

EGE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

(DOKTORA TEZİ)

**GÖRÜNTÜLER ÜZERİNDE ÖZNİTELİK ÇIKARMA
VE SEÇİMİNE ODAKLI BİR ÖRÜNTÜ TANIMA
ÇERÇEVESİ GELİŞTİRİLMESİ**

Arif Erdal TAŞCI

Tez Danışmanı : Prof. Dr. Aybars UĞUR

Bilgisayar Mühendisliği Anabilim Dalı

Sunuş Tarihi : 02.07.2018

Bornova-İZMİR

2018

Arif Erdal TAŞCI tarafından **DOKTORA** tezi olarak sunulan “**Görüntüler Üzerinde Öznitelik Çıkarma ve Seçimine Odaklı Bir Örüntü Tanıma Çerçevesi Geliştirilmesi**” başlıklı bu çalışma EÜ Lisansüstü Eğitim ve Öğretim Yönetmeliği ile EÜ Fen Bilimleri Enstitüsü Eğitim ve Öğretim Yönergesi’nin ilgili hükümleri uyarınca tarafımızdan değerlendirilerek savunmaya değer bulunmuş ve **02.07.2018** tarihinde yapılan tez savunma sınavında aday **oybirliği/oyçokluğu** ile başarılı bulunmuştur.

Jüri Üyeleri:

Jüri Başkanı : Prof. Dr. Aybars UĞUR

Raportör Üye: Prof. Dr. M. Serdar KORUKOĞLU

Üye : Doç. Dr. Doğan AYDIN

Üye : Dr. Öğr. Üyesi Özgür GÜMÜŞ


Üye : Dr. Öğr. Üyesi Korhan KARABULUT

İmza











EGE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ**ETİK KURALLARA UYGUNLUK BEYANI**

EÜ Lisansüstü Eğitim ve Öğretim Yönetmeliğinin ilgili hükümleri uyarınca Doktora Tezi olarak sunduğum “**Görüntüler Üzerinde Öznitelik Çıkarma ve Seçimine Odaklı Bir Örüntü Tanıma Çerçevesi Geliştirilmesi**” başlıklı bu tezin kendi çalışmam olduğunu, sunduğum tüm sonuç, doküman, bilgi ve belgeleri bizzat ve bu tez çalışması kapsamında elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara atıf yaptığımı ve bunları kaynaklar listesinde usulüne uygun olarak verdiğimi, tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını, bu tezin herhangi bir bölümünü bu üniversite veya diğer bir üniversitede başka bir tez çalışması içinde sunmadığımı, bu tezin planlanmasından yazımına kadar bütün safhalarda bilimsel etik kurallarına uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul edeceğimi beyan ederim.

02 / 07 / 2018



İmzası

Arif Erdal TAŞCI

ÖZET**GÖRÜNTÜLER ÜZERİNDE ÖZNİTELİK ÇIKARMA VE SEÇİMİNE
ODAKLI BİR ÖRÜNTÜ TANIMA ÇERÇEVESİ GELİŞTİRİLMESİ**

TAŞCI, Arif Erdal

Doktora Tezi, Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Aybars UĞUR

Temmuz 2018, 138 Sayfa

Günümüzde dijital görüntülerin sayısı, teknolojik imkânların ve aygıtların kullanılması ile birlikte giderek artış göstermektedir. Görüntü türlerinin bilgisayar destekli sınıflandırılması tıp, güvenlik, otomasyon gibi pek çok uygulama alanında yaygın olarak kullanılmaktadır. Öznitelik çıkarma ve seçimi, örüntü tanıma sürecinin alt aşamaları olarak sınıflandırma başarımını artırmak açısından oldukça önem taşımaktadır.

Tez çalışmasında, görüntüler üzerinde öznitelik çıkarma ve seçimi aşamalarının her ikisini de içeren bir örüntü tanıma çerçevesi geliştirilmiştir. Çerçevenin ilk alt modelinde, sadece manuel öznitelik çıkarma yöntemleri kullanılmıştır. Bu modelde, 4 tanesi merkez noktasına göre ikiye ayrılmış görüntülerden türetilen özgün öznitelikler olmak üzere, 194 adet öznitelik çıkarmayı sağlayan geniş bir yöntem kümesi oluşturulması literatüre yapılan katkılardandır. Öznitelik seçimi aşamasında ise genetik algoritmalarından yararlanılmıştır. Literatüre diğer bir katkı olarak geliştirilen ikinci alt modelde ise, derin öğrenme kullanılarak çıkarılan öznitelik kümesi de ilk alt modele eklenerek sistem genişletilmiş ve böylece tanıma performansı artırılmıştır.

Tez kapsamında, manuel olarak 194, derin öğrenmeyle 4096 olmak üzere toplamda 4290 öznitelik çıkarmayı sağlayan bir çatı oluşturulmuş, deneysel çalışmalarda Flavia ve Caltech-101 verisetleri kullanılmıştır. Her iki verisetinde en iyi sınıflandırma başarımının ECOC-SVM modeli ile sağlandığı ve literatürdeki en iyi sonuçlara göre karşılaştırılabilir olduğu gösterilmiştir.

Anahtar sözcükler: Örüntü tanıma, görüntü işleme, öznitelik çıkarma, öznitelik seçimi, makine öğrenmesi, derin öğrenme, veri madenciliği, eniyileme.

ABSTRACT**DEVELOPMENT OF A PATTERN RECOGNITION FRAMEWORK
FOCUSING ON FEATURE EXTRACTION AND SELECTION ON
IMAGES**

TAŞCI, Arif Erdal

PhD in Computer Engineering

Supervisor: Prof. Dr. Aybars UĞUR

July 2018, 138 pages

Nowadays, the number of digital images is increasing gradually with the use of technological possibilities and devices. Computer aided classification of image types is widely applied in many applications such as medicine, security, automation. The feature extraction and selection stages have great importance in terms of increasing the classification performance as the substages of the pattern recognition process.

In the thesis, a pattern recognition framework including both of feature extraction and selection stages on images is developed. In the first submodel of the framework, only manual feature extraction methods are used. In this model, making up a large set of methods for extracting 194 features, 4 of which are novel ones derived from images divided into two sections according to the center point, is one of the contributions to the literature. Genetic algorithms are utilized in the feature selection stage. In the second submodel, which is developed as another contribution to the literature, the system is extended by adding the feature set extracted by using deep learning to the first submodel, thus recognition performance is improved.

In the scope of the thesis, a framework was created for extracting total of 4290 features (194 handcrafted and 4096 deep learning features), Flavia and Caltech-101 datasets were used in the experimental studies. It is shown that the best classification performance for two datasets is provided with the ECOC-SVM model and it is competitive compared to the existing state-of-the-art results in the literature.

Keywords: Pattern recognition, image processing, feature extraction, feature selection, machine learning, deep learning, data mining, optimization.

TEŞEKKÜR

Tez çalışması süresince, her türlü desteği esirgemeyerek, bilimsel bilgi birikimi, yol göstericiliği, deneyimi ve önerileri ile bu çalışmanın tamamlanmasına yardımcı olan, tez danışmanım Prof. Dr. Aybars Uğur’a, doktora çalışmamı 2211 - Yurt İçi Lisanüstü Burs Programı kapsamında destekleyen TÜBİTAK BİDEB’e ve her zaman maddi – manevi desteklerini esirgemeyen aileme en içten teşekkürlerimi sunarım.

İÇİNDEKİLER

Sayfa

ÖZET	vii
ABSTRACT	ix
TEŞEKKÜR.....	xi
ŞEKİLLER DİZİNİ	xix
ÇİZELGELER DİZİNİ	xxiii
KISALTMALAR DİZİNİ	xxviii
1. GİRİŞ.....	1
2. ÖRÜNTÜ TANIMA, SINIFLANDIRICILAR VE DERİN ÖĞRENME	4
2.1 Örüntü Tanıma.....	4
2.1.1 Örüntü	4
2.1.2 Örüntü Tanıma	5
2.1.3 Örüntü tanıma sistemi	6
2.1.4 Örüntü tanıma yaklaşımları	7
2.1.5 Örüntü tanıma uygulamaları.....	11
2.1.6 Örüntü tanıma ile ilişkili alanlar.....	13
2.2 Sınıflandırıcılar	13

İÇİNDEKİLER (devam)

	<u>Sayfa</u>
2.2.1 ECOC-SVM modeli	13
2.2.2 K-NN sınıflandırıcısı	14
2.2.3 Sınıflandırma ağacı.....	15
2.2.4 Olasılıksal sinir ağı	16
2.2.5 Naive bayes sınıflandırıcı	17
2.2.6 Random forest modeli	17
2.2.7 AdaBoost Sınıflandırıcısı	18
2.3 Derin Öğrenme.....	18
2.3.1 Derin öğrenme nedir?	18
2.3.2 Derin öğrenme modelleri.....	19
2.3.3 Evrimsel sinir ağları.....	20
3. ÖZNİTELİK ÇIKARMA VE SEÇİMİ.....	23
3.1 Öznitelik Çıkarma.....	23
3.1.1 Şekil bilgisine dayalı öznitelikler	24
3.1.2 Doku bilgisine dayalı öznitelikler.....	31
3.2 Derin Öğrenme ile Görüntülerden Öznitelik Çıkarma.....	40

İÇİNDEKİLER (devam)

	<u>Sayfa</u>
3.2.1 Alexnet CNN Modeli ile Öznitelik Çıkarımı	40
3.2.2 VGG-16 CNN Modeli ile Öznitelik Çıkarımı	42
3.2.3 VGG-19 CNN ile Öznitelik Çıkarımı	44
3.3 Öznitelik Seçimi	46
3.3.1 Ardışık ileri yönde seçim algoritması	47
3.3.2 Ardışık geri yönde seçim algoritması.....	47
3.3.3 Genetik algoritmalar.....	48
4. ÖNCEKİ ÇALIŞMALAR	53
5. GELİŞTİRİLEN SİSTEM	59
5.1 Giriş	59
5.2 Geliştirilen Çerçevenin Mimarisi	59
5.3 Geliştirilen Örüntü Tanıma Çerçevesi.....	59
5.4 Uygulaması Gerçekleştirilen Alanlar	61
5.4.1 Flavia Veriseti: Yaprak tanıma	61
5.4.2 Caltech-101 Veriseti: Nesne sınıflandırma	67
5.5 Öznitelik Çıkarma Aşaması.....	70

İÇİNDEKİLER (devam)

	<u>Sayfa</u>
5.6 Öznitelik Seçim Aşaması	70
5.7 Özniteliklerin Normalizasyonu	71
5.8 Sınıflandırma Aşaması	72
5.9 Tartışma ve Sonuçlar	72
6. DENEYSEL ÇALIŞMALAR	73
6.1 Deney Ortamı	73
6.2 Başarım Ölçütleri	74
6.3 Parametre Değerleri	75
6.3.1 Öznitelik çıkarmada kullanılan parametre değerleri	75
6.3.2 Öznitelik seçiminde genetik algoritmalar için kullanılan parametre değerleri	76
6.3.3 Sınıflandırıcılarda kullanılan parametre değerleri	76
6.4 Flavia Veriseti için Elde Edilen Sonuçlar	77
6.4.1 Sadece manuel olarak çıkarılan öznitelikler ile elde edilen deneysel sonuçlar	77
6.4.2 Sadece derin öğrenme öznitelikleri ile elde edilen deneysel sonuçlar	78

İÇİNDEKİLER (devam)

Sayfa

6.4.3 Manuel olarak ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar	83
6.4.4 Sadece seçilen manuel özniteliklerin kullanımı ile elde edilen deneysel sonuçlar	89
6.4.5 Seçilen öznitelikler ile derin öğrenme özniteliklerinin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar	90
6.4.6 Özet tablo gösterimi	92
6.4.7 Geliştirilen manuel örüntü tanıma çerçevesi başarımının literatürdeki yöntemlerle karşılaştırılması	93
6.4.8 Geliştirilen manuel ve derin öğrenmeli örüntü tanıma çerçevesi başarımının literatürdeki yöntemlerle karşılaştırılması	95
6.5 Caltech-101 Veriseti için Elde Edilen Sonuçlar	96
6.5.1 Sadece manuel olarak çıkarılan öznitelikler ile elde edilen deneysel sonuçlar	97
6.5.2 Sadece derin öğrenme öznitelikleri ile elde edilen deneysel sonuçlar	97
6.5.3 Manuel olarak ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar	103
6.5.4 Sadece seçilen manuel özniteliklerin kullanımı ile elde edilen deneysel sonuçlar	109

İÇİNDEKİLER (devam)

Sayfa

6.5.5 Seçilen öz niteliklerle derin öğrenme öz niteliklerinin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar	110
6.5.6 Özet tablo gösterimi.....	112
6.5.7 Geliştirilen manuel örüntü tanıma çerçevesi başarımının literatürdeki yöntemlerle karşılaştırılması.....	113
6.5.8 Geliştirilen manuel ve derin öğrenmeli örüntü tanıma çerçevesinin literatürdeki yöntemlerle karşılaştırılması	115
6.6 Geliştirilen Çerçevenin Test Edilmesi	116
7. SONUÇ VE ÖNERİLER.....	117
7.1 Sonuç.....	117
7.2 Öneriler ve Gelecek Çalışmalar	118
KAYNAKLAR DİZİNİ	120

ŞEKİLLER DİZİNİ

<u>Şekil</u>	<u>Sayfa</u>
2.1: İki adet örüntü örneği (a) Dalga, (b) Karakter (Fukunaga, 1990).	5
2.2: Örnek bir örüntü tanıma modeli (Jain et al., 2000).	7
2.3: Şablon eşleme yönteminin gösterimi (a) Girdi görüntüsü, (b) Şablonlar, (c) K harfinin görüntü ile normalize edilmiş çapraz-korelasyonu (d) P harfinin görüntü ile normalize edilmiş çapraz-korelasyonu (e) Şablonların görüntünün üzerine konmuş hali (Kpalma and Ronsin, 2007).	8
2.4: Sözdizimsel tanımlama örneği (Kpalma and Ronsin, 2007).	10
2.5 Örnek PNN yapısı (Specht, 1992).	17
2.6: Farklı yapay zeka sistemlerinin ilişkilerinin karşılaştırılmasını gösteren akış çizelgesi (Goodfellow et al., 2016).....	19
2.7: Derin öğrenme modelinin örneklenmesi (Goodfellow et al., 2016).....	20
2.8: Genel bir CNN mimarisi örneği (Guo et al., 2016).....	21
2.9: CNN modellerinin şematik yapısı (Liu et al., 2017).	22
2.10: CNN modellerinin kavramsal yapısı (Liu et al., 2017).	22
3.1: GLCM örnekleri (a) GLCM matrisinin oluşturulması, (b) Konum ve yön tanımlama (Mathworks Inc., 2017).	36
3.2: Zigzag yönteminin gösterimi (Cornell Univ, 2017)	38
3.3: LBP operatörünün uygulanmasına ilişkin örnek (Nabiyev ve Günay, 2011).39	

ŞEKİLLER DİZİNİ (devam)

<u>Şekil</u>	<u>Sayfa</u>
3.4: AlexNet CNN mimarisinin genel görünümü (Krizhevsky et al., 2012)	41
3.5: VGG-16 CNN mimarisinin şematik gösterimi (Gopalakrishnan et al., 2017).....	44
3.6: VGG-19 CNN mimarisinin yapısı (Simonyan and Zisserman, 2014)	46
3.7: Ardışık ileri yönde seçim algoritması arama uzayı (Gutierrez-Osuna, 2017b)	47
3.8: Ardışık geri yönde seçim algoritması arama uzayı (Gutierrez-Osuna, 2017b)	48
3.9: Genetik algoritmalar ile öznitelik seçimi çözüm kodlama mekanizması	50
3.10: Tek noktalı çaprazlama işlemi	51
3.11: Öznitelik seçiminde mutasyon işlemi örneği	51
5.1: Önerilen örüntü tanıma mimarisi	59
5.2: Geliştirilen örüntü tanıma çerçevesi, alt model-1	60
5.3: Geliştirilen örüntü tanıma çerçevesi, alt model-2	60
5.4: FLAVIA yaprak veri seti için her yaprak türüne ilişkin örnek görüntüler (Wu et al., 2007a; 2007b).....	62
5.5: Görüntü ön işleme aşamaları (a) RGB görüntü, (b) Gri tonlamalı görüntü, (c) Medyan filtreli görüntü, (d) Kırpılmış görüntü (e) Otsu eşiklemeli siyah-beyaz görüntü	65

ŞEKİLLER DİZİNİ (devam)

<u>Şekil</u>	<u>Sayfa</u>
5.6: Yaprak görüntülerini yaprak sapı sol tarafta olacak şekilde doğrultan yazılım modülünün etkisinin ekran görüntüsü	67
5.7: Yarım yaprak görüntüsü önışleme aşamaları (a) Doğrultma, (b) Sol Parça, (c) Sağ Parça.	67
5.8: Caltech-101 verisetinden alınan örnek görüntüler.....	68
5.9: Caltech-101 veriseti görüntü önışleme aşaması (a) Renkli görüntü (b) Yüz kısmı işaretlenen renkli görüntü (c) Siyah-beyaz yüz maskesi (d) Renkli yüz maskesi	69
6.1: Hata Matrisi (Fawcett, 2006).....	74
6.2: Flavia verisetinde seçilen özniteliklerle derin öğrenme özniteliklerinin birlikte kullanımı sonucunda elde edilen doğruluk oranlarını gösteren grafik	91
6.3: Flavia verisetinde farklı türdeki öznitelik kullanımına ilişkin alınan en iyi sonuçları gösteren grafik.....	93
6.4: Flavia verisetinde manuel örüntü tanıma çerçevesi doğruluk oranının literatürdeki diğer çalışmalar ile karşılaştırılmasını gösteren grafik	95
6.5: Flavia verisetinde manuel ve derin öğrenmeli örüntü tanıma çerçevesi doğruluk oranının literatürdeki diğer çalışmalar ile karşılaştırılmasını gösteren grafik	96
6.6: Caltech-101 verisetinde seçilen özniteliklerle derin öğrenme özniteliklerinin birlikte kullanımı sonucunda elde edilen doğruluk oranlarını gösteren grafik....	112

ŞEKİLLER DİZİNİ (devam)

Şekil

Sayfa

6.7: Caltech-101 verisetinde farklı türdeki öznitelik kullanımına ilişkin alınan en iyi sonuçları gösteren grafik.....	113
6.8: Caltech101 verisetinde manuel örüntü tanıma çerçevesi doğruluk oranının literatürdeki diğer çalışmalar ile karşılaştırılmasını gösteren grafik.....	114
6.9: Caltech-101 verisetinde manuel ve derin öğrenmeli örüntü tanıma çerçevesi doğruluk oranının literatürdeki diğer çalışmalar ile karşılaştırılmasını gösteren grafik.....	116

ÇİZELGELER DİZİNİ

<u>Çizelge</u>	<u>Sayfa</u>
2.1: Örüntü tanıma sistemi uygulama alanları ve örnekleri (De Sa, 2001).	12
3.1: AlexNet CNN katmanlarına ilişkin açıklamalar (Mathworks Inc., 2018).....	41
3.2: VGG-16 CNN katmanlarına ilişkin açıklamalar (Mathworks Inc., 2018)	43
3.3: VGG-19 CNN katmanlarına ilişkin açıklamalar (Mathworks Inc., 2018)	45
3.4: Ardışık ileri yönde seçim algoritması (Gutierrez-Osuna, 2017b)	47
5.1: Flavia yaprak görüntü tür bilgilerini ve ilgili görüntü numaralarını gösteren çizelge (Wu et al., 2007b).....	63
5.2: Flavia verisetindeki farklı sınıflara ait görüntü sayıları.....	64
6.1: Deney ortamı	73
6.2: Zernike moment için kullanılan n ve m değerleri (Tahmasbi et al., 2011)	76
6.3: Öznitelik seçiminde GA için kullanılan parametre değerleri	76
6.4: Sınıflandırıcılarda kullanılan parametre değerleri	77
6.5: Flavia verisetinde sadece manuel olarak çıkarılan öznitelikler ile elde edilen deneysel sonuçlar.....	78
6.6: Flavia verisetinde sadece derin öğrenme öznitelikleri ile AlexNet CNN modeli ve FC7 katmanından elde edilen deneysel sonuçlar	79
6.7: Flavia verisetinde sadece derin öğrenme öznitelikleri ile AlexNet CNN modeli ve FC6 katmanından elde edilen deneysel sonuçlar	80

ÇİZELGELER DİZİNİ (devam)

<u>Çizelge</u>	<u>Sayfa</u>
6.8: Flavia verisetinde sadece derin öğrenme öz nitelikleri ile VGG-16 CNN modeli ve FC7 katmanından elde edilen deneysel sonuçlar	81
6.9: Flavia verisetinde sadece derin öğrenme öz nitelikleri ile VGG-16 CNN modeli ve FC6 katmanından elde edilen deneysel sonuçlar	81
6.10: Flavia verisetinde sadece derin öğrenme öz nitelikleri ile VGG-19 CNN modeli ve FC7 katmanından elde edilen deneysel sonuçlar	82
6.11: Flavia verisetinde sadece derin öğrenme öz nitelikleri ile VGG-19 CNN modeli ve FC6 katmanından elde edilen deneysel sonuçlar	83
6.12: Flavia verisetinde manuel olarak ve AlexNet CNN modeli ve FC7 katmanından derin öğrenme ile çıkarılan öz niteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar.....	84
6.13: Flavia verisetinde manuel olarak ve AlexNet CNN modeli ve FC6 katmanından derin öğrenme ile çıkarılan öz niteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar.....	85
6.14: Flavia verisetinde manuel olarak ve VGG-16 CNN modeli ve FC7 katmanından derin öğrenme ile çıkarılan öz niteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar.....	86
6.15: Flavia verisetinde manuel olarak ve VGG-16 CNN modeli ve FC6 katmanından derin öğrenme ile çıkarılan öz niteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar.....	87

ÇİZELGELER DİZİNİ (devam)

<u>Çizelge</u>	<u>Sayfa</u>
6.16: Flavia verisetinde manuel olarak ve VGG-19 CNN modeli ve FC7 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar	88
6.17: Flavia verisetinde manuel olarak ve VGG-19 CNN modeli ve FC6 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar	89
6.18: Flavia verisetinde sadece seçilen manuel öznitelikler kullanıldığında elde edilen deneysel sonuçlar	90
6.19: Flavia verisetinde seçilen öznitelikler ile derin öğrenme özniteliklerinin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar	91
6.20: Flavia verisetinde farklı türdeki öznitelik kullanımına ilişkin alınan en iyi sonuçları gösteren özet tablo	92
6.21: Flavia verisetinde manuel örüntü tanıma çerçevesi başarımının literatürdeki yöntemlerle karşılaştırılması.....	94
6.22: Flavia verisetinde manuel ve derin öğrenmeli örüntü tanıma çerçevesi başarımının literatürle karşılaştırılması	96
6.23: Caltech-101 verisetinde sadece manuel olarak çıkarılan özniteliklerin kullanımı sonucunda elde edilen deneysel sonuçlar	97
6.24: Caltech-101 verisetinde sadece derin öğrenme öznitelikleri ile AlexNet CNN modeli ve FC7 katmanından elde edilen deneysel sonuçlar	98

ÇİZELGELER DİZİNİ (devam)

