defa çalıştırılmış ve ortalama doğruluk değeri elde

edilmiştir. Her iki yöntemin çalışma süreleri Tablo 4.14’te verilmiştir. Klasik yöntem ile önerilen yöntemin karmaşıklık matrisleri Şekil 4.25 ve Şekil 4.26’da verilmiştir.

Tablo 4.14 Çalışma sürelerinin karşılaştırılması

Yöntemler	Sınıflandırma doğruluğu (%)	Çalışma Süreleri	Sabit Diskteki Boyut	Küçültme Oranı
Klasik ESA	95.2±0.9	241.21 sn.	136 MB	71.8 kat
ADD-TDA-ESA	94.4±1.7	83.08 sn.	1.89 MB	



Şekil 4.25 Klasik ESA karmaşıklık matrisi



Şekil 4.26 Önerilen yöntemin karmaşıklık matrisi

4.4.3. Sonuç

Bu çalışmada, imge sınıflandırması için algısal özet fonksiyonu tabanlı yeni bir derin öğrenme mimarisi sunulmuştur. Önerilen ADD-TDA-ESA yöntemi, imge sınıflandırma süresini azaltırken sınıflandırma performansını kabul edilebilir bir seviyede tutmuştur. Bu yöntem, algısal özetleme, evrimsel öznitelik çıkarma ve sınıflandırma olmak üzere 3 adımdan oluşmuştur. ADD-TDA tabanlı algısal özet fonksiyonu, önerilen ADD-TDA-ESA yönteminde kullanılmıştır. Bu aşamaya ön işleme safhası da denilebilir. İkinci aşamada, ESA'nın evrimsel yöntemi kullanılarak bir öznitelik kümesi elde edilmiştir. Elde edilen öznitelikler DVM kullanılarak sınıflandırılmıştır. Sınıflandırmadaki doğruluk oranı ve çalışma süresi parametreleri, önerilen yöntemin performansını ölçmek için kullanılmıştır. Ayrıca, önerilen algısal özet fonksiyonunun güçlü öznitelikleri sayesinde, 32x32 boyutundaki küçük imgeler, Caltech-101 veri tabanındaki boyutları 400x600x3 ile 280x186x3 arasında değişen imgelere kıyasla tatmin edici sınıflandırma sonucu verirken çalışma süresini yaklaşık olarak üçte bir oranında azaltmıştır.

5. SONUÇLAR VE TARTIŞMA

Evrişimsel sinir ağları kullanılarak gerçekleştirilen imge işleme çalışmalarında, en önemli problem, yapılan işlemlerin pikseller mertebesinde olmasından dolayı hesaplama maliyetinin yüksek olmasıdır. Fakat imge veri setinin boyutu çok büyük değilse, kabul edilebilir sınıflandırma performansı için birkaç evrişimsel ağ yeterli olabilmektedir. Derin öğrenme ile ilgili çalışmalarda hesaplama maliyetinin üstesinden gelebilmek için özet öğrenme fonksiyonu temelli yöntemler önerilmiştir. Özet öğrenme temelli yöntemler genellikle öznitelik çıkarma adımından sonra öznitelik indirgenmesi yaparak gerçekleştirilmektedir. Bu tez çalışmasında imge yapısını bozmayan algısal özet fonksiyonları kullanılarak direkt ham imgelerden belirgin öznitelikler elde edilmiştir. Bu nedenle, bu tez çalışması, imge işleme operasyonları için algısal özet fonksiyonu ve derin öğrenmeyi birleştirmektedir.

Algısal özet fonksiyonlarının algısal dayanıklılık, çakışmama yeteneği, tahmin edilemezlik ve sıkıştırma gibi çalışma prensipleri dikkate alınarak ADD-TDA tabanlı algısal özet fonksiyonu geliştirilmiştir. Geliştirilen özet fonksiyonu dayanıklılık, görsel kalite, imge kimlik doğrulama yeteneği, imgeyi yeniden elde etme performans kriterlerine göre değerlendirilmiş ve literatürdeki diğer yöntemlerle karşılaştırılarak başarılı sonuçlar elde edilmiştir.