<u>Çizelge</u>	<u>Sayfa</u>
6.25: Caltech-101 verisetinde sadece derin öğrenme öznitelikleri ile AlexNet CNN modeli ve FC6 katmanından elde edilen deneysel sonuçlar	99
6.26: Caltech-101 verisetinde sadece derin öğrenme öznitelikleri ile VGG-16 CNN modeli ve FC7 katmanından elde edilen deneysel sonuçlar	100
6.27: Caltech-101 verisetinde sadece derin öğrenme öznitelikleri ile VGG-16 CNN modeli ve FC6 katmanından elde edilen deneysel sonuçlar	101
6.28: Caltech-101 verisetinde sadece derin öğrenme öznitelikleri ile VGG-19 CNN modeli ve FC7 katmanından elde edilen deneysel sonuçlar	102
6.29: Caltech-101 verisetinde sadece derin öğrenme öznitelikleri ile VGG-19 CNN modeli ve FC6 katmanından elde edilen deneysel sonuçlar	103
6.30: Caltech-101 verisetinde manuel olarak ve AlexNet CNN modeli ve FC7 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar.....	104
6.31: Caltech-101 verisetinde manuel olarak ve AlexNet CNN modeli ve FC6 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar.....	105
6.32: Caltech-101 verisetinde manuel olarak ve VGG-16 CNN modeli ve FC7 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar.....	106
6.33: Caltech-101 verisetinde manuel olarak ve VGG-16 CNN modeli ve FC6 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar.....	107

ÇİZELGELER DİZİNİ (devam)

<u>Çizelge</u>	<u>Sayfa</u>
6.34: Caltech-101 verisetinde manuel olarak ve VGG-19 CNN modeli ve FC7 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar	108
6.35: Caltech-101 verisetinde manuel olarak ve VGG-19 CNN modeli ve FC6 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar	109
6.36: Caltech-101 verisetinde sadece seçilen manuel öznitelikler kullanıldığında elde edilen deneysel sonuçlar	110
6.37: Caltech-101 verisetinde seçilen özniteliklerle derin öğrenme özniteliklerinin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar	111
6.38: Caltech-101 verisetinde farklı türdeki öznitelik kullanımına ilişkin alınan en iyi sonuçları gösteren özet tablo	112
6.39: Caltech-101 verisetinde manuel örüntü tanıma çerçevesi başarımının literatürle karşılaştırılması	114
6.40: Caltech-101 verisetinde manuel ve derin öğrenmeli örüntü tanıma çerçevesi başarımının literatürle karşılaştırılması	115
6.41: Çerçevenin test edilmesi sonucunda elde edilen doğruluk oranları	116

KISALTMALAR DİZİNİ

<u>Kısaltmalar</u>	<u>Açıklama</u>
ACO	Ant Colony Optimization
ANN	Artificial Neural Networks
AWF	Area Width Factor
CART	Classification and Regression Tree
CNN	Convolutional Neural Network
CT	Classification Tree
CT	Computerized Tomography
DCT	Discrete Cosine Transform
DFT	Discrete Fourier Transform
DT	Decision Tree
ECOC	Error Correcting Output Codes
EKG	Electrocardiogram
FC	Fully Connected
FPR	False Positive Rate
GA	Genetic Algorithms
GLCM	Gray Level Co-occurrence Matrix

KISALTMALAR DİZİNİ (devam)

<u>Kısaltmalar</u>	<u>Açıklama</u>
GP	Genetic Programming
HOG	Histogram of Oriented Gradients
IG	Information Gain
ILSVRC	ImageNet Large-Scale Visual Recognition Challenge
LBP	Local binary pattern
LVQ	Learning Vector Quantization
LWF	Leaf Width Factor
K-NN	K-Nearest Neighbor
FN	False Negative
FP	False Positive
MI	Mutual Information
MLP	Multi Layer Perceptron
MRMR	Minimum Redundancy and Maximum Relevance
MRI	Magnetic Resonance Imaging
NB	Naive Bayes
NP-Hard	Nondeterministic Polynomial-Time Hard

KISALTMALAR DİZİNİ (devam)

<u>Kısaltmalar</u>	<u>Açıklama</u>
OVA	One Versus All
OVO	One Versus One
PNN	Probabilistic Neural Network
PR	Pattern Recognition
PSO	Particle Swarm Optimization
RF	Random Forest
RGB-D	Red Green Blue – Depth
ROI	Region of Interest
RR-HC	Random Restart Hill Climbing
SA	Simulated Annealing
SBS	Sequential Backward Selection
SFFS	Sequential Forward Floating Selection
SFS	Sequential Forward Selection
SOM	Self Organizing Map
SVM	Support Vector Machine
SVM-RFE	Support Vector Machine – Recursive Feature Elimination

KISALTMALAR DİZİNİ (devam)

<u>Kısaltmalar</u>	<u>Açıklama</u>
TDNN	Time Delay Neural Networks
TN	True Negative
TNR	True Negative Rate
TP	True Positive
TPR	True Positive Rate
US	Ultrasonography
VLSI	Very Large Scale Integration

1. GİRİŞ

Günümüzde dijital görüntülerin sayısı giderek artmaktadır. Elde edilen dijital görüntüler ile görüntü işleme tabanlı tanıma ve sınıflandırma sistemleri tıptan, biyometrik güvenlik uygulamalarına, astronomiden jeolojiye, belge ve/veya karakter, yaprak tanımadan, nesne tanıma, hayvan türlerinin sınıflandırılmasına kadar çok çeşitli alanlarda kullanılmaktadır. Erken aşamada hastalıkların belirlenmesi mümkün hale gelmekte, nodül bölgesinin, karakter, yüz, iris, parmakizi, yaprak vb. görüntülerin tanınması sağlanmaktadır (Jain et al., 2000; Mago and Bhatia, 2011; Dutt et al., 2012). Tıp alanında, bilgisayarlı tomografi (BT) (Computerized Tomography) (CT), manyetik rezonans (Magnetic Resonance Imaging) (MRI), ultrasonografi (Ultrasonography) (US) gibi çeşitli tıbbi görüntüler üzerinde bilgisayar destekli tanılama sistemlerinde, nodül tanıma, kanserli bölgenin tanınması, yağlı karaciğer bölgesinin tanınması, hastalık sınıflandırma gibi uygulamalar yer alırken bunların dışında yaprak tanıma, yüz, iris, parmak izi, imza, plaka tanıma, belge, kaya, arazi, galaksi, otomobil, kuş, bitki türlerinin sınıflandırılması, endüstriyel otomasyon gibi uygulama alanları da bulunmaktadır (Jain et al., 2000; Mago and Bhatia, 2011; Dutt et al., 2012; Acharya et al., 2015).

Öznitelik çıkarma ve seçimi örüntü tanıma aşamalarından olup, sınıflandırma işlemleri öncesinde yapılan birtakım yöntemleri içermektedir. Öznitelik çıkarma, görüntüden anlamlı bilgilerin elde edilerek veri boyutunun azaltılması, sınıflandırma başarısının artırılması yönünden yarar sağlarken; öznitelik seçimi ise sınıflandırıcıların eğitim süresinin kısaltılması, başarımının artırılması, öznitelik boyutunun indirgenmesi ve ayırt edici özniteliklerin belirlenmesi bakımından önem taşımaktadır. Bu kapsamda, görüntüler üzerinde öznitelik çıkarma ve seçimine dayalı bir örüntü tanıma çerçevesinin geliştirilmesi, başta bu alanlarda çalışan araştırmacıların, önceden oluşturulmuş öznitelik kümelerini içeren çerçeveye erişimini sağlayarak farklı görüntüler üzerinde uzman bilgisi dahilinde çıkarılan bu öznitelikleri uygulayabilmesine yardımcı olacaktır. Ayrıca, manuel olarak çıkartılan özniteliklerle birlikte derin öğrenme ile elde edilen öznitelikleri içeren çerçeve, hem derin öğrenmenin otomatik öznitelik keşfine katkısını, hem de uzmanlık bilgisi gerektiren özniteliklerin kullanımını farklı görüntü türleri üzerinde kolaylaştıracaktır.

Öznitelik seçim yönteminde de uygulanan yöntemler, görüntü işleme ve örüntü tanıma üzerinde çalışan araştırmacılara yol gösterecek, görüntü tanıma/sınıflandırma sistemlerinin başarımını artıracaktır. Bu ve benzeri birtakım yararları içermesi, çeşitli alanlarda kullanılabilmesi, projenin motivasyonudur ve tez çalışmasının doğmasına neden olmuştur.

Tez kapsamında geliştirilen çerçevenin amacı, görüntüler üzerinde örüntü tanıma uygulamalarında, öznitelik çıkarma ve seçimi aşamalarında kullanılmak üzere çeşitli yöntemleri içinde barındıran bir altyapı sunmaktır. Bunun için şekil ve doku bilgisine dayalı olmak üzere manuel ve özgün oransal öznitelikler çıkartılmıştır. Bu özniteliklere ek olarak, öznitelik seçim yöntemleri uygulanarak sınıflandırma performansını artırmak amaçlanmaktadır.

Tez çalışmasında literatüre yapılan temel katkılardan birincisi, görüntüler üzerinde manuel olarak 194 adet öznitelik çıkarmayı sağlayan yöntemleri içeren bir çerçeve ortaya koymaktır. Bu öznitelik çıkarma yöntemleri, yapılan çalışmaya özgü biçimde seçilerek bir araya getirilmiştir. Öznitelik çeşitliliği, öznitelikler arasındaki ayırteedicilik kriterini sağlayarak sınıflandırma başarımını artırmak için gereklidir ve önemlidir. Bu çerçeve, alan hakkında fazla bilgi sahibi olmadan, bu alanlarda çalışan kişilere yardımcı olacak, yazılım geliştirme süreçlerini kolaylaştıracak ve başarımlar açısından olumlu yönde katkı sağlayacaktır.

Literatüre yapılan ikinci katkı, geliştirilen öznitelik çerçevesinde yer alan merkez noktasına göre ikiye ayrılmış görüntülerden türetilen 4 adet özgün özniteliktir. Bu öznitelikler, öznitelik çerçevesini genişletmek ve özgünlük kazandırmak amacıyla sisteme eklenmiştir.

Tez kapsamında yapılan diğer bir katkı ise, manuel özniteliklere ek olarak derin öğrenme ile elde edilen öznitelikleri de içeren ayrı bir örüntü tanıma çerçevesi hazırlanmasıdır. Bu sayede, hem derin öğrenme mimarisinin hem de uzman bilgisinin yararları birleştirilerek daha kapsamlı bir çerçeve sunulmuştur.

Tez metninin bölümleri şu şekilde özetlenebilir:

Takip eden bölümde, örüntü tanıma ve derin öğrenme hakkında bilgi verilmekte, örüntü, örüntü tanıma kavramları ile örüntü tanıma yaklaşımları açıklanmakta, örüntü tanıma ile ilişkili alanlar belirtilmektedir. Ayrıca, tez çalışmasında ve literatürde kullanılan sınıflandırıcılar bu bölümde anlatılmaktadır.

Tezin üçüncü bölümünde, tez çalışmasında uygulanan öznitelik çıkarma ve seçim yöntemleri ayrıntılı biçimde açıklanmaktadır. Öznitelik çıkarma yöntemleri kapsamında, manuel olarak çıkarılan öznitelikler dışında, derin öğrenme ile elde edilen öznitelikler de bu bölümde anlatılmaktadır.

Dördüncü bölümde, farklı görüntü türleri üzerinde örüntü tanıma alanında çalışan araştırmacıların kullandığı öznitelik çıkarma ve seçim yöntemleri üzerinde durulmaktadır. Tez sürecinde yararlanılan Flavia ve Caltech-101 verisetleri üzerinde, literatürde elde edilmiş başarı oranları da bu bölümde ifade edilmektedir.

Beşinci bölümde, tez kapsamında geliştirilen sistem hakkında bilgi verilmekte, geliştirilen çerçevenin mimarisi ve öznitelik çerçevesi sunulmaktadır. Ayrıca 2 farklı örnek çalışma için uygulanan her bir aşama ayrıntılı olarak açıklanmakta, yapılan adımlardan bahsedilmektedir.

Altıncı bölümde, tez sürecinde kullanılan Flavia ve Caltech-101 verisetleri üzerinde elde edilen deneysel sonuçlar verilmektedir. Bu sonuçlar, sadece manuel öznitelik kümesinin uygulanması ve sadece derin öğrenme özniteliklerinin kullanımının dışında hem manuel hem de derin öğrenme özniteliklerinin birlikte kullanımına ilişkin farklı sınıflandırıcılar üzerinde çeşitli başarımlarına göre elde edilmiş sonuçları da içermektedir. Bunlara ek olarak, öznitelik seçimine ilişkin alınan deneysel sonuçlar da bu bölümde gösterilmektedir.

Tezin son bölümünde ise literatüre yapılan katkılar ile birlikte yapılan çalışmadan çıkarılan sonuçlar yanında, gelecekte bu alanda çalışacak olan araştırmacılara öneriler de sunulmaktadır.

2. ÖRÜNTÜ TANIMA, SINIFLANDIRICILAR VE DERİN ÖĞRENME

Bu bölümde, tez kapsamında geliştirilmiş çerçeveye ilgili olarak örüntü (pattern), örüntü tanıma (pattern recognition) (PR) kavramları açıklanmış, örüntü tanıma yaklaşımları, uygulamaları, örüntü tanıma ile ilişkili alanlar hakkında genel bir bilgi verilmiş, literatürde kullanılan birtakım sınıflandırıcılar özetlenmiş, derin öğrenme kavramları üzerinde durulmuştur.


2.1 Örüntü Tanıma


2.1.1 Örüntü

Tanımlanmış, ismi olabilen bir varlıktır. Örnek olarak parmak izi görüntüsü, el yazısı karakterleri, insan yüzü, ses sinyalleri vb. verilebilir. Örüntü, bir varlığın çok sayıdaki örnekleri arasında ortak payda olarak da tanımlanmakta olup, örüntüler ortak özelliklerine göre farklı gruplara atanır ve örüntü sınıfları oluşturulur (Jain and Duin, 2017).

$$x = (x_1, \dots, x_p)^T \quad (2.1)$$

Örüntü, Eşitlik 2.1'deki gibi x_i değerleri bir nesnenin öznitelik değeri, ^{T} vektör transpozunu olmak üzere, p boyutlu bir nesnenin veri vektörü olarak tanımlanır. Öznitelikler, sınıflandırma işlemi için önemli olan değişkenlerdir (Webb, 2002). Örüntü, tanımak istediğimiz nesnenin tanımlanmasıdır (Friedman and Kandel, 1999). Nesnelerin fiziksel temsildir ve genellikle görüntüler, sinyaller veya tablo halindeki değerler biçiminde olabilmektedir (De Sa, 2001). Karakter ve sinyal örüntüsüne ilişkin örnek Şekil 2.1'de gösterilmiştir.





Şekil 2.1: İki adet örüntü örneği (a) Dalga, (b) Karakter (Fukunaga, 1990).

2.1.2 Örüntü Tanıma

Örüntü tanıma, nesneleri belli sayıda kategoriye sınıflandırma amacına yönelik olan bilimsel bir disiplindir. Uygulamaya bağlı olarak nesneler (örüntüler); görüntüler, sinyaller ya da sınıflandırmaya ihtiyaç duyulan herhangi bir türde ölçüm tipi olabilir (Theodoridis and Koutroumbas, 2009). Bishop'a (2006) göre örüntü tanıma, verilerdeki düzenliliklerin bilgisayar algoritmaları kullanılarak keşfi ve bu düzenliliklerin, verileri farklı kategorilere sınıflandırmak amacıyla kullanılmasıdır. Bir başka tanımla, Jain et al.,'a (2000) göre örüntü tanıma; makinelerin ortamı nasıl gözlemlediği, ilgilenilen örüntüyü arkaplandan ayırmayı nasıl öğrendiği, örüntülerin sınıfları hakkında uygun kararları nasıl verdiği gibi konularla ilgilenen çalışmadır. Örüntü tanıma problemi, farklı türdeki populasyonlar arasında ayırtedicilik problemi olarak adlandırılabilir. (Friedman and Kandel, 1999).

Örüntü tanımada sınıflandırıcılar, örüntülerin ait olduğu kategoriye atanmasını sağlamaktadır. Bunun için, öznitelik uzayı sınıf etiketli karar bölgelerine diskriminant fonksiyonlarıyla bölünmektedir. W adet örüntü sınıfı için w_i i. sınıf etiketi, $g(x)$ diskriminant fonksiyonu olmak üzere, x öznitelik vektörü w_i sınıfına Eşitlik 2.2'deki durumda atanmaktadır (Gutierrez-Osuna, 2017a).

$$g_i(x) > g_j(x) \quad j=1,2,\dots,W; \quad \forall j \neq i \quad (2.2)$$

Fukunaga'ya (1990) göre insanlardaki karar verme süreci örüntü tanıma ile ilişkilidir. Örnek olarak, satranç oyunundaki bir sonraki hamle satranç tahtasının o andaki örüntüsüne, hisse senedinin alınması veya satılması karmaşık bilgi örüntüsüne bağlıdır. Örüntü tanımanın amacı da bu karar verme sürecindeki karmaşık mekanizmayı aydınlığa kavuşturmak ve bilgisayarları kullanarak bu işlevleri otomatikleştirmektir. Örüntü tanıma araştırmaları çoğunlukla karakter tanıma, nesne tanıma, parmak izi tanıma, barkod okuyucu, hastalık tanılama gibi gerçekçi problem türlerine ve bu problem türlerini çözmek için gerekli olan matematiksel yaklaşım ve modellere odaklanmıştır. Örüntü tanıma, çok boyutlu uzayda yoğunluk fonksiyonlarının tahmini ve uzayı kategori veya sınıflara ayırma problemi olarak ele alınabilir (Fukunaga, 1990). De Sa'ya (2001) göre örüntü tanıma, nesnelerin tanınması ve sınıflandırılmasıyla ilgilenen bilimsel bir disiplindir.

Örüntü tanıma, 1960'lı yıllardan beri önemli oranda gelişme gösteren bir çalışma alanıdır. İstatistik, mühendislik, yapay zekâ, bilgisayar bilimi, psikoloji ve fizyoloji alanları gibi çeşitli disiplinlerdeki gelişmeleri kapsamakta, disiplinlerarası oldukça fazla sayıda konu içermektedir (Webb, 2002).


2.1.3 Örüntü tanıma sistemi

Hızlı biçimde gelişen ve kullanıma hazır hesaplama gücüyle, büyük veri setlerinin etkin biçimde işlenmesi sağlanmış, aynı zamanda, büyük veritabanlarının mevcut olması ve sıkı performans gereksinimleri (hız, doğruluk ve maliyet) nedeniyle otomatik örüntü tanıma sistemlerine talep önemli derecede artış göstermiştir (Jain et al., 2000).

Jain et al.'a (2000) göre örüntü tanıma sisteminin tasarımı; verinin elde edilmesi ve ön işlenmesi, verinin temsili ve karar verme olmak üzere 3 aşamayı içermekte olup örüntü tanıma sistemleri genel kapsamda veri setinin elde edilmesi, ön işleme, öznitelik çıkarma, öznitelik seçimi ve sınıflandırma aşamalarından oluşmaktadır. Veri setinin elde edilmesi geliştirilecek tanıma sistemi için kullanılacak görüntüler, sinyaller gibi unsurları kapsamaktadır. Ön işleme aşaması, ilgilenilen örüntünün arkaplandan bölütlenmesi, gürültülerden arındırılması, normalize edilmesi ve örüntünün ileriki aşamalar için uygun forma getirilmesini sağlayan işlemlerden oluşmaktadır (Jain et al., 2000). Öznitelik çıkarma aşaması, bir nesneyi tanımlamak için kullanılan daha düşük boyutlu ayırt edici bilgilerin,

ölçüm değerlerinin, özniteliklerin çıkarılmasını kapsamaktadır. Öznitelik seçimi, verilen d adet öznitelik içinden $m < d$ olacak biçimde m adet ayırt edici özniteliğin seçilmesi işlemidir. Sınıflandırma aşaması ise mevcut nesnelerin tanımlayıcılarına bağlı olarak yeni bir nesneyi önceden belirlenmiş sınıflardan uygun olanına atamayı sağlamaktadır.

İstatistiksel örüntü tanıma modeli eğitim (öğrenme) ve test (sınıflandırma) olmak üzere 2 adımda işletilmektedir. Eğitim modunda; sınıflandırıcı öznitelik uzayını bölümllemek için eğitilmekte, test modunda ise eğitilmiş sınıflandırıcı, verilen girdi örüntüsünü, ölçülen öznitelik değerlerine göre örüntü sınıflarından birine atama işlemini gerçekleştirmektedir (Jain et al., 2000). Örnek bir örüntü tanıma modeli Şekil 2.2’de gösterilmektedir.



Şekil 2.2: Örnek bir örüntü tanıma modeli (Jain et al., 2000).

2.1.4 Örüntü tanıma yaklaşımları


Örüntü tanıma sürecinde şablon eşleme (template matching), istatistiksel yaklaşım, sözdizimsel veya yapısal eşleme (syntactic or structural matching) ile yapay sinir ağları (YSA) (artificial neural networks) (ANN) gibi yaklaşımlar kullanılmaktadır (Jain et al., 2000). Alt bölümlerde örüntü tanımada kullanılan ve en bilinen bu 4 yaklaşım açıklanmaktadır.

Şablon Eşleme

Şablon eşleme, görüntü işlemede şekilleri belirlemek ve yerini bulmak için yaygın olarak kullanılan, örüntü tanımadaki en basit ve eski yaklaşımlardan biridir (Kpalma and Ronsin, 2007; Jain et al., 2000). Eşleşme, aynı türdeki iki varlık (noktalar, eğriler veya şekiller) arasındaki benzerliği belirlemek için kullanılır. Bu yaklaşımda, görüntü içerisinde verilen şablon (model) ile eşleşen parça aranır. Örüntü tanımada, şablon fonksiyonu ile girdi görüntüsünü benzerlik ölçütünün

optimizasyonunu sağlamak amacıyla; çapraz-korelasyonu maksimize etmek veya uzaklığı minimize etmek gibi kriterler uygulanır (Kpalma and Ronsin, 2007; Jain et al., 2000). Eşleme yapılırken şablonun izin verilen tüm taşıma, döndürme ve ölçekleme işlemleri dikkate alınır.

Şablon eşleme yaklaşımı, büyük şablonlar ve çok geniş sayıda görüntüler için oldukça maliyetlidir ve işlem yükü fazladır (Kpalma and Ronsin, 2007). Ayrıca, görüntüleme sürecindeki bozulmalar, bakış açısındaki değişiklikler, örüntülerdeki geniş sınıf içi çeşitliliğin olması gibi etkenler, şablon eşlemenin başarısını olumsuz yönde etkileyebilmektedir (Jain et al., 2000). Deforme olabilir şablon modelleri, deformasyonun kolaylıkla açıklanamadığı veya doğrudan modellenemediği durumlarda örüntüleri eşlemek için kullanılabilir (Grenander, 1994; Jain et al., 2000). Şablon eşleme yaklaşımına ilişkin örnek Şekil 2.3'te gösterilmiştir.



Şekil 2.3: Şablon eşleme yönteminin gösterimi (a) Girdi görüntüsü, (b) Şablonlar, (c) K harfinin görüntü ile normalize edilmiş çapraz-korelasyonu (d) P harfinin görüntü ile normalize edilmiş çapraz-korelasyonu (e) Şablonların görüntünün üzerine konmuş hali (Kpalma and Ronsin, 2007).

İstatistiksel Yaklaşım

İstatistiksel sınıflandırma, olasılık ve istatistik tabanlı bir yaklaşımdır. Bu yaklaşımda, her bir örüntü d boyutlu uzayda d adet öznitelikten (ölçüm değerleri) oluşan bir vektör, çok boyutlu öznitelik uzayında bir nokta olarak temsil edilir. Örüntü tanımada, ele alınması en kolay olduğundan, en sık kullanılan yaklaşımdır.