Evrişimsel Sinir Ağı, işlem katmanları (doğrusal ve doğrusal olmayan) tarafından öğrenilebilen çeşitli algoritmalarından oluşmaktadır. Özniteliklerin oluşumu bu katmanlar arasındadır. ESA, imge tanıma, segmentasyon ve sınıflandırma alanlarında ciddi performansa sahip olduğu için diğer klasik yöntemlere göre üstün performans göstermektedir. Evrişimsel sinir ağları mimarilerinde bulunan giriş, evrişim, düzleştirilmiş doğrusal birim, havuzlama katmanı gibi parametreler incelenmiş ve en uygun mimari olarak 5 evrişim katmanı bulunan bir mimari tercih edilmiştir. ESA mimarilerinin son katmanı olan sınıflandırma katmanında klasik olarak softmax sınıflandırıcısı kullanılmaktadır. Softmax sınıflandırıcısı, lojistik regresyonun ikili formunu genelleştiren temel ESA sınıflandırıcısıdır. Softmax sınıflandırma katmanının amacı, son çıktı katmanındaki tüm net aktivasyonlarını olasılıksal olarak yorumlanabilecek değerler setine dönüştürmektir. Evrişim katmanlarından elde edilen öznitelikler YSA, DVM ve KNN gibi sınıflandırıcılar kullanılarak sınıflandırma işlemi yapılmıştır. Ayrıca AÖT-ESA yönteminin performansını

ölçmek için sınıflandırma doğruluk oranı, duyarlılık, özgüllük, youden indeksi ve çalışma süresi parametreleri kullanılmıştır.

5.1. Tez Çıktılarının Literatüre Katkıları

Bu tez çalışmasının literatüre katkıları aşağıdaki gibi sıralanabilir.

1. Bu tez çalışmasında, imgelerin belirgin özniteliklerini çıkarmak için blok tabanlı algısal özet fonksiyonu önerilmiştir. Önerilen algısal özet fonksiyonu kullanılarak, imgelerin belirgin öznitelikleri elde edilmekte ve sınıflandırma işlemi bu öznitelikler kullanılarak gerçekleştirilmektedir. ADD, jpeg sıkıştırmaya dirençli öznitelikleri seçmek için kullanılırken TDA, döndürme gibi geometrik saldırılara dayanıklı öznitelikleri elde etmek için kullanılmaktadır.
2. Algısal özet fonksiyonları ile ESA yapısı imge tanımda ilk defa kullanılmıştır. Bu yapıda algısal özet fonksiyonları ile ESA katmanları öznitelik çıkarma için kullanılmaktadır. Daha sonra YSA, DVM ve KNN sınıflandırıcıları kullanılmıştır.
3. Karaciğer imgelerinde uygulanan AÖT-ESA yönteminde YSA sınıflandırıcısı kullanılarak algısal özet fonksiyonundan geçirilmiş 32x32 boyutuna indirgenmiş karaciğer imgeleri en yüksek doğruluk oranına ulaşmıştır.
4. Karaciğer imgelerinde, algısal özet fonksiyonu kullanılmadan elde edilen ortalama başarı oranı %94.8, çalışma süresi ise 18.56 saniyedir. Uygulanan AÖT-ESA yönteminde, elde edilen sınıflandırmada ki ortalama başarı oranı %96.7, çalışma süresi 9.08 saniyedir. Bu çalışmada elde edilen başarı oranının daha yüksek olduğu görülmüştür. Öte yandan çalışma süresi ise yaklaşık 9 saniye düşmüştür.
5. Orijinal karaciğer imgelerinin boyut yüksekliği doğruluk, duyarlılık, özgüllük ve youden indeksi gibi parametreler üzerinde pozitif bir etkiye sahip olmadığı gözlemlenmiştir.
6. Caltech-101 veritabanının kullanıldığı çalışmada, algısal özet fonksiyonu kullanılmadan elde edilen ortalama başarı oranı %95.2, çalışma süresi ise 241.21 saniyedir. ADD-TDA tabanlı algısal özet fonksiyonu kullanılarak elde edilen sınıflandırmada ki ortalama başarı oranı %94.4, çalışma süresi 83.08 saniyedir. Bu çalışmada elde edilen başarı oranında çok küçük bir düşüş gözlemlenmişken çalışma süresi yaklaşık 158 saniye düşmüştür.
7. 4. bölümün 4.3 numaralı önerilen yönteminde 16x16 boyutuna indirgenmiş imgelerin sabit diskteki toplam boyutunu 177.5 kat düşürüldüğü görülmektedir. Buna rağmen

ortalama %85 oranında başarımlı elde edilmiştir. İmge boyutunda 177.5 kat düşüş olmasına rağmen doğrulama performansının kabul edilebilir bir eşik değerde olduğu görülmüştür.

8. Önerilen çalışma ile imgelerin sabit diskte kapladığı boyut 20 ile 177.5 kat arasında küçülmesine rağmen doğru tanıma ve yorumlama performansı %85 gibi bir eşik üzerinde tutulmuştur. Çalışma süresini ve sabit diskteki toplam boyutunu azaltan çok boyutlu renkli imgeleri indirgeyerek belirgin öznitelikleri elde etmemizi sağlayan algısal özet fonksiyonu tabanlı evrimsel sinir ağı önerilmiştir.

Bu tez çalışmasında, algısal özet fonksiyonlarının imgelerde boyut küçültmesine rağmen belirgin öznitelikleri çıkartabildiğiyle ilgili yöntem savunulmuştur. Tezde kullanılan algısal özet fonksiyonu ve ESA yöntemi gelişime açık bir alandır. Önerilen bu hibrit yapıyla ilgili ileride birçok çalışmanın yapılması mümkündür. Farklı algısal özet fonksiyonlarının kullanımı, farklı ESA mimarilerinin kullanımı ve farklı sınıflandırıcıların kullanımının çalışma süresi ve sınıflandırma başarımına etkisinin araştırılması birçok çalışmaya ilham kaynağı olacaktır. Algısal özet fonksiyonlarının kullanımıyla imgelerin küçülüp sınıflandırma performanslarının kabul edilebilir seviyede yüksek olması imgelerin bulunduğu büyük veri tabanlarında imgelerin analizini kolaylaştıracaktır.

Yayınlar

Bu tez çalışması kapsamında bir adet Science Citation Indexli (SCI) dergide [70], iki adet yurt dışında sözlü olarak sunulmuş toplam 3 adet uluslararası bildiri çalışması yapılmıştır[57] [69] [71]. Ayrıca bir adet kabul edilmiş fakat 2019 yılında yayınlanacak dergi yayını çalışması yapılmıştır.