Jain et al.'a (2000) göre farklı sınıflardaki örüntü vektörlerini kompakt biçimde, farklı bölgelere ayırmak, farklı sınıflara ait örüntüleri ayıran karar sınırlarını, öznitelik uzayında bulmak amaçlanır. Karar sınırları, her sınıfa ait örüntünün olasılık dağılımları ve istatistiksel karar teorisi ile belirlenir.

Örüntü tanımada, eğitici (öğretmenli, danışmanlı) öğrenme (supervised learning), eğitici (öğretmensiz, danışmansız) öğrenme (unsupervised learning), destekleyici (pekiştirmeli) öğrenme (reinforcement learning) ve yarı eğitici öğrenme (semi-supervised learning) olmak üzere birtakım öğrenme yaklaşımları önerilmiştir.

Eğitici öğrenme, girdi kümesi ile girdi kümesine karşılık gelen çıktı kümesi modele verilerek öğrenme işlemi gerçekleştirilir. Ardından, modelin girdi ve çıktılar arasındaki ilişkileri öğrenerek, bilinmeyen girdiler için uygun çıktıları üretmesi beklenir.


Eğitici öğrenme ise yalnızca girdi kümesi verilerek öğrenme gerçekleştirilir. Girdi kümesine karşılık gelen çıktı kümeleri modele verilmez. Küme sayısı sisteme verilebilir. Parametreler arasındaki ilişkileri sistemin kendi kendine öğrenmesi beklenir. Kümeleme amacıyla kullanılmaktadır.

Destekleyici öğrenme, verilen ödül en yüksek düzeye çıkaracak eylemlerle ilgilenir (Sutton and Barto, 2012). Etmen ortamla etkileşime geçerek ve yaptığı eylemlerin sonuçlarını gözlemleyerek öğrenmeyi gerçekleştirir. O anda verilecek kararlar gelecekteki verilebilecek kararları da etkiler. Tavla oyununun yüksek standartta oynanması örnek olarak verilebilir (Bishop, 2006).

Yarı eğitici öğrenme ise az miktarda etiketli ve çok miktarda etiketsiz veriler üzerinden öğrenme işlemi sağlanır. Verileri elde etmek eğitici öğrenmeye göre daha ucuz, kolay ve daha az zaman almaktadır (Zhu, 2008). Ayrıca, eğitici öğrenmeye göre elde edilen başarıyı artırmak amaçlanır.

Sözdizimsel ve Yapısal Eşleme

Matematiksel dilbilim yöntemlerinin örüntü tanımada kullanılmasıdır (Venguerov and Cunningham, 1998). Karmaşık örüntüleri gerektiren tanıma problemlerinde hiyerarşik yaklaşımı benimsemek daha uygundur. Bu yaklaşımda, örüntülerin basit alt örüntülerden, alt örüntülerin ise daha basit alt örüntülerden oluştuğu hiyerarşik düzen kullanılır (Jain et al., 2000). Örüntüler, istatistiksel örüntü tanımada nümerik öznitelik vektörleri arasındaki ilişkilerden daha karmaşık ilişkileri dikkate alan yapılarla temsil edilmektedir. En basit alt örüntüler (primitifler) arasındaki ilişki ile örüntüler belirlenir. Sözdizimsel eşlemede, dilin sözdizimi ile örüntünün yapısı arasındaki benzerlik dikkate alınır. Örüntüler dilde yer alan cümleler (codebook), primitifler ise dilin alfabesi (codeword) olarak temsil edilir. Cümleler de gramer kurallarına göre üretilir (Jain et al., 2000; Kpalma and Ronsin, 2007).



Şekil 2.4: Sözdizimsel tanımlama örneği (Kpalma and Ronsin, 2007).

Şekil 2.4'teki örneğe göre sağ taraftaki şeklin parçaları, solda dilin alfabesinde yer alan karakterlerle tanımlanmıştır. Şekle göre primitiflerin başlangıcından itibaren karakterler birleştirildiğinde, $S = d b a b c b a b d b a b c b a b$ biçiminde şekil temsil edilmektedir.

EKG (Electrocardiogram) (elektrokardiyogram) dalgaları, desenli görüntüler, dış hat şekil analizi gibi örüntülerin belirli bir yapıya sahip olduğu durumlarda bu yaklaşımın kullanılması uygundur. Ancak, gerçekleştirimi, gürültülü örüntülerin bölütlenmesi ve eğitim verilerinden gramerin çıkartılması gibi işlemlerden dolayı zordur (Jain et al., 2000).

Yapay Sinir Ağları

Yapay sinir ağları, paralel bir hesaplama sistemi olup çok sayıda birbirleriyle bağlantılı basit işlemci içerir. Bu ağlar; öğrenme, genelleştirme,

adaptasyon, hata toleransı, dağıtık temsil ve hesaplama yeteneğine sahiptir. Çok katmanlı yapısı sayesinde doğrusal olmayan problemleri çözebilir. Sınıflandırma, kümeleme, regresyon, tahminleme vb. işlemlerde etkili sonuç vermektedir. Karakutu (blackbox) yaklaşımıyla işlemlerini gerçekleştirerek kendi içinde ağırlıklarını ve parametrelerini günceller. Çok katmanlı algılayıcı (multi layer perceptron) (MLP), öğrenen vektör nicemlemesi (learning vector quantization) (LVQ), öz düzenleyici haritalar (self organizing map) (SOM) vb. ağlar örnek olarak verilebilir.

Yapay sinir ağlarının başarımı, ara katman sayısı ve ara katmanlarındaki nöron sayısının problemi temsil edecek oranda artırılmasıyla artış gösterir. Ayrıca kullanılan aktivasyon fonksiyonları da sistemin başarımı açısından önemlidir. Ağın boyutu arttıkça, yapısı karmaşıklaşacaktır ve bu durumda gereken hesaplama maliyeti artacaktır (Asht and Dass, 2012).

2.1.5 Örüntü tanıma uygulamaları

İstatistiksel örüntü tanıma sistemlerinin, akademik ve ticari olmak üzere çeşitli alanlarda uygulama alanı bulunmaktadır ve örüntü tanıma yöntem ve teknikleri yaygın olarak kullanılmaktadır. Bunlar, psikoloji, etnoloji, adli tıp, pazarlama, yapay zekâ, uzaktan algılama, tarım, bilgisayar bilimleri, veri madenciliği, belge sınıflandırma, multimedya, biyometri, gözetim, tıbbi görüntüleme, biyoinformatik ve internet araması gibi alanları içerebilmektedir (Kpalma and Ronsin, 2007). Örüntü tanıma sistemlerinin uygulama alanları ve bu alanlara ilişkin birkaç örnek Çizelge 2.1’de gösterilmektedir.

Çizelge 2.1: Örüntü tanıma sistemi uygulama alanları ve örnekleri (De Sa, 2001).

Alan	Örnek
Tarım	Ürün analizi
	Toprak değerlendirme
Astronomi	Teleskopik görüntülerin analizi
	Otomatik spektroskopi
Biyoloji	Otomatik sitoloji
	Kromozomların özellikleri
	Genetik çalışmalar
Yönetim	Trafik analizi ve kontrolü
	Kentsel büyümenin değerlendirilmesi
Ekonomi	Hisse senedi tahmini
	Girişimci performansının analizi
Mühendislik	Üretilmiş ürünlerde hata tespiti
	Karakter tanıma
	Ses tanıma
	Otomatik navigasyon sistemleri
	Kirlilik analizi
Jeoloji	Kayaların sınıflandırılması
	Madencilik kaynaklarının tahmini
	Jeo-kaynakların uydu görüntüleri kullanılarak analizi
	Sismik analiz
Tıp	Elektrokardiyogram analizi
	Elektroansefalo analizi
	Tıbbi görüntülerin analizi
Askeri	Hava fotoğraflarının analizi
	Radar ve sonar sinyallerinin analizi
	Otomatik hedef tanıma
Güvenlik	Parmak izlerinin tanımlanması
	Gözetim ve alarm sistemleri

2.1.6 Örüntü tanıma ile ilişkili alanlar

Örüntü tanıma çok sayıda alan ile ilişkilidir. Bu alanlardan birkaçı; makine öğrenmesi, veri madenciliği, adaptif sinyal işleme, yapay sinir ağları, keşifsel veri analizi, bulanık ve genetik sistemler, tespit ve tahmin kuramı, robotik ve görü, formal diller, bilişsel bilim, biyolojik sibernetik, yapısal modelleme, matematiksel istatistik, doğrusal olmayan optimizasyon, hesaplamalı nörobilimdir (Dutt et al., 2012).

2.2 Sınıflandırıcılar

Sınıflandırıcı, girdi verilerini sınıf etiketlerine eşleyen matematiksel fonksiyon, öğrenme algoritması olarak tanımlanabilmektedir.

Görüntülerin hangi kategoriye ait olduğunun tanımlanması için seçili bölgelerden çıkarılan öznitelik vektörlerinin sınıflandırılması sağlanmalıdır. Bu kapsamda, her bir örüntü üzerinde farklı sınıflandırıcı modelleri kullanılarak etiketleme işleminin uygulanması gerekmektedir. Literatürde kullanılan bazı sınıflandırıcılar ise ECOC (Error Correcting Output Codes) (Hata Düzeltten Çıktı Kodlaması) – SVM (Support Vector Machine) (Destek Vektör Makinesi), K-NN (K-Nearest Neighbor) (K-En Yakın Komşu) Sınıflandırıcısı, CT (Classification Tree) (Sınıflandırma Ağacı), PNN (Probabilistic Neural Network) (Olasılıksal Sinir Ağları), NB (Naive Bayes) ve RF (Random Forest), AdaBoost gibi modellerden oluşmaktadır.

İzleyen bölümlerde, bu sınıflandırıcılar hakkında genel bilgi verilmektedir.

2.2.1 ECOC-SVM modeli

Görüntüler ikiden fazla sınıf içerdiğinde çok sınıflı sınıflandırma işlemi hata düzelten çıktı kodlaması (ECOC) modelinden yararlanılmaktadır.

ECOC, çok sayıda ikili sınıflandırıcıyı birleştirerek çok sınıflı sınıflandırma problemini çözmeyi sağlayan topluluk yöntemidir. Ayrıca, ikili sınıflandırıcıların genelleştirme yeteneğini iyileştiren genel bir çerçevedir (ali Bagheri et al., 2012; Dietterich and Bakiri'den, 1995).

ECOC çerçevesi, kodlama ve kod çözme aşamalarından oluşmaktadır (Zhong et al., 2017). Kodlama aşamasında verilerden ECOC matrisi tanımlanır,

ikili sınıflandırıcılar ECOC modeline göre eğitilir. Bu aşamada, her bir sınıf için n uzunluklu kod kelimesi (codeword) tasarlanır. Kod kelimesinin her bir pozisyonu verilen ikili problem için sınıf üyeliğini belirler (Escalera et al., 2011). Kod çözme aşamasında ise kod kelimesi ve ikili sınıflandırıcıların çıktıları arasındaki benzerliğe dayalı olarak test örneğine sınıf etiketi atanmaktadır (Zhong et al., 2017). En yaygın kod çözme yöntemlerinden birisi Hamming uzaklığıdır. Bu yöntem, tahmin vektörü ile kod kelimesi arasındaki minimum uzaklığı arar (Ali Bagheri et al., 2012). ECOC matrisinde, $\{-1, 1\}$ değerleri bulunmaktadır. Bu matris, Allwein et al. (2000) tarafından $\{-1, 0, 1\}$ değerlerini içerecek şekilde genişletilmiştir. Sıfır değeri sınıflandırıcının eğitimi aşamasından ilgili sınıfın dikkate alınmadığını göstermektedir. En yaygın kodlama tasarımları bire karşı bir (One Versus One) (OVO), bire karşı hepsi (One Versus All) (OVA), yoğun ve seyrek kodlama stratejileridir.

SVM, örüntü tanıma ve regresyonda kullanılabilen, istatistiksel öğrenme teorisine dayalı eğitimci öğrenme modelidir (Busuttill, 2003). Vapnik tarafından ilk olarak ortaya çıkarılmıştır (Vapnik, 1979). SVM sınıflandırıcısı, girdi veya yüksek boyutlu öznelik uzayında karar sınırlarını belirleyen karar hiperdüzlemi fikrine dayalıdır (Chamasemani and Singh, 2011). SVM öğrenme algoritması, pozitif ve negatif sınıfa ait eğitim örneklerini ayıran en yüksek marjine (her sınıfın en yakın noktası arasındaki uzaklığı maksimize eden) sahip hiperdüzlemi bulmayı amaçlar, buna göre doğrusal fonksiyonları oluşturur. Eğitilen SVM modeli, test örnekleri üzerinde tahminleme yapmak amacıyla kullanılır. Algoritmanın, görülmeyen örnekler için genelleştirme yeteneğinin de iyi olması beklenmektedir. Doğrusal olmayan problemlerde ise veri eğitim kümesinin ayrılabilir olduğu daha yüksek boyutlu öznelik uzayı ile eşlenerek doğrusal sınıflandırıcı ile çözülebilir.

SVM, varsayılan olarak iki sınıflı sınıflandırma problemleri için tasarlanmıştır. ECOC çerçevesi, SVM'in çok sayıda sınıf içeren problemlere uyarlanması için kullanılmıştır.

2.2.2 K-NN sınıflandırıcısı

K-NN sınıflandırıcısı, bilinmeyen bir veriyi; önceden bilinen veriler, belirtilen uzaklık kriteri ve en yakın k komşu sayısına göre sınıflandıran bir

tekniktir. İlk olarak Cover and Hart (1967) tarafından önerilmiştir. Örüntü, nesne ve olay tanıma, makine öğrenmesi, metin sınıflandırma gibi alanlarda uygulanan yüksek düzeyde basit, etkili ve geçerli bir algoritmadır (Bhatia and Mantana, 2010). K-NN, örnek tabanlı ve parametrik olmayan tembel (lazy) öğrenme algoritmaları arasında en temel olanlardan biridir. Kullanımı çeşitlendirmek ve iyileştirmek amacıyla çeşitli en yakın komşu sınıflandırıcı teknikleri geliştirilmiştir. Ağırlıklı K-NN, indirgenmiş K-NN, bulanık K-NN vb (Bhatia and Mantana, 2010; Keller et al., 1985).

K-NN algoritması, sunduğu yapı ile kendi içerisinde birtakım avantajları ve dezavantajları barındırmaktadır. Tembel öğrenme algoritması olması nedeniyle basit ve kolay öğrenebilmesi, gürültülü eğitim verilerine karşı dirençli olması, eğitim verileri geniş olsa bile etkili çalışabilmesi gibi avantajları içermektedir. Buna karşılık, k komşu sayına göre eğilimli olması, örnek ve öznitelik sayısına bağlı olarak hesaplama karmaşıklığının artması, bellek gereksiniminin yüksek olması, tembel öğrenme algoritması olması nedeniyle bilinmeyen veriler üzerinde yavaş çalışması, sınıflarla ilişkisiz öznitelikler kullanıldığında kolaylıkla istenilen sonuçlardan sapabilmesi gibi dezavantajları da bulundurmaktadır (Bhatia and Mantana, 2010).

K-NN algoritmasının başarımında, k parametresi dışında kullanılan uzaklık kriteri ve öznitelikler de etkilidir. Öznitelik seçimi yapılarak sınıflandırıcıya uygun özniteliklerin seçilmesiyle, ilişkisiz özniteliklerin sistemden çıkarılması başarıyı artıracaktır. K-NN için en çok kullanılan k değerlerinden birisi 1'dir. k değeri yükseldikçe işlem yükü ve dikkate alınan örnek sayısı artacaktır. Uzaklık ölçütü olarak ise Manhattan uzaklığı, Öklid uzaklığı, Minkowski uzaklığı gibi kriterler uygulanmaktadır.

2.2.3 Sınıflandırma ağacı

Sınıflandırma ağacı bir tür karar ağacı (Decision Tree) (DT) olup, veri uzayının özyinelemeli olarak bölünmesiyle her bir veri türüne uygun sınıf etiketi atanması sağlanır (Loh, 2011; Ishwaran and Rao, 2018). Sınıflandırma ağacı 3 tür düğüm içermektedir:

Kök düğümü, tüm verileri içeren ağacın en üst düğümüdür. Bölme düğümü, veriyi bir altgruba atayan düğümdür. Terminal düğüm ise son kararı (çıktıyı) temsil etmektedir (Ishwaran and Rao, 2018).

Karar ağaçları, sınıflandırma ve regresyon için kullanılan parametrik olmayan bir eğitici öğrenme yöntemidir (Scikit-learn, 2018). DT, en yaygın olarak kullanılan veri madenciliği ve makine öğrenmesi modellerinden birisidir. Özniteliklerden çıkarılan karar kuralları ile sınıflandırma modeli oluşturulur.


DT, karmaşık karar verme sürecini basit kararların birleşiminden oluşan sürece ayırarak daha ve kolay anlaşılabilir çözümler sunar. DT'nin görselleştirmesi kolaydır. DT'de, karar kuralları çıkarmak için kullanılan yaklaşımlar başarılıdır (Kingsford and Salzberg, 2008). DT, nümerik ve kategorik değerleri işleme konusunda yeterince esnek olup eksik özniteliğe sahip verilerle de çalışabilmektedir (Kingsford and Salzberg, 2008). Bir kez DT oluşturulduğunda yeni verileri kolaylıkla sınıflandırabilmektedir. DT, İkiden fazla sınıf etiketi içeren problemleri desteklemektedir. Fakat verideki küçük değişikliklere karşı hassastır, bu durum oluşturulan ağaçta büyük çaplı değişikliklere sebep olabilmektedir (Kingsford and Salzberg, 2008). Ayrıca, karmaşık ağaçlar oluşabilmekte bu durum modelin genelleştirme yeteneğini düşürmektedir. Bunun için budama, bir yaprak düğümü için gereken en küçük örnek sayısı, ağacın en yüksek derinliğini ayarlamak gibi birtakım işlemler uygulanarak bu problem çözülmeye çalışılmaktadır (Scikit-learn, 2018).

2.2.4 Olasılıksal sinir ağı

Olasılıksal sinir ağı, radyal tabanlı fonksiyonu bulunan, sınıflandırma problemlerinde, örüntü tanımada, doğrusal olmayan eşlemede ve sınıf üyelik olasılıklarının tahminlenmesinde kullanılan bir sinir ağı modelidir (Specht, 1992). Specht (1988) tarafından önerilmiştir. İleribeslemeli bir yapıya sahiptir. PNN, örneklerden tek geçişte hızlı bir biçimde öğrenerek asimptotik olarak Bayes optimal karar sınırlarına ulaşmaktadır (Specht, 1992). En önemli dezavantajı, her bir eğitim örüntüsü için bir düğüm veya nöron gerektirmesidir. Bu durumun önüne geçmek amacıyla çeşitli kümeleme teknikleri önerilmiştir (Specht, 1992).

PNN; girdi, örüntü, toplama ve çıktı katmanlarından oluşmaktadır. Örnek PNN yapısına ilişkin görüntü Şekil 2.5'te gösterilmektedir. Girdi katmanı, girdi vektörünün özniteliklerini temsil eden n adet düğümden meydana gelmektedir. Örüntü katmanı verisetinin kardinalitesi boyutunda nöron içermektedir. Bu nöronlar, radyal tabanlı fonksiyonlar tarafından aktif edilmektedir (Kusy and Zajdel, 2015). Bu nöronlar, toplama katmanının girdisini oluşturmaktadır. Çıktı

katmanı ise tüm toplama katmanı nöronlarının çıktısını dikkate alarak ve Bayes teoremine uygun olarak ilgili vektörün kategorisini belirler (Kusy and Zajdel, 2015).



Şekil 2.5 Örnek PNN yapısı (Specht, 1992).

2.2.5 Naive bayes sınıflandırıcı

Naive Bayes sınıflandırıcı, Bayes teoremini uygulayarak olasılıksal sınıflandırma işlemini gerçekleştirir. Bu modelde, özniteliklerin verilen sınıfta istatistiksel olarak bağımsız olduğu varsayılır. Örüntü tanıma, makine öğrenmesi gibi çok sayıda alanda, kolay öğrenilebilmesi ve yüksek doğruluk oranı ile sınıflandırması nedeniyle kullanılan etkili bir sınıflandırıcıdır. Bu modelde, öznitelikler bağımsız olmadığında sınıflandırma doğruluk oranı düşmektedir. Ayrıca, NB parametrik olmayan sürekli özniteliklerle ilgilenmez (Martinez-Arroyo and Sucar, 2006).

2.2.6 Random forest modeli

Random Forest, çok sayıda sınıflandırma ağacının eğitim kümesi üzerinde yerine koymalı biçimde rastgele sayıda örneklerinin alınmasıyla eğitilen sınıflandırma modellerinden oluşmaktadır. RF, her bir düğümde bölümlmeyi belirlemek için özniteliklerin rastgele seçimini kullanır (Breiman, 2001). Breiman (2001)'e göre, rastgele özniteliklerin seçilmesi sınıflandırma doğruluk oranını artırırken, verinin gürültülere karşı hassasiyetini azaltır ve öznitelikler arasındaki korelasyonu en aza indirger (Fraiman et al., 2012). RF, 2001 yılında Leo Breiman

tarafından geliştirilmiştir (Breiman, 2001). RF sınıflandırıcısı, Bagging topluluk öğrenme algoritmalarına örnek olarak gösterilebilir. Topluluk öğrenme yöntemleri, çok sayıda sınıflandırıcı modellerini birleştirerek, sadece bir sınıflandırıcı kullanımına göre daha güçlü modeller ve yüksek başarımlı sonuçlar elde etmeyi amaçlayan algoritmalarlardır.

RF algoritmasında, test kümesindeki veriler, oluşturulan ağaçların oyları arasında en çok oyu alan sınıfa atanmaktadır. RF, büyük verisetlerinde ve yüksek boyutlu özniteliklerde, Bagging ve Boosting yöntemlerine göre daha etkili çalışabilmekte ve daha iyi sonuçlar verebilmekte, basit ve kolay bir biçimde paralelleştirilebilmekte, aykırı durum ve gürültülere karşı dirençli olabilmektedir (Breiman, 2001).

2.2.7 AdaBoost Sınıflandırıcısı


AdaBoost algoritması, Adaptive boosting'in kısaltılmış hali olup bir topluluk sınıflandırıcısı ve boosting makine öğrenme algoritmasıdır. Hızlı yakınsama ve kolay gerçekleştirme özelliğine sahiptir (Wang, 2012). Boosting algoritmaları, çok sayıda nispeten zayıf ve doğru olmayan kuralları birleştirerek, son derece yüksek doğruluk oranlı bir tahminleme kuralı oluşturmaya dayalı bir makine öğrenmesi yaklaşımı olarak tanımlanmaktadır (Schapire, 2013). AdaBoost ilk olarak Freund ve Schapire tarafından tasarlanmış olup, literatürde çeşitli alanlarda yaygın olarak kullanılmaktadır (Freund and Schapire, 1997). AdaBoost algoritmasında, her bir iterasyonda yanlış sınıflandırılan eğitim seti örneklerinin ağırlıkları artırılarak bu örnekler için modelin öğrenmesi sağlanır. Ayrıca, doğru sınıflandırılan örneklerin ağırlıkları da azaltılır (Wang, 2012).