KAYNAKLAR

- [1] **Manickam, A., Devarasan, E., Manogaran, G., Priyan, M. K., Varatharajan, R., Hsu, C. H., & Krishnamoorthi, R.** (2018). Score level based latent fingerprint enhancement and matching using SIFT feature. *Multimedia Tools and Applications*, 1–21. <https://doi.org/10.1007/s11042-018-5633-1>
- [2] **Khan, S., Khan, A., Maqsood, M., Aadil, F., & Ghazanfar, M. A.** (2018). Optimized Gabor Feature Extraction for Mass Classification Using Cuckoo Search for Big Data E-Healthcare. *Journal of Grid Computing*. <https://doi.org/10.1007/s10723-018-9459-x>
- [3] **Jaiswal, A. K., & Banka, H.** (2017). Local pattern transformation based feature extraction techniques for classification of epileptic EEG signals. *Biomedical Signal Processing and Control*, 34, 81–92. <https://doi.org/10.1016/j.bspc.2017.01.005>
- [4] **Khan, S., Hussain, M., Aboalsamh, H., & Bebis, G.** (2017). A comparison of different Gabor feature extraction approaches for mass classification in mammography. *Multimedia Tools and Applications*, 76(1), 33–57. <https://doi.org/10.1007/s11042-015-3017-3>
- [5] **Sahoo, S., Kanungo, B., Behera, S., & Sabut, S.** (2017). Multiresolution wavelet transform based feature extraction and ECG classification to detect cardiac abnormalities. *Measurement: Journal of the International Measurement Confederation*, 108, 55–66. <https://doi.org/10.1016/j.measurement.2017.05.022>
- [6] **Rai, H. M., & Chatterjee, K.** (2018). A unique feature extraction using MRDWT for automatic classification of abnormal heartbeat from ECG big data with Multilayered Probabilistic Neural Network classifier. *Applied Soft Computing Journal*. <https://doi.org/10.1016/j.asoc.2018.04.005>
- [7] **Torkul, O., Gülseçen, S., Uyaroğlu, Y., Çağır, G., & Uçar, M. K.** (2017). *Mühendislikte Yapay Zeka ve Uygulamaları* (1. baskı). Sakarya: Sakarya Üniversitesi Kütüphanesi Yayınevi. 10 Kasım 2018 Tarihinde adresinden erişildi https://drive.google.com/file/d/1AIwKgjfS4LhSVCaFTtLxoS_dUB9MfwA/view
- [8] **Talwar, A., & Kumar, Y.** (2013). Machine Learning: An artificial intelligence methodology. *International Journal of Engineering and Computer Science*, 2(12), 3400–3405. <https://doi.org/10.1007/978-3-662-12405-5>
- [9] MathWorks. (2017). *Mastering Machine Learning A Step-by-Step Guide with MATLAB*.
- [10] **Dreiseitl, S., & Ohno-machado, L.** (2003). Logistic regression and artificial neural network classification models : a methodology review, 35(2002), 352–359. [https://doi.org/10.1016/S1532-0464\(03\)00034-0](https://doi.org/10.1016/S1532-0464(03)00034-0)
- [11] **Saxena, A., Prasad, M., Gupta, A., Bharill, N., Patel, O. P., Tiwari, A., Lin, C. T.** (2017). A review of clustering techniques and developments. *Neurocomputing*, 267, 664–681. <https://doi.org/10.1016/j.neucom.2017.06.053>
- [12] **Minhas, F. U. A. A., Sabih, D., & Hussain, M.** (2012). Automated classification of liver disorders using ultrasound images. *Journal of Medical Systems*, 36(5), 3163–3172. <https://doi.org/10.1007/s10916-011-9803-1>
- [13] **Acharya, U. R., Sree, S. V., Ribeiro, R., Krishnamurthi, G., Marinho, R. T., Sanches, J., & Suri, J. S.** (2012). Data mining framework for fatty liver disease classification in ultrasound: A hybrid feature extraction paradigm.

- Medical Physics*, 39(7), 4255–4264. <https://doi.org/10.1118/1.4725759>
- [14] **Virmani, J., Kumar, V., Kalra, N., & Khandelwal, N.** (2013b). SVM-based characterization of liver ultrasound images using wavelet packet texture descriptors. *Journal of Digital Imaging*, 26(3), 530–543. <https://doi.org/10.1007/s10278-012-9537-8>
 - [15] **Virmani, J., Kumar, V., Kalra, N., & Khandelwal, N.** (2013a). Prediction of liver cirrhosis based on multiresolution texture descriptors from B-mode ultrasound. *International Journal of Convergence Computing*, 1(1), 19. <https://doi.org/10.1504/IJCONVC.2013.054658>
 - [16] **Roy, M.** (2014). Classification of Ultrasonography Images of Human Fatty and Normal Livers using GLCM Textural Features, 4(July). <https://doi.org/10.13140/2.1.3752.5122>
 - [17] **Rivas, E. C., Moreno, F., Benitez, A., Morocho, V., Vanegas, P., & Medina, R.** (2015). Hepatic Steatosis detection using the co-occurrence matrix in tomography and ultrasound images. *2015 20th Symposium on Signal Processing, Images and Computer Vision, STSIVA 2015 - Conference Proceedings*. <https://doi.org/10.1109/STSIVA.2015.7330417>
 - [18] **Wu, J. Y., Beland, M., Konrad, J., Tuomi, A., Glidden, D., Grand, D., & Merck, D.** (2015). Quantitative ultrasound texture analysis for clinical decision making support, 9419, 94190W. <https://doi.org/10.1117/12.2081949>
 - [19] **Hwang, Y. N., Lee, J. H., Kim, G. Y., Jiang, Y. Y., & Kim, S. M.** (2015). Classification of focal liver lesions on ultrasound images by extracting hybrid textural features and using an artificial neural network. *Bio-Medical Materials and Engineering*, 26, S1599–S1611. <https://doi.org/10.3233/BME-151459>
 - [20] **Acharya, U. R., Fujita, H., Bhat, S., Raghavendra, U., Gudigar, A., Molinari, F., Hoong Ng, K.** (2016). Decision support system for fatty liver disease using GIST descriptors extracted from ultrasound images. *Information Fusion*, 29, 32–39. <https://doi.org/10.1016/j.inffus.2015.09.006>
 - [21] **Mallat, S.** (2012). {G}roup {I}nvariant {S}cattering. *Communications in Pure and Applied Mathematics*, 65(10), 1331–1398. *What is Machine Learning*.
 - [22] **Bruna, J., & Mallat, S.** (2013). {I}nvariant {S}cattering {C}onvolution {N}etworks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8), 1872–1886. <https://doi.org/10.1109/TPAMI.2012.230>
 - [23] **Zeng, R., Wu, J., Senhadji, L., & Shu, H.** (2015). Tensor Object Classification via Multilinear Discriminant Analysis, 1971–1975.
 - [24] **Li, S. Z., Yu, B., Wu, W., Su, S. Z., & Ji, R. R.** (2015). Feature learning based on SAE-PCA network for human gesture recognition in RGBD images. *Neurocomputing*, 151(P2), 565–573. <https://doi.org/10.1016/j.neucom.2014.06.086>
 - [25] **Chan, T. H., Jia, K., Gao, S., Lu, J., Zeng, Z., & Ma, Y.** (2015). PCANet: A Simple Deep Learning Baseline for Image Classification? *IEEE Transactions on Image Processing*, 24(12), 5017–5032. <https://doi.org/10.1109/TIP.2015.2475625>
 - [26] **Gan, Y., Yang, T., & He, C.** (2014). A deep graph embedding network model for face recognition. *İçinde International Conference on Signal Processing Proceedings, ICSP (C. 2015–Janua, ss. 1268–1271)*. <https://doi.org/10.1109/ICOSP.2014.7015203>
 - [27] **Qin, H., Li, X., Liang, J., Peng, Y., & Zhang, C.** (2016). DeepFish: Accurate