2.3 Derin Öğrenme

2.3.1 Derin öğrenme nedir?

Derin öğrenme, verinin çok düzeyli temsili ile soyutlamasını öğrenmeye dayanan makine öğrenmesi algoritmalarıdır (Goodfellow et al., 2016). Ayrıca bir temsil öğrenme yöntemidir. Geleneksel makine öğrenmesindeki veri temsili mükemmellik ve alan uzmanlığı gerektirmesinin yerine, derin öğrenme ile hiyerarşik olarak daha soyut özniteliklerin otomatik olarak keşfi sağlanmaktadır (Şekil 2.6).

Derin öğrenme son yıllarda özellikler bilgisayarlı görü ve görüntü sınıflandırma uygulamalarında yaygın olarak kullanılmaktadır ve başarılı sonuçlar vermektedir.




Şekil 2.6: Farklı yapay zeka sistemlerinin ilişkilerinin karşılaştırılmasını gösteren akış çizelgesi (Goodfellow et al., 2016)

2.3.2 Derin öğrenme modelleri

Evrişimsel sinir ağları, tekrarlayan sinir ağları (recurrent neural networks), kısıtlı Boltzman makinesi (restricted Boltzmann machine), otokodlayıcılar (autoencoders) gibi çeşitli derin öğrenme modelleri literatürde kullanılmaktadır.

Derin öğrenme modelinin örneklenmesi Şekil 2.7’de sunulmaktadır. Girdi görüntülerinin piksel değerlerini doğrudan nesne etiketiyle ilişkilendirmek zordur. Bu nedenle, Şekil 2.7’deki gibi piksel değerlerinden nesne etiketlerine, modelin

farklı katmanları tarafından bir dizi hiyerarşik basit eşleme yoluyla işlemler yapılarak ve bu işlemler alt parçalara ayrılarak problem çözülmektedir. İlk olarak komşu pikselleri karşılaştırarak kenarları, ardından kenar topluluklarından dış hatları ve köşeleri, daha sonra belli bir nesne ve parçası ile son olarak nesne sınıfı tespit edilmektedir (Goodfellow et al., 2016).




Şekil 2.7: Derin öğrenme modelinin örnekleme (Goodfellow et al., 2016)

2.3.3 Evrişimsel sinir ağları

Evrişimsel sinir ağları (convolutional neural network) (CNN), görsel sistemin yapısından esinlenerek geliştirilen bir derin sinir ağıdır (Bengio, 2009). İleri beslemeli çok katmanlı yapay sinir ağlarının mimarisel bir uzantısıdır. Bir başka tanımla CNN modelleri, özellikle 2 boyutlu veriler olan görüntüler ve videolar için tasarlanmış çok katmanlı sinir ağları ailesidir (Arel et al., 2010). Görüntü ve ses tanıma uygulamalarında, bilgisayarlı görü alanında, sınıflandırma işlemlerinde yaygın ve etkili biçimde kullanılmaktadır.


CNN kavramının ortaya çıkmasında zaman gecikmeli sinir ağlarından (Time Delay Neural Networks) (TDNN) esinlenilmiştir. TDNN’de zamansal boyutta ağırlıklar paylaşıldığı için hesaplama gereksiniminin indirgenmesine yol açmaktadır (Liu et al., 2017). Benzer biçimde CNN modellerinde de genel matris çarpımı yerine evrişim işlemi uygulanarak ağırlıkların sayısı ve ağın karmaşıklığı azaltılmaktadır (Liu et al., 2017).

CNN modelleri, evrişim, havuzlama ve tam bağlantılı temel katmanlardan oluşmaktadır. Genel bir CNN mimarisinin yapısı Şekil 2.8’de gösterilmektedir. Şekil 2.8’e göre girdi görüntüsü filtreler kullanılarak evrişim katmanında öznitelik haritaları çıkartılmaktadır. Ardından havuzlama katmanında öznitelik boyutu indirgenerek öznitelikler taşıma işlemlerine karşı değişmez hale getirilmekte, öznitelik soyutluluğu artırılmaktadır. Tam bağlantılı katmanlarda hiyerarşik olarak öznitelikler elde edilebilmektedir.




Şekil 2.8: Genel bir CNN mimarisi örneği (Guo et al., 2016)

CNN modellerinin şematik yapısı Şekil 2.9’da ve kavramsal yapısı Şekil 2.10’da gösterilmektedir. Şekil 2.10’da yer alan c katmanı evrişim, s katmanı altörnekleme katmanını temsil etmektedir.



Şekil 2.9: CNN modellerinin şematik yapısı (Liu et al., 2017).



Şekil 2.10: CNN modellerinin kavramsal yapısı (Liu et al., 2017).

CNN'ler, veri ön işleme gereksinimlerini minimize etmek için önerilen modellerden birisidir. Ayrıca, CNN modelleri büyük veri setleri üzerinde hiyerarşik olarak öznelikleri öğrenebilme konusunda etkilidir. CNN modelleriyle elde edilen öznelıklar, manuel olarak çıkartılan öznelıklere göre daha etkili sonuçlar verebilmektedir.

3. ÖZİNİTELİK ÇIKARMA VE SEÇİMİ

Bu bölümde, örüntü tanıma ve makine öğrenmesi alanlarında kullanılan özinitelik çıkarma ve seçimi hakkında bilgi verilmektedir. Özinitelik çıkarma ve seçim aşamalarında uygulanan yöntemler alt bölümlerde ayrıntılı olarak açıklanmaktadır.

3.1 Özinitelik Çıkarma

Özinitelik çıkarma, girdi verisinin boyutunu ve gerekli kaynakların sayısını azaltmak amacıyla uygulanan, örüntü tanıma, görüntü işleme gibi alanlarda sıklıkla kullanılan bir işlemdir. Görüntüler üzerinde anlamlı, öz bilgilerin çıkarılmasını sağlayan işlemleri içermektedir. Özinitelikler; şekil, renk ve doku bilgisine dayalı olarak çıkartılabilmektedir.

Şekil bilgisi, görüntünün içeriğini tanımlayan en temel ve önemli özellikleri içermektedir. **Şekil bilgisine dayalı özinitelikler**, şeklin ayırt edici özelliklerini kullanarak şekli tanımlamak için kullanılır. Bu özinitelikler, sadece dış hat bilgisinin kullanıldığı dış hat tabanlı ve şeklin tüm bölgesinin kullanıldığı bölge tabanlı özinitelikler olmak üzere iki alt gruba ayrılmaktadır (Kunaver and Tasic, 2005; Zhang and Lu, 2004). Fourier tanımlayıcılar dış hat tabanlı özinitelikler, momentler ise bölge tabanlı özinitelikler kapsamında ele alınmaktadır. Şeklin alt parçalara bölünme durumuna göre de dış hat tabanlı ve bölge tabanlı özinitelikler, global (sürekli) ya da yapısal (ayrık) yaklaşımlar ile modellenenebilmektedir (Zhang and Lu, 2004). Global yaklaşımlar için çevre, dışmerkezlilik, dairesellik, Fourier tanımlayıcıları, ölçek uzayı tanımlayıcıları ve dalgacık tanımlayıcıları, yapısal yaklaşımlar için ise B-Spline, zincir kodu örnekleri gibi özinitelikler kullanılmaktadır (Zhang and Lu, 2004).

Renge dayalı özinitelikler de belli bir renk uzayı ya da modeline göre tanımlanmaktadır. Literatürde RGB, LUV, HSV ve HMMD gibi çeşitli renk modelleri bulunmaktadır. Belirtilen renk modeline göre renk histogramı, renk momentleri, renk uyum vektörü, renk korelogramı gibi özinitelikler kullanılmaktadır (Tian, 2013).

Doku analizi kapsamında birinci dereceden, ikinci dereceden veya daha yüksek dereceden istatistiksel bilgiler kullanılarak **dokusal özinitelikler** çıkarılabilmektedir (Theodoridis and Koutroumbas, 2009). Dokusal özinitelikler

kapsamında eş-oluşum matrisleri, enerji filtreleri, Gabor filtresi, dalgacık dönüşümü gibi yaklaşımlar kullanılmaktadır (Ruiz et al., 2004, Haralick et al., 1973).

Alt bölümlerde, şekil ve doku bilgisine dayalı öznitelikler ayrıntılı biçimde anlatılmaktadır.

3.1.1 Şekil bilgisine dayalı öznitelikler

Şekil bilgisine dayalı öznitelikler, ilgilenilen görüntü bölgesini diğer görüntülerden ayırt edebilmek için şekil bilgisini kullanır. Geometrik ya da morfolojik öznitelikler olarak da adlandırılmaktadır. Şekil bilgisine bağlı olarak çıkarılan oransal ve özgün öznitelikler de bu bölümde açıklanmaktadır.

Alan (Area)

Görüntü bölgesinin içindeki toplam piksel sayısı olarak tanımlanır. Skaler bir değerdir. A ile gösterilir (MathWorks Inc., 2017). İlgili bölgesinin büyüklüğünü dikkate alarak, sınıflandırmada eşik değerinin belirlenmesine yardımcı olan bir özniteliktir.

Dışbükey alan (Convex area)

Görüntü bölgesini içeren en küçük boyutlu dışbükey kabuğun alanını temsil eder (MathWorks Inc., 2017). Skaler bir değerdir. Ca ile gösterilir. İlgili bölgesinin büyüklüğünü ve sınırlarını dikkate alarak elde edilen dışbükey kabuğun alanı, sınıflandırmada eşik değerinin belirlenmesine yardımcı olan bir özniteliktir.

Eşdeğer çap (Equivalent diameter)

Görüntü bölgesi ile aynı alana sahip dairenin çapını belirtir (MathWorks Inc., 2017). Skaler bir değerdir. Eqd ile gösterilir. Görüntünün ilgili bölgesinin büyüklüğünü dikkate alarak, sınıflandırmada elde edilen aynı alanlı daire için eşik değerinin belirlenmesine yardımcı olan bir özniteliktir.

Ana (büyük) eksen uzunluğu (Major axis length)

Elipsler için merkezlerinden geçen en uzun kirişin uzunluğu olarak tanımlanmaktadır. Bir başka ifadeyle, ilgilenilen görüntünün bölgesiyle aynı normalize edilmiş ikinci merkezi momente sahip elipsin ana eksen uzunluğunu temsil eder (MathWorks Inc., 2017). Skaler bir değerdir. Mj ile gösterilir. Görüntünün şeklini dikkate alarak, sınıflandırmada eşik değerini belirlemeyi sağlar.

Küçük (ikincil) eksen uzunluğu (Minor axis length)

Elipsler için merkezlerinden, ana eksene dik yönde geçen kısa kirişin uzunluğu olarak tanımlanmaktadır. Bir başka ifadeyle, ilgilenilen görüntü bölgesiyle aynı normalize edilmiş ikinci merkezi momente sahip elipsin küçük eksen uzunluğunu temsil eder (MathWorks Inc., 2017). Skaler bir değerdir. M_n ile gösterilir. Görüntünün şeklini dikkate alarak, sınıflandırmada eşik değerini belirlemeyi sağlar.

Çevre uzunluğu (Perimeter)

İlgi bölgesinin sınırları etrafındaki uzaklığı belirtir (MathWorks Inc., 2017). Skaler bir değerdir. P ile gösterilir.

Dışmerkezlilik (Eccentricity)

İlgi bölgesiyle aynı ikinci momente sahip elipsin dışmerkezliliğini belirten değerdir. Bu değer, elipsde odaklar arasındaki uzaklığın (Foci) ana eksen uzunluk değeri oranına eşittir. (MathWorks Inc., 2017). Skaler bir değerdir. Değeri 0 ile 1 arasında değişmektedir. E_c ile gösterilir. Dışmerkezlilik denklemi Eşitlik 3.1’de ifade edilmektedir.

$$E_c = \frac{Foci}{M_j} \quad (3.1)$$

Biçim katsayısı (Form factor)

İlgi bölgesi ile daire arasındaki farkı tanımlamak için kullanılır (Wu et al., 2007a). F ile gösterilir. Biçim katsayısı denklemi Eşitlik 3.2’de ifade edilmektedir.

$$F = \frac{4\pi A_{ROI}}{P_{ROI}^2} \quad (3.2)$$

A_{ROI} ilgi bölgesinin alanı; P_{ROI} ilgi bölgesinin çevresi olmak üzere.

İkincil eksen uzunluğunun ana eksen uzunluğuna oranı

İlgi bölgesinin kısa eksen uzunluğunun ana eksen uzunluğu oranı olarak ifade edilir. M_{NJ} ile gösterilir. Bu oran, Eşitlik 3.3’te ifade edilmektedir.

$$M_{NJ} = \frac{M_N}{M_J} \quad (3.3)$$

Dışbükey kabuğun çevresinin seçilen bölge çevresine oranı

İlgi bölgesinin dışbükey kabuğunun çevresinin, ilgi bölgesinin çevresine oranını temsil eder (Ulutürk and Uğur, 2012). R_{CHR} ile gösterilir. Bu oran, Eşitlik 3.4’te ifade edilmektedir.

$$R_{CHR} = \frac{P_{CH}}{P_{ROI}} \quad (3.4)$$

P_{CH} ilgi bölgesinin dışbükey kabuğunun çevresi, P_{ROI} ilgi bölgesinin çevresi olmak üzere.

Dikdörtgensellik (Rectangularity)

İlgi bölgesinin dikdörtgene benzeyişini belirten bir değerdir (Yang et al., 2008). Bu oran, ilgi bölgesinin alanının, ilgi bölgesinin ana eksen ve ikincil eksen uzunluklarının çarpımına bölünmesi sonucu elde edilen değere eşittir. R ile gösterilir. Dikdörtgensellik denklemi Eşitlik 3.5'te ifade edilmektedir.

$$R = \frac{A_{ROI}}{Mj * Mn} \quad (3.5)$$

Kapsam (Extent)

İlgi bölgesinin alanının, ilgi bölgesini kuşatan minimum sınırlı dikdörtgensel bölgenin alan değerine oranını belirtir (MathWorks Inc., 2017). Skaler bir değerdir. E ile gösterilir. Kapsam denklemi Eşitlik 3.6'da ifade edilmektedir.

$$E = \frac{A_{ROI}}{A_{MBB}} \quad (3.6)$$

A_{MBB} ilgi bölgesini kuşatan minimum sınırlı dikdörtgensel bölgenin alanı olmak üzere.

Katılık (Solidity)

İlgi bölgesinin dışbükey veya içbükey olma derecesini gösteren bir değerdir (Yang et al., 2008). İlgi bölgesinin alanının, ilgi bölgesini kuşatan dışbükey kabuğun alan değerine bölümüne eşittir. S ile gösterilir. Katılık denklemi Eşitlik 3.7'de ifade edilmektedir.

$$S = \frac{A_{ROI}}{A_{CH}} \quad (3.7)$$

A_{CH} ilgi bölgesini kuşatan dışbükey kabuğun alanı olmak üzere.

Çevre uzunluğunun ana eksen uzunluğuna oranı

İlgi bölgesinin çevre uzunluğunun, ana eksen uzunluğuna oranıdır (Ulutürk and Uğur, 2012). R_{PMJ} ile gösterilir. Bu oran Eşitlik 3.8'de ifade edilmektedir.

$$R_{PMJ} = \frac{P_{ROI}}{Mj} \quad (3.8)$$

Merkez noktasına göre ikiye ayrılmış görüntülerden türetilen öznitelikler

Merkez noktasına göre ikiye ayrılmış görüntülerden çeşitli oransal, geometrik öznitelikler çıkartılmıştır. Bu öznitelikler şu şekilde açıklanabilir:

Alan oranı

Sol parça görüntüsünün alanının sağ parça görüntüsünün alanına oranını belirten değerdir (Ulutürk and Uğur, 2012). R_A ile gösterilir. Bu oran, Eşitlik 3.9'da ifade edilmektedir.

$$R_A = \frac{A_L}{A_R} \quad (3.9)$$

A_L sol parça görüntüsünün alanı, A_R sağ parça görüntüsünün alanı olmak üzere.

Kapsam oranı

Sol parça görüntüsünün kapsamının sağ parça görüntüsünün kapsamına oranını belirten değerdir (Ulutürk and Uğur, 2012). R_E ile gösterilir. Bu oran, Eşitlik 3.10'da ifade edilmektedir.

$$R_E = \frac{E_L}{E_R} \quad (3.10)$$

E_L sol parça görüntüsünün kapsamı, E_R sağ parça görüntüsünün kapsamı olmak üzere.

Katılık oranı

Sol parça görüntüsünün katılığının sağ parça görüntüsünün katılığına oranını belirten değerdir (Ulutürk, 2012). R_S ile gösterilir. Bu oran, Eşitlik 3.11'de ifade edilmektedir.

$$R_S = \frac{S_L}{S_R} \quad (3.11)$$

S_L sol parça görüntüsünün katılığı, S_R sağ parça görüntüsünün katılığı olmak üzere.

Merkez noktasına göre ikiye ayrılmış görüntülerden türetilen özgün öznitelikler

Ana eksen uzunluğu oranı

Sol parça görüntüsünün ana eksen uzunluğunun sağ parça görüntüsünün ana eksen uzunluğuna oranını belirten değerdir. R_{MJ} ile gösterilir. Bu oran, Eşitlik 3.12’de ifade edilmektedir.

$$R_{MJ} = \frac{Mj_L}{Mj_R} \quad (3.12)$$

Mj_L sol parça görüntüsünün ana eksen uzunluğu, Mj_R sağ parça görüntüsünün ana eksen uzunluğu olmak üzere.

Kısa eksen uzunluğu oranı

Sol parça görüntüsünün kısa eksen uzunluğunun sağ parça görüntüsünün kısa eksen uzunluğuna oranını belirten değerdir. R_{MN} ile gösterilir. Bu oran, Eşitlik 3.13’te ifade edilmektedir.

$$R_{MN} = \frac{Mn_L}{Mn_R} \quad (3.13)$$

Mn_L sol parça görüntüsünün kısa eksen uzunluğu, Mn_R sağ parça görüntüsünün kısa eksen uzunluğu olmak üzere.

Çevre oranı

Sol parça görüntüsünün çevresinin sağ parça görüntüsünün çevresine oranını belirten değerdir. R_P ile gösterilir. Bu oran, Eşitlik 3.14’te ifade edilmektedir.

$$R_P = \frac{P_L}{P_R} \quad (3.14)$$

P_L sol parça görüntüsünün ana eksen uzunluğu, P_R sağ parça görüntüsünün ana eksen uzunluğu olmak üzere.

Dışmerkezlilik oranı

Sol parça görüntüsünün dış merkezliliğinin sağ parça görüntüsünün dış merkezliliğine oranını belirten değerdir. R_{EC} ile gösterilir. Bu oran, Eşitlik 3.15’te ifade edilmektedir.

$$R_{EC} = \frac{Ec_L}{Ec_R} \quad (3.15)$$

E_{CL} sol parça görüntüsünün dış merkezliliği, E_{CR} sağ parça görüntüsünün dış merkezliliği olmak üzere.

Hu momentleri

Moment değişmezleri, örüntü tanıma ve sınıflandırma problemlerinde yaygın olarak kullanılmaktadır. Hu momentleri taşıma, döndürme ve ölçekleme işlemlerinden bağımsız olarak elde edilen skaler nicelikler, bölgesel özneliklerdir (Taşcı, 2013). Hu tarafından 1962 yılında 7 farklı moment tanımlanmıştır. Bu momentler arasında 7. Moment çarpıklığa karşı da değişmezdir. Çarpıklığa karşı değişmez olması ayna görüntülerin ayırt edilmesinde yararlıdır (Hu, 1962). Hu momentleri örüntü tanıma problemlerinde sıklıkla kullanılmaktadır. 2 boyutlu sürekli $f(x,y)$ fonksiyonu için $r = p + q$ dereceli geometrik moment Eşitlik 3.16'daki gibi tanımlanmaktadır (Taşcı, 2013; Huang and Leng, 2010; Flusser et al., 2009).

$$M_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^p y^q f(x,y) dx dy$$

$$p, q = 0, 1, 2, \dots \quad (3.16)$$

Eşitlik 3.31 gri tonlamalı görüntüye uyarlandığında, görüntünün momenti elde edilmektedir. Görüntünün momentine ilişkin denklem, Eşitlik 3.17'de gösterilmiştir.

$$M_{ij} = \sum_x \sum_y x^i y^j I(x,y) \quad (3.17)$$

Hu momentlerinden 7 adet öznelik çıkartılabilmektedir. Hu momentlerinin denklemleri Eşitlik 3.18'de gösterilmektedir (Hu, 1962).

$$\phi_1 = \eta_{20} + \eta_{02} \quad (3.18)$$

$$\phi_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2$$

$$\phi_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2$$

$$\phi_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2$$

$$\phi_5 = (\eta_{30} - 3\eta_{12}) + (\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] +$$

$$(\eta_{21} + \eta_{03})(3\eta_{21} - \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]$$

$$\phi_6 = (\eta_{20} - \eta_{02}) + [(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2 + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03})]$$

$$\phi_7 = (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2]$$

$$- (\eta_{30} - 3\eta_{12})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]$$

η_{ij} normalize edilmiş merkezi moment olmak üzere.

Fourier tanımlayıcıları

Fourier tanımlayıcılarında, xy düzleminde şekilde yer alan K adet sınır noktası $((x_0, y_0), (x_1, y_1), (x_2, y_2), (x_{K-1}, y_{K-1}))$ koordinat çiftleri $x(k) = x_k$ ve $y(k) = y_k$ olarak ifade edilebilir. Bu notasyonla sınırlar $k = 0, 1, 2, \dots, K-1$ değerleri için $s(k) = [x(k), y(k)]$ biçiminde temsil edilebilir ve her bir koordinat çifti $k = 0, 1, 2, \dots, K-1$ değerleri için Eşitlik 3.19'daki karmaşık sayı gibi işlem görür (Gonzalez and Woods, 2002). Bu temsil ile 2 boyutlu temsil tek boyuta indirgenmektedir.

$$s(k) = x(k) + jy(k) \quad (3.19)$$

$s(k)$ 'nın ayrık Fourier dönüşümü (Discrete Fourier Transform) (DFT), $u = 0, 1, 2, \dots, K-1$ değerleri için Eşitlik 3.20'deki gibi temsil edilmektedir (Gonzalez and Woods, 2002).

$$a(u) = \frac{1}{K} \sum_{k=0}^{K-1} s(k) e^{-j2\pi uk} \quad (3.20)$$

$a(u)$ 'nın karmaşık katsayıları sınırın Fourier tanımlayıcıları olarak adlandırılmaktadır. Ters Fourier dönüşümünün katsayıları ile $s(k)$ fonksiyonu $k = 0, 1, 2, \dots, K-1$ değerleri için Eşitlik 3.21'deki gibi eski haline getirilebilir (Gonzalez and Woods, 2002).

$$s(k) = \sum_{u=0}^{K-1} a(u) e^{j2\pi uk / K} \quad (3.21)$$

Tüm Fourier katsayıları yerine ilk P katsayı kullanarak da Eşitlik 3.22'deki gibi yaklaşım yapılabilir. Bu durumda, P değeri küçüldükçe sınırlar üzerinde daha fazla ayrıntı kaybı oluşacaktır. Yüksek frekanslı bileşenler ince ayrıntılardan sorumlu iken, düşük frekanslı bileşenler global şekli belirlemek için kullanılmaktadır (Gonzalez and Woods, 2002).

$$\hat{s}(k) = \sum_{u=0}^{P-1} a(u) e^{j2\pi uk / K} \quad (3.22)$$

Fourier tanımlayıcıları doğrudan başlangıç noktası, taşıma, döndürme ve ölçekleme işlemlerinden bağımsız değildir. Bu tür dönüşümlere karşı değişmezlik sağlamak amacıyla tanımlayıcılar üzerinde birtakım basit dönüşüm işlemleri gerçekleştirilmelidir (Gonzalez and Woods, 2002).