- underwater live fish recognition with a deep architecture. *Neurocomputing*, 187, 49–58. <https://doi.org/10.1016/j.neucom.2015.10.122>
- [28] **Lei, Z., Yi, D., & Li, S. Z.** (2016). Learning Stacked Image Descriptor for Face Recognition. *IEEE Transactions on Circuits and Systems for Video Technology*, 26(9), 1685–1696. <https://doi.org/10.1109/TCSVT.2015.2473415>
- [29] **Zhao, Y., Wang, R., Wang, W., & Gao, W.** (2016). Multilevel Modified Finite Radon Transform Network for Image Upsampling. *IEEE Transactions on Circuits and Systems for Video Technology*, 26(12), 2189–2199. <https://doi.org/10.1109/TCSVT.2015.2504731>
- [30] **Fridrich, J., & Goljan, M.** (2000). Robust Hash Functions for Digital Watermarking Department of Electrical Engineering , SUNY Binghamton , NY 13902-6000.
- [31] **Kozat, S. S., Venkatesan, R., & Mihcak, M. K.** (2004). Robust perceptual image hashing via matrix invariants. *2004 International Conference on Image Processing, 2004. ICIP '04.*, 5, 3443–3446. <https://doi.org/10.1109/ICIP.2004.1421855>
- [32] **Monga, V., & Mihcak, M. K.** (2006). Robust Image Hashing via Non-Negative Matrix Factorizations, 225–228.
- [33] **Qin, C., Chang, C.-C., & Tsou, P.-L.** (2013). Robust image hashing using non-uniform sampling in discrete Fourier domain. *Digital Signal Processing*, 23(2), 578–585. <https://doi.org/10.1016/j.dsp.2012.11.002>
- [34] **Qin, C., Chen, X., Luo, X., Zhang, X., & Sun, X.** (2018). Perceptual image hashing via dual-cross pattern encoding and salient structure detection. *Information Sciences*, 423, 284–302. <https://doi.org/10.1016/j.ins.2017.09.060>
- [35] **Tang, Z., Li, X., Zhang, X., Zhang, S., & Dai, Y.** (2018). Image hashing with color vector angle. *Neurocomputing*, 308, 147–158. <https://doi.org/10.1016/j.neucom.2018.04.057>
- [36] **Qin, C., Sun, M., & Chang, C. C.** (2018). Perceptual hashing for color images based on hybrid extraction of structural features. *Signal Processing*, 142, 194–205. <https://doi.org/10.1016/j.sigpro.2017.07.019>
- [37] **Elman, J. L.** (1990). Finding {S}tructure in {T}ime. *Cognitive science*, 14(2), 179–211.
- [38] **Hochreiter, S., & Schmidhuber, J.** (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1–32.
- [39] Understanding LSTM Networks -- colah's blog. (2016). Tarihinde adresinden erişildi <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- [40] **Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P.** (1998). Gradient Based Learning Applied to Document Recognition. <https://doi.org/10.1136/gutjnl-2011-300779>
- [41] **LeCun, Y., Fu Jie Huang, & Bottou, L.** (2004). Learning methods for generic object recognition with invariance to pose and lighting. *Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2004. CVPR 2004., 2, 97–104. <https://doi.org/10.1109/CVPR.2004.1315150>
- [42] **İnik, Ö., & Ülker, E.** (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85–104. Tarihinde adresinden erişildi <http://dergipark.gov.tr/gbad>