Zernike momentleri

Zernike polinomları ilk olarak 1934 yılında Zernike tarafından önerilmiştir. n dereceli ve l tekrarlamalı karmaşık Zernike moment Eşitlik 3.23'teki gibi tanımlanmaktadır (Teh and Chin, 1988). Bu momentler oldukça popüler ve kullanışlı olup, gürültüye dayanıklılık, bilgi fazlalığı ve yeniden yapılandırma kabiliyeti açısından alternatiflerden daha iyi performans sergilemektedir (Shutler'den, 2002; Teh and Chin, 1988).

$$A_{nl} = \frac{n+1}{\pi} \int_0^{2\pi} \int_0^\infty [V_{nl}(r, \theta)]^* \cdot f(r \cos \theta, r \sin \theta) r dr d\theta \quad (3.23)$$

$n=0,1,2,\dots,\infty$ olmak üzere, $*$ sembolü karmaşık eşleniği göstermek üzere, l pozitif veya negatif tamsayı değerlerini Eşitlik 3.24'teki koşula göre almak üzere,

$$n - |l| = \text{çift} \quad \text{ve} \quad |l| \leq n \quad \text{olmak üzere.} \quad (3.24)$$

Zernike polinomları ise Eşitlik 3.25'deki gibidir. Bu polinomlar, $x^2 + y^2 \leq 1$ birim disk üzerinde ortogonal karmaşık değerli fonksiyon kümesidir (Teh and Chin'den, 1988; Born and Wolf, 1975).

$$v_{nl}(x, y) = V_{nl}(r \cos \theta, r \sin \theta) = R_{nl}(r) e^{il\theta} \quad (3.25)$$

$R_{nl}(r)$ ise Eşitlik 3.26'daki gibi tanımlanmak üzere (Teh and Chin, 1988),

$$R_{nl}(r) = \sum_{s=0}^{(n-|l|)/2} (-1)^s \cdot \frac{(n-s)!}{s! \left(n + \frac{|l|}{2} - s\right)! \left(n - \frac{|l|}{2} - s\right)!} r^{n-2s} = \sum_{\substack{k=|l| \\ n-k=\text{çift}}}^n B_{n|l|k} r^k \quad (3.26)$$

3.1.2 Doku bilgisine dayalı öznitelikler

Dokular; parlaklık, renk, boyut gibi özellikleri bulunan, alt örüntülerden oluşan karmaşık görsel örüntüler olarak tanımlanmaktadır ve görüntüdeki benzerliklerin gruplanması olarak kabul edilmektedir (Materka and Strzelecki, 1998; Rosenfeld and Kak'dan, 1982).

Doku analizi kapsamında kullanılan yaklaşımlar **yapısal, istatistiksel, model tabanlı ve dönüşüm yöntemleri** olmak üzere 4 sınıfa ayrılmaktadır (Materka and Strzelecki, 1998). **Yapısal yöntemlerde**, doku iyi tanımlanmış ilkellerle (mikrodoku) ve bu ilkellerin uzaysal düzenlemelerinin hiyerarşisi (makrodoku) ile temsil edilir (Materka and Strzelecki, 1998; Haralick'den, 1979; Levine'den, 1985). Bu yaklaşımda, görüntünün iyi bir sembolik tanımı sağlanmaktadır fakat elde edilen öznitelikler analiz görevlerinden ziyade sentez görevleri için daha kullanışlıdır (Materka and Strzelecki, 1998).

Materka and Strzelecki (1998), **istatistiksel yöntemlerin**, dokunun hiyerarşik yapısını açıkça anlamaya çalışmadığını, bunun yerine dokuyu; görüntünün gri düzeyleri arasındaki ilişkileri ve dağılımları yöneten deterministik olmayan özellikleri tarafından dolaylı olarak temsil ettiğini söylemektedir. Srinivasan and Shobha (2008)'e göre, yerel özniteliği tanımlayan piksel sayısına bağımlı olarak, istatistiksel yöntemler kendi içlerinde birinci dereceden, ikinci dereceden veya daha yüksek dereceden olmak üzere gruplara ayrılmakta ve istatistiksel, dokusal öznitelikler çıkarılabilmektedir (Theodoridis and Koutroumbas, 2009).

Materka and Strzelecki (1998)'e göre, **model tabanlı** doku analizinde fraktal ve stokastik model kullanılarak, görüntü dokusunun üretken görüntü modeli ve stokastik modeliyle yorumlanması sağlanmaktadır (Cross and Jain, 1983; Pentland, 1984; Chellappa and Chatterjee, 1985; Derin and Elliott, 1987; Manjunath and Chellappa, 1991; Strzelecki and Materka, 1997).

Materka and Strzelecki (1998); Fourier, Gabor, dalgacık (wavelet) gibi **dönüşüm yöntemleri** ile görüntü, koordinat sistemi dokunun özellikleriyle ilişkili olan (frekans ve büyüklük gibi) bir uzayda temsil edildiğini belirtmektedir.

Doku bilgisine dayalı öznitelikler, ilgilenilen görüntü bölgesini diğer görüntülerden ayırt edebilmek için doku, gri düzey yoğunluğu bilgisini kullanmaktadır.

Bu bölümde, istatistiksel ve dönüşüm yöntemlerini içeren doku bilgisine dayalı öznitelikler açıklanmaktadır. İstatistiksel yöntemlerinden, birinci ve ikinci dereceden istatistiksel öznitelikler anlatılmaktadır. Dönüşüm yöntemlerinde ise ayrık cosinüs dönüşümü ile elde edilen özniteliklerden bahsedilmektedir.

Birinci dereceden istatistiksel öznitelikler

Birinci dereceden istatistiksel öznitelikler, ilgilenilen pikselin gri düzey yoğunluğuna ilişkin bilgiler elde edilmesini sağlayan özniteliklerdir. Bu aşamada, piksel komşuluk ilişkileri dikkate alınmamaktadır (Srinivasan and Shobha, 2008). Görüntüdeki gri düzeyin histogram dağılımına ilişkin çıkarılan değerleri içerir. Birinci dereceden istatistiksel öznitelikler şu şekilde özetlenebilir:

Aritmetik ortalama (Arithmetic mean)

İlgi bölgesindeki gri düzey yoğunluklarının aritmetik ortalaması hesaplanmaktadır. Veri dağılımının merkezini bulmayı sağlar. Aritmetik ortalama ile ilişkin denklem Eşitlik 3.27’de gösterilmektedir.

$$\mu = \frac{1}{N} \sum_{i=1}^N I_i \quad (3.27)$$

μ aritmetik ortalama, I_i i.pikselin gri düzey yoğunluğu ve N ilgi bölgesi içerisindeki toplam piksel sayısı olmak üzere.

Geometrik ortalama (Geometric mean)

İlgi bölgesindeki gri düzey yoğunluklarının geometrik ortalaması hesaplanmaktadır. Geometrik ortalama ile ilişkin denklem Eşitlik 3.28’de gösterilmektedir.

$$G = \sqrt[N]{I_1 \cdot I_2 \cdots I_N} \quad (3.28)$$

G geometrik ortalama, I_i i.pikselin gri düzey yoğunluğu ve N ilgi bölgesi içerisindeki toplam piksel sayısı olmak üzere.

Harmonik ortalama (Harmonic mean)

İlgi bölgesindeki gri düzey yoğunluklarının harmonik ortalaması hesaplanmaktadır. Harmonik ortalama ile ilişkin denklem Eşitlik 3.29’da gösterilmektedir.

$$H = \frac{n}{\frac{1}{I_1} + \frac{1}{I_2} + \dots + \frac{1}{I_n}} \quad (3.29)$$

H harmonik ortalama, I_i i.pikselin gri düzey yoğunluğu ve N ilgilenilen bölge içerisindeki toplam piksel sayısı olmak üzere.

Standart sapma (Standard deviation)

İlgilenilen bölgedeki gri düzey yoğunluklarının standart sapması hesaplanmaktadır. Bu öznelik ile gri düzey yoğunluk değerlerinin ortalama değerden ne kadar sapma/yayılım gösterdiği belirlenebilmektedir. Standart sapmaya ilişkin denklem Eşitlik 3.30’da gösterilmiştir.

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (I_i - \mu)^2} \quad (3.30)$$

s standart sapma, I_i i.pikselin gri düzey yoğunluğu, μ aritmetik ortalama ve n ilgilenilen bölge içerisindeki toplam piksel sayısı olmak üzere.

Çarpıklık (Skewness)

İlgi bölgesinin gri düzey yoğunluğu histogramının asimetriklik derecesini tanımlamak amacıyla kullanılır. Sıfıra, pozitif veya negatif bir değere eşit olabilmektedir. Normalize edilmiş üçüncü moment olarak da bilinmektedir (Taşcı, 2013). Çarpıklık değerinin hesaplanmasına ilişkin denklem Eşitlik 3.31’de gösterilmektedir (R Tutorial, 2017).

$$g = \frac{m_3}{m_2^{3/2}}, m_3 = \sum (I_i - \mu)^3 / n \text{ ve } m_2 = \sum (I_i - \mu)^2 / n \quad (3.31)$$

g çarpıklık, m_3 3. merkezi moment ve m_2 2. merkezi moment olmak üzere.

Basıklık (Kurtosis)

İlgi bölgesinin gri düzey yoğunluğu histogramının keskinliğini ölçmek, kuyruk şeklini tanımlamak amacıyla kullanılır. Dağılımın dördüncü merkezi momentinin normalize edilmiş formu olarak da tanımlanmaktadır (Wolfram MathWorld, 2017). Basıklık değerinin hesaplanmasına ilişkin denklem Eşitlik 3.32’de gösterilmektedir (Wolfram MathWorld, 2017).

$$k = \frac{m_4}{m_2^2}, m_4 = \sum (I_i - \mu)^4 / n \text{ ve } m_2 = \sum (I_i - \mu)^2 / n \quad (3.32)$$

k basıklık, m_4 4. merkezi moment ve m_2 2. merkezi moment olmak üzere.

Entropi (Bilgi yitimi) (Entropy)

Entropi, rastsal bir değişkenin belirsizliğinin ölçüsü olarak tanımlanmaktadır (Taşcı, 2013). İlgi bölgesinin dokusunu nitelemek amacıyla, gri düzey yoğunluklarının rastgeleliğini ölçmek için kullanılan istatistiksel bir ölçüttür (Mathworks Inc., 2017). Entropi, Eşitlik 3.33’teki gibi tanımlanır.

$$\text{Entropy} = - \sum_{i=1}^n p_i \log_2 p_i \quad (3.33)$$

n toplam durum sayısı, p_i i. durumun gerçekleşme olasılığı olmak üzere.

Çeyrekler arası aralık (Interquartile range)

Üçüncü çeyrek değer ile birinci çeyrek değer arasındaki farka eşittir. Bu aralık, verinin dağılımını tanımlamak amacıyla kullanılır, veri yayılımı arttıkça aralık değeri büyür (Minitab Inc., 2017). Çeyrekler arası aralığın hesaplanmasına ilişkin denklem Eşitlik 3.34’te gösterilmiştir.

$$\text{IQR} = Q3 - Q1 \quad (3.34)$$

IQR çeyrek değerler genişliği, Q3 üçüncü çeyrek değer, Q1 birinci çeyrek değer olmak üzere.

İkinci dereceden istatistiksel öznitelikler


İkinci dereceden istatistiksel öznitelikler, verilen uzaklık değeri ve açıya göre belirlenen komşu pikseller arasındaki ilişkileri dikkate almaktadır. Bu kapsamda **gri düzey eş oluşum matrisi (gri düzey uzaysal bağımlılık) (gray level co-occurrence matrix)** örnek olarak verilebilir.

Gri düzey eş oluşum matrisi (Gri düzey uzaysal bağımlılık) (Gray level co-occurrence matrix)


Gri düzey eş oluşum matrisi, 1973 yılında Haralick et al. tarafından önerilmiş olup, birçok doku analiz uygulamalarında yaygın olarak kullanılmaktadır ve önemli bir öznitelik çıkarma yöntemi olarak uygulanmaktadır (Sebastian et al., 2012). Gri düzey eş oluşum matrisi, i gri düzey yoğunluğu değerine sahip olan pikselin j gri düzey yoğunluğu değerine sahip olan pikselle, verilen uzaysal ilişkiye göre komşu olduğu durum sayılarını oluşturur. Komşuluk durumu yatay, dikey veya sağ, sol köşegensel olmak üzere 4 farklı türde tanımlanabilir. İkili resimler iki farklı ve gri tonlamalı resimler genellikle 8 farklı gri düzeyine ölçeklenir (MathWorks Inc., 2017, Taşcı'dan, 2013).

Gri düzey eş oluşum matrisi (GLCM) döndürme işlemine karşı hassastır. Matrisin döndürmeye karşı bağımsız hale getirilmesi için 0, 45, 90 ve 135 derecedeki açılara göre 4 farklı yönde gri düzey eş oluşum matrisleri oluşturulur. Bu matrislerin değerlerinin toplamı ya da ortalaması alınarak GLCM bağımsız hale getirilir (Taşcı, 2013; Eleyan and Demirel, 2011; Bianconi, F. and Fernández, 2014). Verilen $N * N$ boyutlu, I görüntüsü üzerinde, P gri düzey eş oluşum matrisi Eşitlik 3.35'teki gibi tanımlanmaktadır (Eleyan and Demirel, 2011; Taşcı'dan, 2013). Örnek bir GLCM ve konum – açı ayarlama görüntüsü Şekil 3.1'de gösterilmiştir.

$$P(i, j) = \sum_{x=1}^N \sum_{y=1}^N \begin{cases} 1, & \text{Eğer } I(x, y) = i \text{ ve } I(x + \Delta x, y + \Delta y) = j \\ 0, & \text{değilse} \end{cases} \quad (3.35)$$



(a)



(b)

Şekil 3.1: GLCM örnekleri (a) GLCM matrisinin oluşturulması, (b) Konum ve yön tanımlama (Mathworks Inc., 2017).

Gri düzey eş oluşum matrisi, matrisin tüm değerleri toplamı 1 ve her bir değeri 0 ile 1 aralığında olacak biçimde normalize edilerek olasılık değerleri elde edilebilir. Bunun için Eşitlik 3.36'daki denklem kullanılmaktadır (Vidaurreta, 2015).

$$P_d(i,j) = \frac{C_d(i,j)}{\sum_i \sum_j C_d(i,j)} \quad (3.36)$$

$C_d(i,j)$ gri düzey eş oluşum matrisi değerleri, $P_d(i,j)$ olasılık matrisi değerleri olmak üzere.

Genellikle ilgilenilen görüntü bölgeleri 8 farklı doku düzeyine ölçeklendirilmektedir. Ardından 0, 45, 90 ve 135 derecedeki açılara göre 4 farklı yönde 1 birim uzaklıkta gri düzey eş oluşum matrisleri oluşturulmakta ve bu matrislerin tek bir matris içinde toplanarak döndürme işlemine dirençli olması sağlanmaktadır.

GLCM elde edildikten sonraki aşamada, GLCM matrisi üzerinden ikinci dereceden istatistiksel öznitelikler çıkartılmaktadır. Bu öznitelikler, otokorelasyon (autocorrelation), kontrast (contrast), küme önemi (cluster prominence), cluster

shade, enerji, entropi ve homojenlik olmak üzere 7 adettir. $P(i, j)$ normalize edilmiş GLCM matrisindeki (i, j) . girdi olsun. Matrisin satır ve sütunlarının aritmetik ortalaması ve kullanılan öznitelikler Eşitlik 3.37’de gösterilmiştir. (Taşcı, 2013; Soh and Tsatsoulis, 1999).

$$\mu_x = \sum_i \sum_j i.p(i,j) \quad \mu_y = \sum_i \sum_j j.p(i,j) \quad (3.37)$$

$$\text{Autocorrelation} = \sum_i \sum_j (ij).p(i,j)$$

$$\text{Contrast} = \sum_{n=0}^{Ng-1} n^2 \left\{ \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i,j) \parallel i-j \parallel = n \right\}$$

$$\text{Cluster prominence} = \sum_i \sum_j (i+j-\mu_x-\mu_y)^4 p(i,j)$$

$$\text{Cluster shade} = \sum_i \sum_j (i+j-\mu_x-\mu_y)^3 p(i,j)$$

$$\text{Energy (Angular Second Moment)} = \sum_i \sum_j p(i,j)^2$$

$$\text{Entropy} = - \sum_i \sum_j p(i,j) \log(p(i,j))$$

$$\text{Homogeneity} = \sum_i \sum_j \frac{1}{1+(i-j)^2} p(i,j)$$

Ayrık cosinüs dönüşümü


Ayrık cosinüs dönüşümü (Discrete Cosine Transform) (DCT), ayrık Fourier dönüşümüyle yakından ilişkili olup ayrılabilir doğrusal dönüşümdür (Mathworks, 2017). Yani, iki boyutlu DCT ayrı ayrı boyutlarda, tek boyutlu DCT işlemi uygulanarak elde edilebilir. Ayrıca, yüz tanıma gibi örüntü tanıma alanında uygun öznitelikleri çıkarmak amacıyla kullanılan güçlü bir dönüşüm yöntemi olarak da tanımlanmaktadır (Dabbaghchian et al., 2010). Görüntü sıkıştırma alanında uygulanabilmektedir. Girdi görüntüsü A ve çıktı görüntüsü B için 2 boyutlu DCT Eşitlik 3.38’deki gibi tanımlanmaktadır (Mathworks, 2017).

$$B_{pq} = a_p a_q \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} A_{mn} \cos \frac{\pi(2m+1)p}{2M} \cos \frac{\pi(2n+1)q}{2N}, \quad \begin{matrix} 0 \leq p \leq M-1 \\ 0 \leq q \leq N-1 \end{matrix} \quad (3.38)$$

M ve N, A’nın satır ve sütun boyutu, a_p ve a_q ise Eşitlik 3.39’daki gibi olmak üzere.

$$a_p = \begin{cases} \frac{1}{\sqrt{M}}, p = 0 \\ \sqrt{\frac{2}{M}}, 1 \leq p \leq M-1 \end{cases} \quad a_q = \begin{cases} \frac{1}{\sqrt{N}}, q = 0 \\ \sqrt{\frac{2}{N}}, 1 \leq q \leq N-1 \end{cases} \quad (3.39)$$

Görüntüler üzerinde uygulanan 2 boyutlu DCT ile DCT katsayılar matrisi elde edilmektedir. Bu matris üzerinde seçim yapılarak belli sayıda katsayının seçilmesi sağlanmaktadır ve veri boyutu indirgenmektedir. Katsayılar seçilirken **zigzag** yöntemi kullanılmaktadır. Matris üzerinde zigzag yönteminin gösterimi Şekil 3.2'deki gibidir. Zigzag yönteminde elde edilen katsayılardan önemli olanları ilk sırada yer alırken diğerleri son sıralarda yer almaktadır. Yüksek enerji yoğunluğuna sahip olan katsayı elemanları ilk olarak okunmaktadır (Cornell Univ, 2017).



Şekil 3.2: Zigzag yönteminin gösterimi (Cornell Univ, 2017)

Yerel ikili örüntü (Local binary pattern) (LBP) öznitelikleri

Yerel ikili örüntü operatörü, dokusal öznitelik çıkarma amacıyla tasarlanmıştır, en iyi doku tanımlayıcılarından birisidir ve çeşitli uygulamalarda kullanılmaktadır (Ahonen et al.'dan, 2006; Ojala et al., 1996). Yüksek düzeyde ayırt edici özelliği, monotonik gri düzey değişikliklerine karşı değişmezliği, hesaplama etkinliği ve görüntü analiz uygulamalarına uygunluğu nedeniyle tercih edilmektedir (Ahonen et al., 2006). LBP operatörü, görüntüdeki her bir pikselin 3*3'lük komşuluğunu merkez piksel değeri ile eşikleyerek görüntünün her bir pikseline bir etiket atar. Ardından, etiketlerin histogramı doku tanımlayıcısı olarak kullanılmaktadır (Ahonen et al., 2006).

Görüntünün her bir pikselinde, pikselin kendisi ve komşuları arasındaki farkın $u(x)$ basamak fonksiyonu ile ikilileştirilmesiyle etiketlenme işlemi sağlanmaktadır (Nabiyev ve Günay, 2011). Bu durum Eşitlik 3.40'ta gösterilmektedir. Farklı ölçekteki dokularla ilgilenebilmek için LBP operatöründe farklı boyutlarda komşuluk işlemi uygulanabilmektedir (Ahonen et al., 2006).

$$LBP_{P,R}(x_c) = \sum_{p=0}^{P-1} u(x_p - x_c) 2^p, \quad u_y = \begin{cases} 1, & y \geq 0 \\ 0, & y < 0 \end{cases} \text{ ise } (3.40)$$

LBP etiketi üretilen merkez pikseli, x_p merkez pikselin komşularını, R komşuların merkez piksele olan uzaklığını, P ise işleme koyulan komşu sayısı olmak üzere.

LBP öznitelik çıkarma işlemine ait örnek bir görüntü Şekil 3.3'te gösterilmektedir. Bu örnekte, görüntü üzerindeki merkez piksel için LBP operatörü uygulanması sonucunda ikili ve onlu kod değerleri elde edilmektedir.

110	112	115
78	110	113
68	75	80

Eşikleme
→

1	1	1
0		1
0	0	0

İkili Kod: 11110000

Onlu Kod: 230

Şekil 3.3: LBP operatörünün uygulanmasına ilişkin örnek (Nabiyev ve Günay, 2011)

LBP operatörüne ek olarak, düzgün örüntü (uniform pattern) tanımlaması ile öznitelik vektörünün boyutu azaltılıp, döndürme işleminden bağımsız tanımlayıcı elde edilebilmektedir. Bu durum, düzgün örüntülerde bazı ikili örüntülerin doku görüntülerinde yaygın olarak kullanılmasından kaynaklanmaktadır (Scholarpedia, 2017). Eğer ikili örüntü 0'dan 1'e veya 1'den 0'a en fazla 2 adet bit tabanlı geçişi varsa düzgün örüntü olarak adlandırılmaktadır. Örneğin, 0000000 ve 11111111 örüntüleri 0 bit tabanlı geçişe, 00011100 ve 11011111 örüntüleri 2 bit tabanlı geçişe sahip olduğundan düzgün örüntüdür. Fakat 4 bit tabanlı geçişe sahip 11000010 örüntüsü düzgün değildir. Yapılan çalışmalarda, düzgün örüntülerin doku görüntüleri içerisinde bazen %90'ın üzerinde, geniş bir çoğunluğa sahip olduğu görülmüştür (Nabiyev ve Günay, 2011; Ojala et al, 2002). LBP'de histogram oluştururken düzgün örüntüler kullanıldığında, her bir düzgün örüntü için ayrı bir etiket ve düzgün olmayan tüm örüntüler tek bir etikette temsil edilir. Bu sayede, 8 komşuluk için tüm örüntülerde doku özniteliklerinin toplam 59

farklı etiketle temsili sağlanabilmektedir (Scholarpedia, 2017). Bu sayede, LBP ile 59 adet dokusal öznitelik çıkartılmaktadır.

3.2 Derin Öğrenme ile Görüntülerden Öznitelik Çıkarma


Derin öğrenme ile önceden eğitilmiş çeşitli CNN modelleri üzerinden öznitelikler çıkartılabilmektedir. Bu kapsamda AlexNet, VGG-16 ve VGG-19 CNN mimarileri ile elde edilen öznitelikler izleyen alt bölümlerde açıklanmaktadır.