- [43] CS231n Convolutional Neural Networks for Visual Recognition. (2018). Tarihinde 12 Kasım 2018, adresinden erişildi <http://cs231n.github.io/convolutional-networks/>
- [44] **Smolensky, P.** (1986). Information processing in dynamical systems: Foundations of harmony theory. *Parallel Distributed Processing Explorations in the Microstructure of Cognition*, 1(1), 194–281. <https://doi.org/10.1109/TIT.1962.1057683>
- [45] **Hinton, G. E., & Salakhutdinov, R. R.** (2006). Reducing the dimensionality of data with neural networks. *Science*, 313(5786), 504–507. <https://doi.org/10.1126/science.1127647>
- [46] **Salakhutdinov, R., Mnih, A., & Hinton, G.** (2007). Restricted Boltzmann machines for collaborative filtering. *Proceedings of the 24th international conference on Machine learning - ICML '07*, 791–798. <https://doi.org/10.1145/1273496.1273596>
- [47] **Hinton, G. E., & Salakhutdinov, R. R.** (2009). Replicated Softmax: an Undirected Topic Model. *Advances in Neural Information Processing Systems*, 1607–1614. <https://doi.org/10.1007/s40519-017-0429-2>
- [48] **Şeker, A.** (2017). *Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme*. İstanbul.
- [49] **Bengio, Y.** (2009). Learning Deep Architectures for AI. *Foundations and Trends® in Machine Learning*, 2(1), 1–127. <https://doi.org/10.1561/22000000006>
- [50] **Diederik, P. K., & Welling, M.** (2015). Auto-Encoding Variational Bayes, (ML), 1–14. <https://doi.org/10.1051/0004-6361/201527329>
- [51] **Swaminathan Ashwin, Mao Yinian, W. M.** (2015). Robust and Secure Image Hashing, 1(2), 1–70.
- [52] **Hernandez, R. A. P., Miyatake, M. N., & Kurkoski, B. M.** (2011). Robust image hashing using image normalization and SVD decomposition. *Midwest Symposium on Circuits and Systems*, 00, 0–3. <https://doi.org/10.1016/B978-0-12-803581-8.09967-7>
- [53] Google Görseller. (2018). Tarihinde 01 Aralık 2018, adresinden erişildi <https://www.google.com.tr/imghp?hl=tr&authuser=0>
- [54] TinEye Image Recognition. (2018). About - TinEye. Tarihinde 01 Aralık 2018, adresinden erişildi <https://www.tineye.com/about>
- [55] **Kjelsrud, O.** (2014). Using Perceptual Hash Algorithms to Identify Fragmented and Transformed Video Files.
- [56] 36 Mind Blowing YouTube Facts, Figures and Statistics. (2018). Tarihinde 01 Aralık 2018, adresinden erişildi <https://videonitch.com/2017/12/13/36-mind-blowing-youtube-facts-figures-statistics-2017-re-post/>
- [57] **Özyurt, F., Tuncer, T., & Avcı, E.** (2017). *International Advanced Researches & Engineering Congress-2017*. Tarihinde 01 Aralık 2018, adresinden erişildi <http://iarec.osmaniye.edu.tr/Osmaniye/TURKEY>
- [58] SIPI Image Database. (1966). Tarihinde 03 Aralık 2018, adresinden erişildi <http://sipi.usc.edu/database/>
- [59] **Tang, Z. J., Zhang, X. Q., Dai, Y. M., & Lan, W. W.** (2013). Perceptual image hashing using local entropies and DWT. *The Imaging Science Journal*, 61(2), 241–251. <https://doi.org/10.1179/1743131X11Y.0000000039>
- [60] **Choi, Y. S., & Park, J. H.** (2012). Image hash generation method using hierarchical histogram. *Multimedia Tools and Applications*, 61(1), 181–194. <https://doi.org/10.1007/s11042-010-0724-7>