3.2.1 Alexnet CNN Modeli ile Öznitelik Çıkarımı

AlexNet, 1 milyondan fazla görüntü içeren ImageNet (ImageNet, 2018) verisetinin altkütmesi üzerinde eğitilmiş, ImageNet Large-Scale Visual Recognition Challenge (ILSVRC)'de kullanılmış bir CNN modelidir (Russakovsky et al., 2018; Mathworks Inc., 2018). Görüntüleri 1000 farklı sınıfa atayabilmektedir. Bu ağ, girdi katmanı, evrişimsel katman, ReLU ve havuzlama katmanları, tam bağlantılı katman ve çıktı katmanı olmak üzere toplam 25 katman içermektedir (Mathworks Inc., 2018) (Çizelge 3.1). AlexNet CNN mimarisinin genel görünümü Şekil 3.4'de gösterilmektedir.

Çizelge 3.1: AlexNet CNN katmanlarına ilişkin açıklamalar (Mathworks Inc., 2018)

Katman No	Katman Adı	Katman Türü	Katman Özellikleri
1	'data'	Girdi	227x227x3 images with 'zerocenter' normalization
2	'conv1'	Convolution	96 11x11x3 convolutions with stride [4 4] and padding [0 0 0 0]
3	'relu1'	ReLU	ReLU
4	'norm1'	Cross Channel	cross channel normalization with 5 channels per element
5	'pool1'	Max Pooling	3x3 max pooling with stride [2 2] and padding [0 0 0 0]
6	'conv2'	Convolution	256 5x5x48 convolutions with stride [1 1] and padding [2 2 2 2]
7	'relu2'	ReLU	ReLU
8	'norm2'	Cross Channel	cross channel normalization with 5 channels per element
9	'pool2'	Max Pooling	3x3 max pooling with stride [2 2] and padding [0 0 0 0]
10	'conv3'	Convolution	384 3x3x256 convolutions with stride [1 1] and padding [1 1 1 1]
11	'relu3'	ReLU	ReLU
12	'conv4'	Convolution	384 3x3x192 convolutions with stride [1 1] and padding [1 1 1 1]
13	'relu4'	ReLU	ReLU
14	'conv5'	Convolution	256 3x3x192 convolutions with stride [1 1] and padding [1 1 1 1]
15	'relu5'	ReLU	ReLU
16	'pool5'	Max Pooling	3x3 max pooling with stride [2 2] and padding [0 0 0 0]
17	'fc6'	Fully Connected	4096 fully connected layer
18	'relu6'	ReLU	ReLU
19	'drop6'	Dropout	50% dropout
20	'fc7'	Fully Connected	4096 fully connected layer
21	'relu7'	ReLU	ReLU
22	'drop7'	Dropout	50% dropout
23	'fc8'	Fully Connected	1000 fully connected layer
24	'prob'	Softmax	softmax
25	'output'	Classification	crossentropyex with 'tench' and 999 other classes



Şekil 3.4: AlexNet CNN mimarisinin genel görünümü (Krizhevsky et al., 2012)

AlexNet CNN'e göre görüntü girdisi 227*227*3 boyutunda olmalıdır. Bunun için, görüntüler üzerinde öncelikle ölçekleme işlemi yapılmaktadır. Tam bağlantı katmanları ile 4096 adet öznetelik çıkartılabilmektedir. Mimaride yer alan

en son katman 1000 adet sınıfa özgü sınıflandırma işlemini gerçekleştiren katmandır. Sınıflandırma katmanının bitişiğinde yer alan tam bağlantılı (Fully Connected) (FC) katmanlar ile öz nitelikler otomatik olarak elde edilebilmektedir. CNN katmanları ile başlangıçta kenar öz nitelikleri gibi temel öz nitelikler çıkartılabilirken, ilerleyen katmanlarda daha genel öz niteliklere ulaşılabilir.

3.2.2 VGG-16 CNN Modeli ile Öz nitelik Çıkarımı


VGG-16 CNN modeli, AlexNet gibi 1 milyondan fazla görüntüden oluşan ImageNet (ImageNet, 2018) verisetinin altkütmesi üzerinde eğitilmiş, ImageNet Large-Scale Visual Recognition Challenge (ILSVRC)'de kullanılmış bir CNN modelidir (Russakovsky et al., 2018; Mathworks Inc., 2018). Görüntüleri 1000 farklı sınıfa atayabilmektedir. VGG-16, Oxford Üniversitesi'nde Visual Geometry Group tarafından geliştirilmiştir (Simonyan and Zisserman, 2014).

VGG-16 modeli 41 katman içermektedir (Mathworks Inc., 2018) (Çizelge 3.2). Bu katmanlar içerisinde, 13 adet evrişimsel ve 3 adet tam bağlantılı katman yer almaktadır. Çizelge 3.2'ye göre FC6 ve FC7 tam bağlantı katmanlarından 4096 adet öz nitelik çıkartılabilmektedir.

VGG-16 modeline göre görüntü girdisi $224 \times 224 \times 3$ boyutunda olmalıdır. Katman özellikleri AlexNet mimarisiyle benzerlik göstermektedir. VGG-16 mimarisinin şematik görünümü Şekil 3.5'te sunulmaktadır.

Çizelge 3.2: VGG-16 CNN katmanlarına ilişkin açıklamalar (Mathworks Inc., 2018)

Katman No	Katman Adı	Katman Türü	Katman Özellikleri
1	'input'	Image Input	224x224x3 images with 'zerocenter' normalization
2	'conv1_1'	Convolution	64 3x3x3 convolutions with stride [1 1] and padding [1 1]
3	'relu_1'	ReLU	ReLU
4	'conv1_2'	Convolution	64 3x3x64 convolutions with stride [1 1] and padding [1 1]
5	'relu_2'	ReLU	ReLU
6	'pool1'	Max Pooling	2x2 max pooling with stride [2 2] and padding [0 0]
7	'conv2_1'	Convolution	128 3x3x64 convolutions with stride [1 1] and padding [1 1]
8	'relu2_1'	ReLU	ReLU
9	'conv2_2'	Convolution	128 3x3x128 convolutions with stride [1 1] and padding [1 1]
10	'relu2_2'	ReLU	ReLU
11	'pool2'	Max Pooling	2x2 max pooling with stride [2 2] and padding [0 0]
12	'conv3_1'	Convolution	256 3x3x128 convolutions with stride [1 1] and padding [1 1]
13	'relu3_1'	ReLU	ReLU
14	'conv3_2'	Convolution	256 3x3x256 convolutions with stride [1 1] and padding [1 1]
15	'relu3_2'	ReLU	ReLU
16	'conv3_3'	Convolution	256 3x3x256 convolutions with stride [1 1] and padding [1 1]
17	'relu3_3'	ReLU	ReLU
18	'pool3'	Max Pooling	2x2 max pooling with stride [2 2] and padding [0 0]
19	'conv4_1'	Convolution	512 3x3x256 convolutions with stride [1 1] and padding [1 1]
20	'relu4_1'	ReLU	ReLU
21	'conv4_2'	Convolution	512 3x3x512 convolutions with stride [1 1] and padding [1 1]
22	'relu4_2'	ReLU	ReLU
23	'conv4_3'	Convolution	512 3x3x512 convolutions with stride [1 1] and padding [1 1]
24	'relu4_3'	ReLU	ReLU
25	'pool4'	Max Pooling	2x2 max pooling with stride [2 2] and padding [0 0]
26	'conv5_1'	Convolution	512 3x3x512 convolutions with stride [1 1] and padding [1 1]
27	'relu5_1'	ReLU	ReLU
28	'conv5_2'	Convolution	512 3x3x512 convolutions with stride [1 1] and padding [1 1]
29	'relu5_2'	ReLU	ReLU
30	'conv5_3'	Convolution	512 3x3x512 convolutions with stride [1 1] and padding [1 1]
31	'relu5_3'	ReLU	ReLU
32	'pool5'	Max Pooling	2x2 max pooling with stride [2 2] and padding [0 0]
33	'fc6'	Fully Connected	4096 fully connected layer
34	'relu6'	ReLU	ReLU
35	'drop6'	Dropout	50% dropout
36	'fc7'	Fully Connected	4096 fully connected layer
37	'relu7'	ReLU	ReLU
38	'drop7'	Dropout	50% dropout
39	'fc8'	Fully Connected	1000 fully connected layer
40	'prob'	Softmax	softmax
41	'output'	Classification Output	crossentropyex with 'tench', 'goldfish', and 998 other classes



Şekil 3.5: VGG-16 CNN mimarisinin şematik gösterimi (Gopalakrishnan et al., 2017)

3.2.3 VGG-19 CNN ile Öznitelik Çıkarımı

VGG-19 da, VGG-16 ve AlexNet gibi 1 milyondan fazla görüntüden oluşan ImageNet (ImageNet, 2018) verisetinin altkütmesi üzerinde eğitilmiş, ImageNet Large-Scale Visual Recognition Challenge (ILSVRC)’de kullanılmış bir CNN modelidir (Russakovsky et al., 2018; Mathworks Inc., 2018). Görüntüleri 1000 farklı sınıfa atayabilmektedir.

VGG-19 modeli, VGG-16 modelinden farklı olarak 47 katmandan oluşmaktadır (Mathworks Inc., 2018). Bu katmanların 16 adeti evrişimsel ve 3 adeti tam bağlantı katmanlarını içermektedir. Çizelge 3.3’e göre FC6 ve FC7 tam bağlantı katmanlarından 4096 adet öznitelik çıkartılabilmektedir.

VGG-19 modeline göre görüntü girdisi $224 \times 224 \times 3$ boyutunda olmalıdır. Katman özellikleri VGG-16 ve AlexNet modeliyle benzerlik göstermektedir. VGG-19 mimarisinin yapısı Şekil 3.6’da konfigürasyon E’de sunulmaktadır.

Çizelge 3.3: VGG-19 CNN katmanlarına ilişkin açıklamalar (Mathworks Inc., 2018)

Katman No	Katman Adı	Katman Türü	Katman Özellikleri
1	'input'	Image Input	224x224x3 images with 'zero-center' normalization
2	'conv1_1'	Convolution	64 3x3x3 convolutions with stride [1 1] and padding [1 1]
3	'relu1_1'	ReLU	ReLU
4	'conv1_2'	Convolution	64 3x3x64 convolutions with stride [1 1] and padding [1 1]
5	'relu1_2'	ReLU	ReLU
6	'pool1'	Max Pooling	2x2 max pooling with stride [2 2] and padding [0 0]
7	'conv2_1'	Convolution	128 3x3x64 convolutions with stride [1 1] and padding [1 1]
8	'relu2_1'	ReLU	ReLU
9	'conv2_2'	Convolution	128 3x3x128 convolutions with stride [1 1] and padding [1 1]
10	'relu2_2'	ReLU	ReLU
11	'pool2'	Max Pooling	2x2 max pooling with stride [2 2] and padding [0 0]
12	'conv3_1'	Convolution	256 3x3x128 convolutions with stride [1 1] and padding [1 1]
13	'relu3_1'	ReLU	ReLU
14	'conv3_2'	Convolution	256 3x3x256 convolutions with stride [1 1] and padding [1 1]
15	'relu3_2'	ReLU	ReLU
16	'conv3_3'	Convolution	256 3x3x256 convolutions with stride [1 1] and padding [1 1]
17	'relu3_3'	ReLU	ReLU
18	'conv3_4'	Convolution	256 3x3x256 convolutions with stride [1 1] and padding [1 1]
19	'relu3_4'	ReLU	ReLU
20	'pool3'	Max Pooling	2x2 max pooling with stride [2 2] and padding [0 0]
21	'conv4_1'	Convolution	512 3x3x256 convolutions with stride [1 1] and padding [1 1]
22	'relu4_1'	ReLU	ReLU
23	'conv4_2'	Convolution	512 3x3x512 convolutions with stride [1 1] and padding [1 1]
24	'relu4_2'	ReLU	ReLU
25	'conv4_3'	Convolution	512 3x3x512 convolutions with stride [1 1] and padding [1 1]
26	'relu4_3'	ReLU	ReLU
27	'conv4_4'	Convolution	512 3x3x512 convolutions with stride [1 1] and padding [1 1]
28	'relu4_4'	ReLU	ReLU
29	'pool4'	Max Pooling	2x2 max pooling with stride [2 2] and padding [0 0]
30	'conv5_1'	Convolution	512 3x3x512 convolutions with stride [1 1] and padding [1 1]
31	'relu5_1'	ReLU	ReLU
32	'conv5_2'	Convolution	512 3x3x512 convolutions with stride [1 1] and padding [1 1]
33	'relu5_2'	ReLU	ReLU
34	'conv5_3'	Convolution	512 3x3x512 convolutions with stride [1 1] and padding [1 1]
35	'relu5_3'	ReLU	ReLU
36	'conv5_4'	Convolution	512 3x3x512 convolutions with stride [1 1] and padding [1 1]
37	'relu5_4'	ReLU	ReLU
38	'pool5'	Max Pooling	2x2 max pooling with stride [2 2] and padding [0 0]
39	'fc6'	Fully Connected	4096 fully connected layer
40	'relu6'	ReLU	ReLU
41	'drop6'	Dropout	50% dropout
42	'fc7'	Fully Connected	4096 fully connected layer
43	'relu7'	ReLU	ReLU
44	'drop7'	Dropout	50% dropout
45	'fc8'	Fully Connected	1000 fully connected layer
46	'prob'	Softmax	softmax
47	'output'	Classification Output	crossentropyex with 'tench', 'goldfish', and 998 other classes

ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224 × 224 RGB image)					
conv3-64	conv3-64 LRN	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 conv1-256	conv3-256 conv3-256 conv3-256	conv3-256 conv3-256 conv3-256 conv3-256
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

Şekil 3.6: VGG-19 CNN mimarisinin yapısı (Simonyan and Zisserman, 2014)

3.3 Öznitelik Seçimi

Tüm öznitelikler arasından belli sayıda ayırt edici özniteliklerin seçilmesini sağlayan öznitelik seçimi aşamasında, öznitelik alt kümesinin seçilmesi uygunluk fonksiyonlarına göre 3 gruba ayrılmaktadır. Bunlar; filtre (filter), sarmalayıcı (wrapper) ve gömülü (embedded) yöntemlerdir (Guyon and Elisseeff, 2003; Saeys et al., 2007; Jović et al., 2015; Liu and Yu, 2005).

Filtre yöntemi, sınıflandırıcıdan bağımsız bir biçimde veriler arasındaki ilişkileri ve bilgi içeriklerini dikkate alarak öznitelik alt kümesini seçmektedir. Sarmalayıcı yöntemler, istatistiksel örnekleme veya çapraz doğrulama gibi yöntemlerle belirli bir sınıflandırıcı üzerindeki öznitelik kümesinin performansını belirleyerek öznitelik seçimini gerçekleştirir. Gömülü yöntemler ise belli bir modele özgü olarak modelin eğitimi ve çalışması aşamasında öznitelik seçimini sağlamaktadır. SVM-RFE (Support Vector Machine – Recursive Feature Elimination) (Destek Vektör Makinesi – Özyinelemeli Öznitelik Eliminasyonu) ve CART (Classification and Regression Tree) (Sınıflandırma ve Regresyon Ağacı) gömülü yöntemler kapsamında örnek olarak verilebilir (Guyon and Elisseeff, 2003; Chandrashekar and Şahin, 2014). Ayrıca, hem filtre hem de sarmalayıcı

yöntemlerin avantajlarını birleştiren hibrit yöntemler de önerilmiştir (Jović et al., 2015).

Alt bölümlerde, bu çalışmada uygulanan öznitelik seçim yöntemleri ayrıntılı olarak anlatılmaktadır.


3.3.1 Ardışık ileri yönde seçim algoritması

Ardışık ileri yönde seçim algoritması, alt optimal bir arama stratejisi yöntemidir. Optimal öznitelik sayısı az olduğunda en iyi sonucu vermektedir. Bu algoritma, Çizelge 3.4'te gösterilmiştir.

Öznitelik kümesine eleman eklendikçe algoritmanın arama bölgesi daralmaktadır (Şekil 3.7). Bu algoritmadaki temel problem, öznitelik eklendikten sonra bir daha kümeden çıkarılamamasıdır (Gutierrez-Osuna, 2017b).

Çizelge 3.4: Ardışık ileri yönde seçim algoritması (Gutierrez-Osuna, 2017b)

Ardışık ileri yönde seçim algoritması	
I.	Boş öznitelik kümesinden başla $Y_0 = \{\emptyset\}$
II.	En iyi özniteliği seç $x^+ = \arg \max_{x \notin Y_k} J(Y_k + x)$
III.	Güncelle $Y_{k+1} = Y_k + x^+; k = k + 1$
IV.	İstenilen öznitelik boyutuna kadar ikinci adıma git.



Şekil 3.7: Ardışık ileri yönde seçim algoritması arama uzayı (Gutierrez-Osuna, 2017b)

3.3.2 Ardışık geri yönde seçim algoritması

Ardışık geri yönde seçim algoritması, alt optimal bir arama stratejisi yöntemidir. Bu algoritma, ardışık ileri yönde seçim algoritmasının tersi yönde

çalışır. Optimal öznitelik sayısı fazla olduğunda en iyi sonucu verir. SBS (Sequential Backward Selection) algoritması Çizelge 3.5’te gösterilmektedir.

Algoritma, zamanın çoğunluğunu büyük boyutlu alt kümelerde harcar (Şekil 3.8). Bu algoritmadaki temel problem, öznitelik çıkarıldıktan sonra bir daha kümeye eklenememesidir (Gutierrez-Osuna, 2017b).

Çizelge 3.5: Ardışık geri yönde seçim algoritması (Gutierrez-Osuna, 2017b).

Ardışık geri yönde seçim algoritması	
I.	Tüm özniteliklerin bulunduğu kümeden başla $Y_0 = X$
II.	En kötü özniteliği (uygunluk fonksiyonundaki değeri en az azaltan) çıkar. $\bar{x} = \arg \max_{x \in Y_k} J(Y_k - x)$
III.	Güncelle $Y_{k+1} = Y_k - \bar{x}$; $k = k + 1$
IV.	İstenilen öznitelik boyutuna kadar ikinci adıma git.



Şekil 3.8: Ardışık geri yönde seçim algoritması arama uzayı (Gutierrez-Osuna, 2017b)

3.3.3 Genetik algoritmalar

Genetik algoritmalar, doğada en uygun bireyin hayatta kalmasını sağlayan doğal seçim ve arama süreçlerinden ortaya çıkan bir arama ve eniyileme yöntemidir. Makine öğrenmesi, müzik üretimi, genetik birleşim, VLSI (Very Large Scale Integration) teknolojisi, strateji planlama gibi çok sayıda alanda uygulanmaktadır (Srinivas and Patnaik, 1994). GA, evrimsel hesaplamaların bir örneğidir ve yapay zekânın hızla gelişen bir alanıdır. GA, ilk olarak 1960’lı yıllarda John Holland tarafından ortaya çıkarılmış, 1960’lı ve 1970’li yıllarda John Holland ve arkadaşları tarafından Michigan Üniversitesi’nde geliştirilmiştir (Mitchell, 1998).

GA, çözülmesi oldukça zor ve zaman alıcı (nondeterministic polynomial-time hard) (NP-Hard) problemlerin, karmaşık işlemlerin çözümünde kullanılmaktadır. GA, matematiksel güdümlü algoritma olarak dikkate alınmaz. En iyi çözüm, geleneksel gradyan türünde eniyileme işlemi gibi matematiksel formüller yerine nesilden nesile çözümlerin geliştirilmesi ve iyileştirilmesi ile elde edilir (Man et al., 1996). GA, her nesilde en uygun olan bireyin hayatta kalması ve kazanması kuralına göre çalışır.

GA, uygunluk fonksiyonuna göre çalışan global, çok amaçlı, metasezgisel eniyileme yöntemidir. Genetik algoritmalar, tamamen rastsal ve paralel olarak çözüm arayabilen, paralel çalışabilen algoritmalarlardır.

GA ile bir eniyileme problemini çözmek için öncelikle başlangıç çözümlerinden oluşan popülasyon üretilir. Seçim, çaprazlama ve mutasyon işlemleri ile nesiller boyunca çözümler ileri doğru götürülerek kötü çözümlerin yok olması ve daha iyi çözümlerin elde edilmesine çalışılır. Bu sayede arama uzayının boyutu azaltılarak, kabul edilebilir bir zaman dilimi içerisinde etkili ve uygun çözümlerin elde edilmesi sağlanmaktadır.

Genetik algoritmaların anlaşılabilmesi açısından için genetik bilimi hakkında kısmen bilgi sahibi olmak gereklidir. Kromozom, popülasyon, çaprazlama, mutasyon, elitizm (seçkincilik) gibi kavramlar genetik algoritmalar için önem taşımaktadır.

Biyolojik terimler

Kromozom

Tüm canlılar hücrelerden oluşur. Her hücrede bir veya daha fazla kromozom dizisi vardır. Kromozomlar DNA stringleridir ve tüm organizmada taslak olarak görev yapar (Mitchell, 1998).

Gen

Kromozomu oluşturmak için sıralanmış her bir değişkene “gen” adı verilir. Bir kromozom gen adı verilen DNA bloklarından oluşur. Her gen belirli bir proteini kodlar. Her gen gözlerin rengi gibi bir özelliği kodlamada kullanılır (Mitchell, 1998). Bir özellik için gerekli olan ayarlamalar (Örn. Mavi, kahverengi) alel olarak adlandırılır (Mitchell, 1998).

Locus

Her genin kromozomda bulunduğu pozisyona, yere locus adı verilir.

Genom

Bir organizmadaki genetik malzemenin bütününe genom adı verilir.

Genotip

Genom içerisindeki belirli gen kümesine ya da bir organizmadaki genetik yapıya genotip adı verilir.

Fenotip

Canlının sahip olduğu gözlemlenebilir özelliklere fenotip adı verilir. Fenotip genellikle genler tarafından belirlenir. Canlının fiziksel ve zihinsel karakteristikleri, göz rengi, zekası vb.

Yeniden üretim

Yeniden üretim, çaprazlama ile sağlanır. Atalardan gelen genler çaprazlanarak yeni kromozomlar oluşturulur ve çeşitlilik sağlanır. Yeniden oluşturulan kromozomlar mutasyona uğrayabilir.

Mutasyon

DNA ya da RNA dizilim elemanlarının kalıcı değişmesidir.

Uygunluk

Bir organizmanın uygunluğu, hayatta kalma başarısı, adaptasyonu ile ölçülür.

Arama uzayı

İstenen çözümün de aralarında bulunduğu, mümkün olan tüm çözümlerin uzayına arama uzayı adı verilir. Arama uzayındaki her nokta bir olası çözümü temsil etmektedir.

Genetik algoritma bileşenleri

Genetik algoritmalar, popülasyon, kontrol parametreleri, uygunluk fonksiyonları, genetik operatörler (çaprazlama ve mutasyon), seçim ve kodlama mekanizmalarından oluşmaktadır (Srinivas and Patnaik, 1994).


Genetik algoritma bileşenleri şu şekilde açıklanabilir:

Kodlama mekanizması, eniyileme problemine göre değişiklik gösterebilmektedir. Öznitelik seçiminde 1 ve 0 kodlama mekanizması kullanılarak belirtilen özniteliğin seçilip seçilmeyeceği belirlenmektedir. Tez kapsamında kullanılan kodlama mekanizmasının örneği Şekil 3.9'da gösterilmektedir.

1	0	...	1
---	---	-----	---


Şekil 3.9: Genetik algoritmalar ile öznitelik seçimi çözüm kodlama mekanizması

Popülasyon, çok sayıda kromozomdan (bireyden) oluşur. Kromozom ise bir problem için aday çözümü temsil eder ve gen dizisinden oluşur. Genler genellikle tek bir sayı içerirler. Seçim, yeniden üretim için popülasyondan kromozomların seçilmesi işlemidir. Uygunluk değeri daha yüksek olan bireyin seçilme olasılığı daha yüksek olacaktır. Rulet tekeri, rank, turnuva seçimi gibi birtakım ata birey seçim yöntemleri uygulanmaktadır. Rulet tekeri seçim yöntemi uygunluklarla orantılı olacak biçimde seçim olasılığı sağlarken, düşük uygunluk değerine sahip bireylerin seçilme olasılığını sürekli düşük tutmaktadır. Bu problemin önüne geçmek amacıyla rank seçimi uygulanmaktadır. Rank seçiminde, n adet bireyden oluşan popülasyonda en yüksek uygunluk değerine sahip bireye n birim ağırlık, en düşük uygunluk değerine sahip olan bireye 1 birim ağırlık olacak şekilde ağırlıklar atanarak seçimin daha adil olması sağlanmaktadır. Çaprazlama, 2 adet ata kromozom yapısından genetik bilgilerin değişiminin sağlanmasıdır. Seçilen gen değişim noktalarına göre tek noktalı, iki noktalı çaprazlama olabilmektedir. Tez sürecinde, tek noktalı çaprazlama uygulanarak öznitelik seçimi gerçekleştirilmiştir. Tek noktalı çaprazlama işlemi Şekil 3.10'da gösterilmektedir.



Şekil 3.10: Tek noktalı çaprazlama işlemi

Mutasyon ise genellikle kromozom üzerinde rastgele seçilen konumdaki bitin değiştirilmesini içerir. Kromozom kodlamasına göre mutasyon işlemi farklı biçimlerde yapılabilmektedir. Öznitelik seçiminde 0 olan gen değerini 1 ile veya 1 olan gen değerini 0 ile değiştirme mutasyon işlemi olarak tanımlanmaktadır. Mutasyon işlemine ait örnek Şekil 3.11'de gösterilmektedir.



Şekil 3.11: Öznitelik seçiminde mutasyon işlemi örneği

Uygunluk fonksiyonu, her bir kromozomda değerlendirme mekanizmasını ve en iyilemeyi sağlamak için kullanılan fonksiyondur. Uygunluk fonksiyonunun değeri problemden probleme değişiklik gösterebildiğinden dolayı uygunluk değerleri genellikle $[0,1]$ aralığına normalize edilir (Srinivas and Patnaik, 1994). Maksimizasyon problemlerinde en yüksek uygunluk değerine, minimizasyon problemlerinde ise en düşük uygunluk değerine sahip bireyin seçim olasılığı yüksek olacaktır.

Basit genetik algoritmanın genel yapısı (Srinivas and Patnaik, 1994)

1. İlk popülasyonu oluştur.
2. Popülasyondaki her bir bireyin uygunluğunu hesapla.
3. Sonlandırma kriteri tamamlanıncaya kadar aşağıdaki işlemleri tekrarla.
 1. Bir sonraki nesil için çözümleri seç
 2. Çaprazlama ve mutasyon işlemini gerçekleştir.
 3. Popülasyonun yeni uygunluk değerini hesapla.

Elitizm (seçkincilik), her nesil sonunda önceden belirlenmiş sayıda en iyi n adet bireyin kopyalanması ile yeni nesilde bu bireylerin korunması ve en iyi çözümlerin saklanmasını sağlamaktadır.

2-opt algoritması ise, ikili genlerin yer değiştirmesine dayanan yerel arama algoritmasıdır.

4. ÖNCEKİ ÇALIŞMALAR

Literatürde, öznitelik çıkarma ve seçimi aşamalarını içeren görüntü işleme ve örüntü tanıma alanlarında yapılmış çok sayıda çalışma bulunmaktadır. Bu bölümde, öznitelik çıkarma ve seçimi temel hatlarıyla anlatılmakta, literatürdeki çalışmalarda kullanılan yöntemler hakkında bilgi verilmektedir.

Öznitelik çıkarma, çoklu ortam işlemlerinde önemli bir adımdır, bilgisayarlı görüde ise görüntünün içeriğini mümkün olduğunca yansıtan özniteliklerin çıkarılması zorlu bir problem olarak karşımıza çıkmaktadır (Tian, 2013). Bir bilgisayar programının görüntüden anlamsal kavramlar keşfedebilmesi, görüntü işleme ile elde edilen etkili ve anlamlı öznitelikler çıkarılmasına bağlıdır (Tian, 2013). En yaygın olarak kullanılan öznitelikler **şekil, renk ve doku (desen)** bilgilerine dayalı özniteliklerdir.

Öznitelik çıkarmanın kullanıldığı bir problem türü **yaprak tanımadır**. Örüntü tanımanın özellikle yapraklar üzerinde gerçekleştirilmesi biçiminde tanımlanmaktadır (Ehsanirad, 2010). Flavia veri seti üzerinde, Wu et al., (2007a) yaprak şekli ve damarlarını içeren 12 adet morfolojik öznitelik çıkartarak ve bu öznitelikleri 5 temel bileşene indirgeyerek, olasılıksal yapay sinir ağı sınıflandırıcısı ile %90.312 oranında sınıflandırma başarısı elde etmiştir. Türkoğlu ve Hanbay (2015) çalışmasında, 9 adet morfolojik öznitelik çıkartıp, destek vektör makineleri kullanarak yaprak görüntülerinden üzüm çeşitlerini sınıflandırmıştır. Zhang et al. (2015), yaprak görüntülerinden renge, şekle ve dokuya dayalı öznitelikler çıkartarak bitki hastalıklarının otomatik tespitini sağlamıştır. Bitki türlerinin bilgisayarlı görü teknikleri kullanılarak belirlenmesine ilişkin yapılmış çalışmalar hakkında daha ayrıntılı bilgilere Wäldchen and Mäder (2017)'den ulaşılabilir.

Yaprak tanıma problemi için tüm yaprak görüntülerini dikkate alan özniteliklerin kullanımı dışında yaprak görüntüsünün belli bir bölümünü dikkate alan özniteliklerin çıkarılmasını içeren çalışmalarda bulunmaktadır. Ulutürk and Uğur (2012) yaptığı çalışmada, Flavia veri seti üzerindeki yaprak görüntülerinden 7 adet temel morfolojik öznitelik çıkarmış ve bu özniteliklere ek olarak yarım yaprak görüntülerinden şekil bilgisi dikkate alınarak çıkarılan 3 adet oransal özniteliği ekleyerek sistemin tanıma performansını %88.25'ten %92.5'e çıkartmıştır. Rojas-Hernandez et al. (2016) Swedish yaprak veriseti üzerinde varolan özniteliklere ek olarak yaprakların yatay ve dikey simetrisini tanımlayan 3

adet geometrik öznitelik çıkartarak yaprak tanıma sisteminin performansını artırmıştır. Yaprğa özel tanımlayıcıların önerildiğı çalışmada, Hossain and Amin (2010), yaprak genişlik faktörü (leaf width factor) (LWF) adında, yaprağı ana ekseninin karşısından ve ikincil eksene paralel olarak dilimleyerek öznitelik çıkartmıştır. Şerit başına LWF değeri şeritin genişliğinin tüm yaprak uzunluğuna (ana eksen uzunluğu) oranı ile hesaplanmaktadır (Wäldchen and Mäder, 2017). Yanıkoğlu et al. (2014) ise literatüre alan genişlik faktörü (area width factor) (AWF) adında LWF'nin biraz değışmiş hali olan özniteliğı önermiştir. Bu öznitelikte AWF değeri, her şeridin alanının yaprağın tüm alanına (piksel değerleri toplamı) oranı hesaplanarak elde edilmektedir.

Yaprak tanıma probleminin dışında, Hsu (2007) çalışmasında hiperspektral görüntülerin sınıflandırılması amacıyla dalgacık tabanlı öznitelik çıkarma yöntemlerini, Yadav et al. (2015)'teki çalışmasında, ahşapların sınıflandırılmasında dalgacık dönüşümü tabanlı çok çözünürlüklü çeşitli yerel ikili örüntülerden oluşan doku özniteliklerini kullanmıştır. Fu et al. (2014), kolorektal poliplerin sınıflandırılması amacıyla dokusal eş oluşum matrislerinden, uzaysal alanda şekil ve pencere tabanlı özniteliklerden ve spektral alanda kosinüs dönüşümü özniteliklerinden yararlanmıştır.

İlgilenilen görüntü bölgesinden (Region of Interest) (ROI) öznitelik çıkarma dışında oransal ve alt bölgelere, bölümlmeye dayalı özniteliklerin çıkartılarak sistemin tanıma performansında artış sağlandığı görülmektedir. Vamvakas et al. (2009) yaptığı çalışmada, tarihsel makine baskılı ve el yazısı karakterlerini tanımak amacıyla karakter görüntülerinin özyinelemeli alt bölümlenmesine dayalı yeni bir öznitelik çıkarma yöntemi geliştirmiş, farklı granülerite düzeylerinde hiyerarşik sınıflandırma performansının, literatürdeki o ana kadar elde edilmiş en iyi durumdan daha başarılı olduğunu gözlemlemiştir. Çiçek açan bitkilerde, çiçeklerin radyal olarak açması ve merkezi simetrik özelliklerinin bulunması nedeniyle bölgesel özniteliklerin çıkartılması önem taşımaktadır. Pei and Cao (2010), çiçek görüntülerini belirli oranlarda dairesel alt bölgelere ayırmış, bu alt bölgelerdeki bağlantılı bileşen sayısını, ana renk bileşenini ve dokusal eş oluşum matrislerini kullanarak çeşitli öznitelikler çıkartmıştır. Az sayıda fakat ayırt edicilik yeteneğı yüksek öznitelikleri kullanarak diğer çalışmalara göre daha yüksek bir başarı oranı elde etmiştir. Mohammadi et al. (2012), şekil ve

doku bilgilerine dayalı özgün öznitelikler çıkarmış ve bu özniteliklerin tıbbi X ışını görüntüleri üzerinde sınıflandırma başarısını yükselttiğini gözlemlemiştir.

Varolan öznitelikler kümesi üzerinde birtakım yaklaşımlar uygulanarak yeni özniteliklerin elde edilmesi işlemi öznitelik oluşturma olarak tanımlanmaktadır (Markovitch and Rosenstein, 2002). Bu yaklaşımlar; veri güdümlü, hipotez güdümlü, bilgi tabanlı veya hibrit olabilmektedir (Motoda and Liu, 1998). Öznitelik oluşturma da öznitelik çıkarma kapsamında değerlendirilmektedir.

Derin öğrenme kapsamında Liu et al. (2016), evrişimsel sinir ağları kullanarak ve orta düzeyde öznitelik kapsamında derin kanal özniteliklerini otomatik olarak öğrenerek, çıkarılan öznitelikleri yaya tespitinde kullanmıştır. Chen et al. (2017) derin konvolüsyonel sinir ağları ile SVM ve AdaBoost sınıflandırıcıları kullanarak gülümseme tespitinde çıkarılan özniteliklerle %90'ın üzerinde bir oranla başarı sağlamıştır.

Donahue et al. (2014), derin evrişimsel sinir ağları üzerinden çıkarılan aktivasyon özniteliklerini yarı denetimli çoklu görevli, genel amaçlı görsel tanıma uygulamalarında kullanılmak üzere analiz etmişlerdir. Bu kapsamda, Caltech-101 görüntü veriseti üzerinde derin evrişimsel sinir ağının farklı sıradaki gizli katmanlarından gelen aktivasyon değerleri kullanılarak %86.91'lik doğruluk oranına ulaşmışlardır. Lazebnik et al. (2006) görüntüleri alt bölgelere bölümleyerek ve her bir alt bölgeden çıkarılan özniteliklerin histogramını bularak sahne sınıflarının tanınmasını sağlayan bir yöntem önermişlerdir. Kenar (zayıf) ve SIFT (güçlü) öznitelikleri kullanarak Caltech-101 verisetinde %64.6'lık doğruluk oranı elde etmişlerdir.

Zhang et al. (2007) çalışmasında SIFT, SPIN ve RIFT özniteliklerini kullanarak farklı verisetleri üzerinde etkili sonuçlar almıştır. Büyük ölçekli görüntü verilerinin sınıflandırılmasında şekil bilgilerine dayalı HOG (histogram of oriented gradients) ve doku bilgilerine dayalı LBP özniteliklerinin birlikte kullanımı ve Hadoop şeması ile paralel olarak işlemlerin gerçekleştirildiği bir çalışma Lin et al. (2011) tarafından sunulmuştur.

Derin öğrenmenin tıp alanında yapılan çalışmalarda da kullanımı benimsenmiştir. Mamografi görüntülerinde kitle lezyonlarının sınıflandırılmasında (Arevalo et al., 2016), histolojik ve histopatolojik görüntülerde doku

sınıflandırmada (Cruz-Roa et al. 2013), Alzheimer hastalığının tanılanmasında (Suk et al., 2014), glokom göz hastalığının tespitinde (Abbas, 2017), akciğer nodüllerinin sınıflandırılmasında (Wang et al., 2017) derin öğrenmeden yararlanılmıştır.

Derin öğrenme ile özniteliklerin otomatik keşfine ve manuel olarak çıkarılan özniteliklerle ortak kullanımına dair de çeşitli çalışmalar yapılmıştır. Ghazi et al. (2017) geleneksel makine öğrenmesinde kullanılan manuel öznitelik çıkarma yöntemlerinin yerine derin öğrenme ile yüksek düzeyde artan biçimde özniteliklerin otomatik keşfini sağlayarak LifeCLEF 2015 veriseti üzerinde %80 oranında tanıma performansı sağlamıştır. Taşcı and Uğur (2018) çalışmasında CIFAR-10 veriseti üzerindeki görüntülerde derin öğrenme özniteliğine ilave olarak 4 adet manuel öznitelik kullanmıştır. Çuğu et al. (2017), Hall et al. (2015) çalışmalarında, yaprak görüntü türlerinin sınıflandırılmasında; Jin and Gao (2014) çalışmasında renkli ve derinlik içeren görüntülerde (Red Green Blue – Depth) (RGB-D) nesne tanımda, derin öğrenme ve uzman bilgisi dahilinde çıkarılan manuel özniteliklerin birlikte kullanımını sağlayarak hem manuel hem de derin öğrenme ile öznitelik çıkarma yönteminin ayrı ayrı kullanımından daha başarılı tanıma sonuçları elde etmişlerdir.

Öznitelik çıkarma ve seçiminin, verilerin boyutunun indirgenmesi, hesaplama, depolama ve zaman maliyetinin azaltılması, sınıflandırıcının tahminleme performansının artırılması ve genelleştirebilme yeteneğinin iyileştirilmesi, eğitim süresinin kısaltılması, verilerin görselleştirilmesinin ve anlaşılmasının kolaylaştırılması gibi önemi, amacı ve katkıları bulunmaktadır. İnternet belgelerinde metin işlemede, gen ifadesi dizi analizinde, kombinasyonel kimya problemlerinde bu konularda çalışmalar yapılmaktadır (Guyon and Elisseeff, 2003). Farklı sınıfları ayırt edebilme niteliği yüksek özniteliklerin seçilmesi, geliştirilecek tanıma/sınıflandırma sisteminin performansının artırılması açısından önemlidir.

Öznitelik seçim işlemi aşamalarından birisi olan öznitelik altkütmesi üretiminde (feature subset generation) kullanılan arama stratejileri, tam (complete), ardışık (sequential) ve rastgele (randomized) olmak üzere 3 sınıfa ayrılmıştır (Dash and Liu, 1997; Liu and Yu, 2005; Xue et al., 2016). Her bir arama stratejisi için literatürde çeşitli yöntemler önerilmiştir. Tam kapsamlı arama (exhaustive search), dallan ve sınırla (branch and bound) gibi geri izleme yapılabilen çeşitli arama

algoritmaları tam arama stratejileri için kullanılmıştır (Jović et al., 2015; Dash and Liu, 1997). Ardışık arama stratejileri için ardışık ileriye doğru seçim, ardışık geriye doğru eliminasyon gibi özniteliklerin her bir iterasyonda ardışık olarak eklenmesi veya çıkarılmasına göre işlem gören altopimal yöntemler önerilmiştir. Rastgele arama algoritmaları için ise rastgele başlangıçlı tepe tırmanma (random restart hill climbing) (RR-HC), benzetimli tavlama (simulated annealing) (SA), Las Vegas algoritması (Liu and Yu, 2005), genetik algoritmalar Zhuo et al. (2008), genetik programlama (genetic programming) (GP) (Xue et al., 2016), parçacık sürü optimizasyonu (particle swarm optimization) (PSO), karınca kolonisi optimizasyonu (ant colony optimization) (ACO) Stein et al. (2005) gibi optimal çözümü bulmayı amaçlayan evrimsel, popülasyon tabanlı arama yöntemleri literatüre sunulmuştur (Gnana et al., 2016).

Dash and Liu (1997) çalışmasında öznitelik seçimindeki değerlendirme kriterlerini; uzaklık, bilgi veya belirsizlik, bağımlılık, tutarlılık ve sınıflandırıcı hata oranı olmak üzere 5 farklı kategoriye ayırmıştır. Jović et al., (2015) çalışmasında ise bu kategoriler bilgi, uzaklık, tutarlılık, benzerlik ve istatistiksel olmak üzere 5 adettir.

Öznitelik seçiminde, değerlendirme kriteri olarak filtre yönteminin kullanıldığı çalışmalar da kendi içinde her bir özneliğin ayrı olarak değerlendirildiği **tek değişkenli filtre (univariate filter)** ve tüm özniteliklerin birarada, kendi aralarındaki bağımlılıklarında dikkate alındığı **çok değişkenli filtre (multivariate filter)** olmak üzere 2 alt kategoriye ayrılmaktadır (Saeys et al., 2007).

Tek değişkenli filtre kapsamında, Hoque et al. (2014) karşılıklı bilgiye (mutual information) (MI) dayalı öznitelik seçim yöntemini sunmuştur. Karşılıklı bilgi, öznitelikler arası ve öznitelikler ile hedef sınıf arasındaki bilgi kazancını (information gain) (IG) hesaplamaktadır. Mani and Kalpana (2016), bilgi kazancındaki eğilimi ortadan kaldırmak için simetrik olmayan, entropi tabanlı, tek değişkenli filtre yöntemi olan kazanç oranını (gain ratio) değerlendirmiştir. Ayrıca, bilgi tabanlı simetrik belirsizlik (symmetric uncertainty) yöntemi, istatistiksel tabanlı ki-kare (chi-square), korelasyon (correlation) ve Fisher skoru (Fisher score) yöntemleri, uzaklık tabanlı Relief ve ReliefF yöntemleri gibi çeşitli tek değişkenli filtre tabanlı seçim yöntemleri önerilmiştir (Jović et al., 2015).

Çok değişkenli filtre kapsamında ise, literatürde minimum Redundancy and maximum Relevance (mRmR), tutarsızlık kriteri (inconsistency criterion) (Liu and Setiono, 1996), korelasyon tabanlı öznitelik seçimi, hızlı korelasyon tabanlı filtre yöntemi (Yu and Liu, 2003) gibi çeşitli yöntemler önerilmiştir (Jović et al., 2015).

Maldonado and Weber (2009) çalışmasında, SVM sınıflandırıcısı ile ardışık geriye doğru seçim yöntemi kullanarak özgün bir **sarmalayıcı** yöntem önermiştir. En iyi öznitelik alt kümesinin seçilmesi, sınıflandırma hata oranı değerlendirme kriteriyle sağlanmıştır. Literatürdeki sarmalayıcı, gömülü ve hibrit yöntemler için yapılan çalışmalar ayrıntılı olarak Kumar and Minz (2014), Gnana et al. (2016)'den incelenebilir.

5. GELİŞTİRİLEN SİSTEM

5.1 Giriş

Bu bölümde, geliştirilen çerçevenin mimarisi ve alt modellerden bahsedilmiş, tez kapsamında ele alınan görüntüye dayalı problemler, bu problemler için kullanılan veri setleri, görüntü önileme, öznitelik çıkarma, öznitelik seçim ve sınıflandırma aşamaları hakkında bilgi verilmiş, bu aşamalarda yapılan çalışmalar ve işlemler alt bölümlerde açıklanmıştır.

5.2 Geliştirilen Çerçevenin Mimarisi


Tez kapsamında önerilen örüntü tanıma mimarisi Şekil 5.1’de gösterilmiştir. Mimariyi test etmek için iki farklı alanda uygun veriseti belirlenmiştir. Bu sistemde önce veriseti üzerinde gerekli önilemler yapılmakta, sırası ile öznitelik çıkarımı ve seçim yöntemi uygulanmakta ve son aşamada sınıflandırma gerçekleştirilmektedir. Tez sürecinde en çok önem verilen alt alan öznitelik çıkarma aşamasıdır. Manuel olarak çıkarılan temel ve özgün öznitelikler kümesinin sistemin tanıma/sınıflandırma performansına etkisi gözlemlenmiş, uygun olanlar ile çerçeve güncellenmiştir.



Şekil 5.1: Önerilen örüntü tanıma mimarisi

5.3 Geliştirilen Örüntü Tanıma Çerçevesi


Tez çalışmasında geliştirilen örüntü tanıma çerçevesi, Şekil 5.2’de ve Şekil 5.3’te gösterilmektedir. Örüntü tanıma çerçevesi, öznitelik çıkarma ve öznitelik seçim aşamalarından oluşmaktadır. Öznitelik çıkarma bölümü, görüntüler üzerinden çıkarılan iki farklı öznitelik türünü desteklemektedir: Manuel olarak ve derin öğrenme ile çıkarılan öznitelikler.



Şekil 5.2: Geliştirilen örüntü tanıma çerçevesi, alt model-1

Şekil 5.2’de yer alan çerçeve, görüntülerden sadece uzman bilgisi ile çıkarılan 194 adet öz nitelik ve bu öz nitelikler arasında seçim işlemi uygulanması sonucu elde edilen indirgenmiş, seçilen manuel öz nitelik kümesinden oluşan ilk modeli kullanmaktadır.

Şekil 5.3’te yer alan örüntü tanıma çerçevesi ise görüntülerden seçilen manuel öz nitelikleri ve CNN derin öğrenme modeli ile çıkarılan 4096 adet öz niteliği içeren ikinci modeli dikkate almaktadır. Derin öğrenmeyle çıkarılan öz nitelikler üzerinde öz nitelik seçim işlemi uygulanmamakta, sadece manuel öz nitelikler üzerinde seçim gerçekleştirilmektedir.



Şekil 5.3: Geliştirilen örüntü tanıma çerçevesi, alt model-2

5.4 Uygulaması Gerçekleştirilen Alanlar

Tez sürecinde uygulamaya geçilmesi açısından, ilk olarak örnek çalışma konusu araştırılmıştır. Bu süreçte yapılan araştırmalar sonucunda görüntü tanıma – sınıflandırma problemleri incelenmiş, karakter tanımadan hastalık tanımaya, parmak izi tanımadan, bitki, hayvan türlerinin sınıflandırılmasına kadar çeşitli problem türlerine rastlanmıştır. Tez çalışmasında, görüntü işleme aşamasından ziyade öznitelik çıkarma aşamasına odaklanıldığından, görüntü ön işleme aşamasının karmaşık olmadığı ya da önceden referans bölgesi (ground truth) hazır olarak belirlenmiş problem türleri üzerinde durulmuştur.