- [61] **Davarzani, R., Mozaffari, S., & Yaghmaie, K.** (2016). Perceptual image hashing using center-symmetric local binary patterns. *Multimedia Tools and Applications*, 75(8), 4639–4667. <https://doi.org/10.1007/s11042-015-2496-6>
- [62] **Qin, C., Chen, X., Ye, D., Wang, J., & Sun, X.** (2016). A novel image hashing scheme with perceptual robustness using block truncation coding. *Information Sciences*, 361–362, 84–90. <https://doi.org/10.1016/j.ins.2016.04.036>
- [63] **Lin, C. C., & Tsai, W. H.** (2004). Secret image sharing with steganography and authentication. *Journal of Systems and software*, 73(3), 405–414.
- [64] **Yang, C. N., Chen, T. S., Yu, K. H., & Wang, C. C.** (2007). Improvements of image sharing with steganography and authentication. *Journal of Systems and Software*, 80(7), 1070–1076. <https://doi.org/10.1016/j.jss.2006.11.022>
- [65] **Chang, C. C., Hsieh, Y. P., & Lin, C. H.** (2008). Sharing secrets in stego images with authentication. *Pattern Recognition*, 41(10), 3130–3137. <https://doi.org/10.1016/j.patcog.2008.04.006>
- [66] **Eslami, Z., Razzaghi, S. H., & Ahmadabadi, J. Z.** (2010). Secret image sharing based on cellular automata and steganography. *Pattern Recognition*, 43(1), 397–404. <https://doi.org/10.1016/j.patcog.2009.06.007>
- [67] **Wu, W. C., & Lin, Z. W.** (2016). SVD-based self-embedding image authentication scheme using quick response code features. *Journal of Visual Communication and Image Representation*, 38, 18–28. <https://doi.org/10.1016/j.jvcir.2016.02.005>
- [68] **Yang, C. N., Ouyang, J. F., & Harn, L.** (2012). Steganography and authentication in image sharing without parity bits. *Optics Communications*, 285(7), 1725–1735. <https://doi.org/10.1016/j.optcom.2011.12.003>
- [69] **Ozyurt, F., Tuncer, T., & Avci, E.** (2018). A novel probabilistic image authentication method based on universal hash function for rgb images. *2018 International Conference on Computing Sciences and Engineering, ICCSE 2018 - Proceedings*, 1–6. <https://doi.org/10.1109/ICCSE1.2018.8373994>
- [70] **Özyurt, F., Tuncer, T., Avci, E., Koç, M., & Serhatlio, I.** (2018). A Novel Liver Image Classification Method Using Perceptual Hash-Based Convolutional Neural Network.
- [71] **Ozyurt, F., Kutlu, H., Avci, E., Avci, D.** (2018). A New Method for Classification of Images Using Convolutional Neural Network Based on Dwt-Svd Perceptual Hash Function. *2018 3rd International Conference on Computer Science and Engineering (UBMK)*, 410–413.
- [72] **Krizhevsky, A., & Hinton, G. E.** (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Neural Information Processing Systems*, 1–9. <https://doi.org/http://dx.doi.org/10.1016/j.protcy.2014.09.007>
- [73] **Bilgin, T. T., & Erdogan, S. Z.** (2012). A data mining approach for fall detection by using k-nearest neighbour algorithm on wireless sensor network data. *IET Communications*, 6(18), 3281–3287. <https://doi.org/10.1049/iet-com.2011.0228>
- [74] **Furey, T. S., Cristianini, N., Duffy, N., Bednarski, D. W., Schummer, M., & Haussler, D.** (2000). Support vector machine classification and validation of cancer tissue samples using microarray expression data. *Bioinformatics*, 16(10), 906–914. <https://doi.org/10.1093/bioinformatics/16.10.906>
- [75] **Zhu, W., Zeng, N., & Wang, N.** (2010). Sensitivity , Specificity , Accuracy ,

Associated Confidence Interval and ROC Analysis with Practical SAS Implementations K & L consulting services , Inc , Fort Washington , PA Octagon Research Solutions , Wayne. *Nesug*, 1–9.

- [76] **Kumar, S., Batish, A., Singh, R., & Singh, T. P.** (2014). A hybrid Taguchi-artificial neural network approach to predict surface roughness during electric discharge machining of titanium alloys. *Journal of Mechanical Science and Technology*, 28(7), 2831–2844. <https://doi.org/10.1007/s12206-014-0637-x>
- [77] **Fei- Fei, L., Fergus, R., & Perona, P.** (2004). Learning Generative Visual Models from Few Training Examples : *Conference on Computer Vision and Pattern Recognition Workshop (CVPR 2004)*, 00(C), 178. <https://doi.org/10.1109/CVPR.2004.109>



Özgeçmiş

Fatih Özyurt	
KİŞİSEL BİLGİLER	
ADRES:	<i>Fırat Üniversitesi, Öğrenci İşleri Daire Başkanlığı– Elazığ</i>
TELEFON:	<i>+90 (5 5 1) 865 09 49</i>
EPOSTA:	<i>fatihozyurt@firat.edu.tr</i>
DOĞUM YERİ/TARİHİ:	<i>02.12.1986 -Erzurum</i>
MEDENİ HALİ:	<i>Evli</i>
EĞİTİM BİLGİLERİ	
LİSANSÜSTÜ	<i>2014, Fatih Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, İstanbul</i>
LİSANS:	<i>2011, Doğu Akdeniz Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği-İngilizce (Tam Burslu), KKTC</i>
İŞ DENEYİMİ	
2014 – 2018	<i>Fırat Üniversitesi / Enformatik Bölümü, Elazığ</i> <i>Akademik Uzman</i>
2018 – Devam	<i>Fırat Üniversitesi / Enformatik Bölümü, Elazığ</i> <i>Öğretim Görevlisi</i>
BİLDİĞİ YABANCI DİLLER	
	<i>İngilizce</i>