Tez kapsamında, 2 farklı alanda uygulama gerçekleştirilmiştir. İlk olarak, yaprak görüntülerini içeren veriseti üzerinde yaprak tanıma işlemi yapılmıştır. İkinci olarak ise farklı kategorilere sahip nesneleri içeren resimlerden oluşan veriseti üzerinde görüntü tanıma işlemi gerçekleştirilmiştir.

Alt bölümlerde, uygulama alanları, görüntülerin elde edilmesi ve görüntü ön işleme aşamasına ilişkin ayrıntılı bilgiler verilmektedir.

5.4.1 Flavia Veriseti: Yaprak tanıma


Tez kapsamında, ilk örnek çalışma olarak **yaprak tanıma** problemi ele alınmıştır. Yaprak tanıma, bir yaprağın önceden bilinen çeşitli sayıda yaprak görüntü türleri arasından hangi türe ait olduğunun sınıflandırılması işlemidir. Yaprak tanıma, bu sürecin otomatikleştirilmesi, hızlandırılması açısından önem taşımaktadır.

Görüntünün Elde Edilmesi

Yaprak tanıma sisteminin geliştirilmesi için öncelikle yaprak görüntülerinden oluşan bir veri setinin elde edilmesi gerekmektedir. Verisetinin literatürde hazır olarak bulunması, bu alanlarda çalışan araştırmacıların aynı süreç sonunda alabilecekleri sonuçları karşılaştırabilmeleri, daha gerçekçi ve anlamlı bilimsel sonuçlar elde edebilmeleri açısından önem taşımaktadır. Bu süreçte, 32 yaprak türünden oluşan 1907 adet örnek yaprak görüntüsü içeren **FLAVIA** yaprak veri seti kullanılmıştır (Wu et al., 2007a; 2007b).

Flavia veri setindeki her yaprak görüntüsü 1600 * 1200 piksel çözünürlüğündedir. 32 farklı yaprak türü için her türe ilişkin 1 örnek görüntü Şekil 5.4'te gösterilmiştir. Verisetindeki görüntüler incelendiğinde tüm yaprakların

beyaz renkte bir arkaplana sahip olduđu, yapraklarda yeşil rengin ağırlıklı olduđu, aynı türdeki yapraklardan farklı yön ve doğrultuda kayıtlı olanların da bulunduđu anlaşılmaktadır.



Şekil 5.4: FLAVIA yaprak veri seti için her yaprak türüne ilişkin örnek görüntüler (Wu et al., 2007a; 2007b).

Flavia verisetindeki her bir yaprak görüntüsünün ait olduđu tür bilgisi ve bu türdeki yaprak görüntülerinin numaraları Çizelge 5.1’de gösterilmiştir.

Çizelge 5.1: Flavia yaprak görüntü tür bilgilerini ve ilgili görüntü numaralarını gösteren çizelge (Wu et al., 2007b).

Sınıf Etiketi	Bilimsel Adı	Yaygın İsim	Dosya Adı
1	<i>Phyllostachys edulis</i> (Carr.) Houz.	pubescent bamboo	1001-1059
2	<i>Aesculus chinensis</i>	Chinese horse chestnut	1060-1122
3	<i>Berberis anhweiensis</i> Ahrendt	Anhui Barberry	1552-1616
4	<i>Cercis chinensis</i>	Chinese redbud	1123-1194
5	<i>Indigofera tinctoria</i> L.	true indigo	1195-1267
6	<i>Acer Palmatum</i>	Japanese maple	1268-1323
7	<i>Phoebe nanmu</i> (Oliv.) Gamble	Nanmu	1324-1385
8	<i>Kalopanax septemlobus</i> (Thunb. ex A.Murr.) Koidz.	castor aralia	1386-1437
9	<i>Cinnamomum japonicum</i> Sieb.	Chinese cinnamon	1497-1551
10	<i>Koelreuteria paniculata</i> Laxm.	goldenrain tree	1438-1496
11	<i>Ilex macrocarpa</i> Oliv.	Big-fruited Holly	2001-2050
12	<i>Pittosporum tobira</i> (Thunb.) Ait. f.	Japanese cheesewood	2051-2113
14	<i>Chimonanthus praecox</i> L.	wintersweet	2114-2165
15	<i>Cinnamomum camphora</i> (L.) J. Presl	camphortree	2166-2230
16	<i>Viburnum awabuki</i> K.Koch	Japan Arrowwood	2231-2290
17	<i>Osmanthus fragrans</i> Lour.	sweet osmanthus	2291-2346
18	<i>Cedrus deodara</i> (Roxb.) G. Don	deodar	2347-2423
19	<i>Ginkgo biloba</i> L.	ginkgo, maidenhair tree	2424-2485
20	<i>Lagerstroemia indica</i> (L.) Pers.	Crape myrtle, Crepe myrtle	2486-2546
21	<i>Nerium oleander</i> L.	oleander	2547-2612
22	<i>Podocarpus macrophyllus</i> (Thunb.) Sweet	yew plum pine	2616-2675
23	<i>Prunus serrulata</i> Lindl. var. <i>lannesiana</i> auct.	Japanese Flowering Cherry	3001-3055
24	<i>Ligustrum lucidum</i> Ait. f.	Glossy Privet	3056-3110
25	<i>Tonna sinensis</i> M. Roem.	Chinese Toon	3111-3175
26	<i>Prunus persica</i> (L.) Batsch	peach	3176-3229
27	<i>Manglietia fordiana</i> Oliv.	Ford Woodlotus	3230-3281
28	<i>Acer buergerianum</i> Miq.	trident maple	3282-3334
29	<i>Mahonia bealei</i> (Fortune) Carr.	Beale's barberry	3335-3389
30	<i>Magnolia grandiflora</i> L.	southern magnolia	3390-3446
31	<i>Populus ×canadensis</i> Moench	Canadian poplar	3447-3510
32	<i>Liriodendron chinense</i> (Hemsl.) Sarg.	Chinese tulip tree	3511-3563
33	<i>Citrus reticulata</i> Blanco	tangerine	3566-3621

Flavia verisetinde bulunan 32 farklı sınıf içindeki toplam 1907 yaprak görüntüsünde, türler arası görüntü sayısı farklılık göstermektedir. Sınıflara ilişkin görüntü sayıları Çizelge 5.2’de gösterilmektedir. Bu çizelgeye göre, en yüksek görüntü sayısı 77 görüntüyle 18 numaralı sınıfta, en düşük görüntü sayısı ise 50 görüntüyle 11 numaralı sınıfta bulunmaktadır.

Çizelge 5.2: Flavia verisetindeki farklı sınıflara ait görüntü sayıları


Sınıf Numarası	Görüntü Sayısı	Sınıf Numarası	Görüntü Sayısı
1	59	18	77
2	63	19	62
3	65	20	61
4	72	21	66
5	73	22	60
6	56	23	55
7	62	24	55
8	52	25	65
9	55	26	54
10	59	27	52
11	50	28	53
12	63	29	55
14	52	30	57
15	65	31	64
16	60	32	53
17	56	33	56

Görüntü Önleme Aşaması

Bu aşama, yaprak görüntüleri üzerinde öznelilik çıkarmadan önce görüntü kalitesinin artırılarak bilgisayarda işlenmeye, öznelilik çıkarmaya uygun duruma getirilmesi için yapılan bir dizi işleme dayanır. Bu işlemler, temel görüntü işleme teknikleri içinde yer alan filtreleme, gürültülerin ve istenmeyen bölgelerin giderilmesi, istenilen bölgelerin belirginleştirilmesi gibi görüntü iyileştirme

işlemleri, açma, kapama, aşındırma ve genişletme gibi yöntemleri içeren morfolojik işlemlerdir.

Tez kapsamında, öncelikle FLAVIA verisetindeki renkli yaprak görüntüleri gri tonlamalı görüntülere dönüştürülmüştür. Ardından medyan filtresi uygulanarak gürültüler temizlenmiş, düzgünleştirme işlemi yapılmıştır. Gri renk uzayına dönüştürülmüş ve gürültüsü giderilmiş görüntü üzerinde kırpma işlemi uygulanarak görüntüdeki ufak parçalar giderilmeye çalışılmıştır (Şekil 5.5). (Ulutürk and Uğur, 2012)




Şekil 5.5: Görüntü ön işleme aşamaları (a) RGB görüntü, (b) Gri tonlamalı görüntü, (c) Medyan filtreli görüntü, (d) Kırpılmış görüntü (e) Otsu eşikleme siyah-beyaz görüntü

Kırpılan gri tonlamalı görüntü üzerinde Otsu eşikleme yöntemi (Otsu, 1979) uygulanarak görüntü siyah beyaz formata çevrilmiştir (Şekil 7.4). Otsu eşikleme yöntemi, sınıflar arası varyansı maksimize etmeye ve sınıf içi varyansı minimize


etmeye çalışarak, önplan rengini arkaplan renginden ayırmak ve gri tonlamalı görüntüleri siyah-beyaz formata dönüştürmek için kullanılan bir görüntü eşikleme yöntemidir (Otsu, 1979). Ayrıca, etiketleme işlemi yapılarak yaprak görüntüsü arka plandan ayrıştırılmış ve arka plan görüntüsü çıkarılmıştır. Arka plandan ayrıştırılan görüntü üzerinde birden fazla parça olabilmektedir. Bu durumun önüne geçebilmek amacıyla oluşan tüm alt parçalardan en büyük alana sahip olan parça yaprak görüntüsü olarak seçilmiştir.

Görüntü ön işleme aşamasında ayrıca (Ulutürk and Uğur, 2012)'un çalışmasından yararlanılarak, yarım yaprak görüntülerinin ve özniteliklerinin çıkarılabilmesi amacıyla arkaplandan ayrılmış yaprak görüntüleri üzerinde, yaprağın oryantasyonunu dikkate alarak **doğrultma** ve **yaprağı merkez noktasından ikiye bölme** işlemi uygulanmıştır.

FLAVIA verisetindeki görüntüler, yaprak sapının farklı konumlarda ve yönlerde olma durumuna göre saklanmaktadır (Wu et al., 2007a; 2007b). Görüntülerin, saklandıkları konum ve doğrultusu nedeniyle yarım yaprak görüntülerinden öznitelik çıkarılması uygun değildir. Bu durumda, yaprak görüntülerinin sol ve sağ alt parçaları farklılaşmakta, parçalardan çıkarılan sağ ve sol parçaya dayalı oransal öznitelikler değişebilmektedir. Görüntü ön işleme aşamasında, bu problemin çözümü amacıyla yaprağın Otsu eşiklemeli siyah-beyaz görüntülerinde, yaprak sapının sol tarafta olacak şekilde **doğrultulmasını** sağlayan yazılım modülü gerçekleştirilmiş ve ardından yaprak **merkez noktasından ikiye bölünerek** sol ve sağ yaprak parçaları elde edilmiştir (Şekil 5.6 ve Şekil 5.7). Yazılım, yaprak görüntüsünü alarak, kullanıcının belirttiği açıdan döndürme işlemi yapmakta ve bu görüntüyü saklamaktadır. Döndürme işlemi **'loose'** yöntemi kullanılarak yapılmıştır, döndürülen görüntünün verilen girdi görüntüsünden daha büyük olması durumunda kırpma işlemine maruz kalmadan görüntünün oluşturulması sağlanmaktadır.



Şekil 5.6: Yaprak görüntülerini yaprak sapı sol tarafta olacak şekilde doğrultan yazılım modülünün etkisinin ekran görüntüsü



Şekil 5.7: Yarım yaprak görüntüsü önileme aşamaları (a) Doğrultma, (b) Sol Parça, (c) Sağ Parça.

Yarım yaprak görüntülerinde, sınır bölgelerinde oluşan küçük parçaların kaldırılması amacıyla, 2 birimlik yapısal eleman kullanılarak sol ve sağ yaprak parçaları morfolojik açma işlemine tabi tutulmuştur.

Bütün ve yarım yaprak görüntü bölgeleri üzerinde manuel olarak öznelilik çıkarma işlemi gerçekleştirilmiştir.

5.4.2 Caltech-101 Veriseti: Nesne sınıflandırma


Tez çalışmasında ikinci uygulama alanı olarak farklı türdeki nesnelerin (uçak, dürbün, akordeon, karınca vb.) görüntülerinin sınıflandırılması sağlanmıştır. En uygun verisetinin belirlenmesi için literatürdeki araştırmacıların kullanmış olduğu verisetleri incelenmiştir.

Görüntülerin Elde Edilmesi

Tez çalışmasında, nesne sınıflandırma amacıyla Caltech-101 verisetinden yararlanılmıştır. Caltech-101, 101 farklı kategorideki nesnelerin görüntülerini içeren, görüntülerdeki nesnelerin sınıflandırılmasını sağlayan bir verisetidir (Fei-Fei et al., 2006). Her kategori, 40 ile 80 arasında olmak üzere çoğunlukla 50’şer görüntü içermektedir. Her bir görüntü, yaklaşık 300*200 piksel çözünürlüğündedir. Görüntüler, 2003 Eylül ayında Fei-Fei Li, Marco Andreetto ve Marc 'Aurelio Ranzato tarafından toplanmıştır (Caltech Univ., 2006).

Nesnelerin bölütlenmiş kısımlarına ilişkin açıklamaların yer aldığı annotations dosyaları kullanılarak doğrudan nesnelerin bulunduğu ROI (İlgi Bölgesi) belirlenmiştir. Veriseti içindeki ROI’nin tanımlı olmadığı ‘Background_Google’ klasöründeki görüntüler ile diğer klasörlerdeki bölütleme hatalarının olduğu 4 farklı görüntü çıkarılmıştır. Tez kapsamında, 101 farklı sınıf etiketinden oluşan 8673 görüntü üzerinde çalışma yapılmıştır. Bu görüntülerde, bölütleme yapmadan ROI bölgeleri üzerinde manuel olarak öznitelik çıkarma işlemi gerçekleştirilmiştir.

Caltech-101 veriseti görüntü çeşitliliği bakımından oldukça zengindir. Caltech-101 verisetine ilişkin farklı sınıflardan alınan bazı örnek görüntüler Şekil 5.8’de gösterilmektedir.



Şekil 5.8: Caltech-101 verisetinden alınan örnek görüntüler

Görüntü Önışleme Aşaması

Görüntü önışleme aşaması, öznitelik çıkarma aşamasına geçmeden önce görüntünün gri tonlamalı veya siyah beyaz görüntüye dönüşümü, ROI (Region of Interest) (İlgi Bölgesi)’nin belirlenmesi ve görüntünün öznitelik çıkarmaya uygun hale getirilmesi için birtakım işlemleri içermektedir.

İlk olarak, tek kanal bilgilerinin kullanılarak özniteliklerin çıkartılmasını sağlamak amacıyla Caltech-101 verisetinden elde edilen görüntüler eğer renkli ise gri tonlamalı görüntüye dönüştürülmüştür.


İkinci olarak, görüntüdeki ilgi bölgelerinin tanımlı olduğu, nesnelerin bölütlenmiş kısımlarına ilişkin açıklamaların yer aldığı annotations dosyaları kullanılmıştır. Bu sayede, maskeleme işlemi yapılarak görüntüden çokgensel olarak ilgi bölgeleri siyah beyaz görüntü formatında çıkartılmıştır (Şekil 5.9). Bu sayede, görüntüler üzerinde bölütleme yapılmadan ilgi bölgelerinde manuel olarak öznitelik çıkarma işlemi gerçekleştirilebilmiştir.



(a)



(b)



(c)



(d)

Şekil 5.9: Caltech-101 veriseti görüntü önışleme aşaması (a) Renkli görüntü (b) Yüz kısmı işaretlenen renkli görüntü (c) Siyah-beyaz yüz maskesi (d) Renkli yüz maskesi

5.5 Öznitelik Çıkarma Aşaması

Yaprak tanıma ve nesne sınıflandırma örnek çalışmaları kapsamında, şekil bilgisine dayalı, doku bilgisine dayalı ve oransal, bölgesel olmak üzere 194 adet öznitelik çıkarılmayı sağlayan yöntem kullanılmış veya gerçekleştirimi yapılmıştır. Özniteliklerin çıkarılması için Matlab programındaki **regionprops** komutundan da yararlanılmıştır.

Tez çalışmasında, şekil bilgisine dayalı olarak; alan, dışbükey alan, eşdeğer çap, ana (büyük) eksen uzunluğu, küçük (ikincil) eksen uzunluğu, çevre uzunluğu, dışmerkezlilik, biçim katsayısı, ikincil eksen uzunluğunun ana eksen uzunluğuna oranı, dışbükey kabuğun çevresinin seçilen bölge çevresine oranı, dikdörtgensellik, kapsam, katılık, çevre uzunluğunun ana eksen uzunluğuna oranı öznitelikleri, merkez noktasına göre ikiye ayrılmış görüntülerden türetilen alan oranı, kapsam oranı, katılık oranı, ana eksen uzunluğu oranı, kısa eksen uzunluğu oranı, çevre oranı, dışmerkezlilik oranı öznitelikleri ile Hu momentleri, Fourier tanımlayıcıları, Zernike momentleri kullanılmıştır. Ayrıca, doku bilgisine dayalı olarak da birinci ve ikinci dereceden istatistiksel öznitelikler ile ayrık cosinüs dönüşümü, yerel ikili örüntü öznitelikleri uygulanmıştır.

Tez çalışmasında, Fourier tanımlayıcıları kapsamında 10 adet öznitelik kullanılmıştır. Bu öznitelikler normalize edilerek dönüşüm işlemlerine karşı değişmez hale getirilmiştir.

Manuel olarak elde edilen 194 özniteliğe ek olarak önceden eğitilmiş AlexNet, VGG-16 ve VGG-19 evrimsel sinir ağları ile 4096 adet derin öğrenme özneliği de ek olarak çıkartılmıştır.

5.6 Öznitelik Seçim Aşaması

Öznitelik seçim aşamasında, tez sürecinde, SFS, SBS algoritmaları ile GA'dan yararlanılmıştır. GA'dan etkili sonuçlar alınmıştır. Ayrıca, ardışık ileri yönde kayan seçim (sequential forward floating selection) (SFFS) algoritması da veriler üzerinde denenmiştir fakat çalışma hızı çok yavaş ve maliyetli olduğundan deneysel çalışmalarda kullanılmamıştır. Tez kapsamında özniteliklerin seçiminde sıra (rank) seçim yöntemi uygulanarak ata bireyler belirlenmiştir.

Öznitelik seçiminde seçilen özniteliklerle elde edilen sınıflandırma doğruluk oranı uygunluk değeri olarak kullanılmıştır. Bu kriter sınıflandırıcıya

bağımlı seçim işlemi olduğundan sarmalayıcı yöntemlerden yararlanılmıştır. Bunun için 5 katlı çapraz geçişleme yapılmıştır. Bu değer, $[0,1]$ aralığına ölçeklendirilmiştir.

Tez kapsamında genetik algoritmalara ek olarak elitizm ve en iyi birey üzerinde yerel arama algoritması da uygulanmıştır.

Tez çalışmasında, manuel olarak çıkarılan öznitelikler ile derin öğrenme ile elde edilen özniteliklerden geniş bir öznitelik kümesi oluşturulmuş, manuel olarak çıkartılan 194 öznitelik arasında sınıflandırma başarımını artırmak amacıyla öznitelik seçim işlemi gerçekleştirilmiştir. Derin öğrenme ile elde edilen öznitelikler yüksek düzeyde ayırt edici olduklarından bu öznitelikler üzerinde öznitelik seçimi uygulanmamıştır.

Geliştirilen çerçevede, öznitelik seçim aşamasında genetik algoritmaların başlangıcında 194 adet handcrafted öznitelikten %90'ı rastgele seçilmektedir. Ayrıca, çaprazlama, mutasyon ve en iyi bireylerin nesiller boyunca korunmasını sağlamak için elitizm işlemleri uygulanmıştır.

Öznitelik seçimi kapsamında, en son nesildeki en iyi birey üzerinde yerel arama algoritması uygulanarak sonucun iyileştirilmesi sağlanmıştır. Bu süreçte uygunluk değerinde bir artış olmadığında işlem sonlandırılmıştır.

Genetik algoritmalar kapsamında kullanılan parametre ve performans değerleri, deneysel sonuçlar aşamasında açıklanmaktadır.

5.7 Özniteliklerin Normalizasyonu

Yapılan çalışmada, kullanılan öznitelikler arasında derin öğrenme öznitelikleri kendi içinde anlamlı sonuçlar verdiğinden, bu öznitelikler üzerinde normalizasyon işlemi uygulanmamıştır. Bunların dışında kalan, manuel olarak çıkarılan 194 adet öznitelik değerlerinin aralıkları değişkenlik gösterebilmektedir. Bu durum sınıflandırma başarımında problemlere sebep olacağından, manuel öznitelik değerleri normalizasyon işlemine tabi tutulmuştur.

Normalizasyon işlemi için min-max normalizasyon yöntemi kullanılmış, manuel öznitelik değerleri $[-1,1]$ aralığına ölçeklendirilmiştir. $[x_{\min} \ x_{\max}]$ aralığındaki değerler $[y_{\min} \ y_{\max}]$ aralığındaki değerlere ölçeklendirilmek istendiğinde x değerinin y değerine dönüşümüne ilişkin hesaplama Eşitlik 5.1'de gösterilmektedir (MathWorks Inc., 2018).

$$y = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \cdot (y_{\max} - y_{\min}) + y_{\min} \quad (5.1)$$

Öznitelik normalizasyonu yapılırken, öncelikle veriseti eğitim ve test kümesine ayrılmıştır. Eğitim setindeki manuel her bir öznitelik değeri $[-1,1]$ aralığına ölçeklendirilmiş, test setindeki her bir manuel öznitelik verisi eğitim setindeki en küçük ve en büyük değerlerden oluşan Eşitlik 5.1’de yer alan ayarlama göre normalize edilmiştir.

5.8 Sınıflandırma Aşaması

Görüntülerin hangi kategoriye ait olduğunun tanımlanması için seçili bölgelerden çıkarılan öznitelik vektörlerinin sınıflandırılması sağlanmalıdır. Bu kapsamda, her bir görüntü üzerinde farklı sınıflandırıcı modelleri kullanılarak etiketleme işleme uygulanmıştır. Sınıflandırma başarımının ölçümünde doğruluk oranı kullanılmıştır. Kullanılan sınıflandırıcılar ise ECOC-SVM, K-NN, CT, PNN, NB, RF, AdaBoost yöntemlerinden oluşmaktadır.

5.9 Tartışma ve Sonuçlar

Bu bölümde, geliştirilen çerçevenin mimarisi ve öznitelik çerçevesi sunularak, yaprak ve nesne tanıma verisetleri üzerinde uygulanan aşamalar açıklanmıştır. İki farklı veriseti için yapılan işlemler genel olarak benzerlik göstermekte fakat görüntü ön işleme aşaması ilgilenilen görüntülerin türüne göre farklılaşmaktadır. Ayrıca, kullanılan verisetlerindeki görüntülerin ve görüntü türlerinin sayısı, çıkarılan özniteliklerin sınıflandırma aşamasına etkisi yönünden önem taşımaktadır. Öznitelik seçimi; öznitelik sayısının indirgenmesi, sınıflandırma performansının artırılması için gerekli ve önemlidir. Sınıflandırma aşamasında farklı türde sınıflandırıcıların kullanılması, sınıflandırıcıların verilerin genelleştirme performansına etkisini gözlemlemeyi sağlamaktadır.

Bu kapsamda, çıkarılan öznitelik sayısı daha da artırılarak ve sınıf etiketleriyle ilişkili öznitelikler seçilerek sınıflandırma başarımı daha iyi sonuçlar alınabilir. Öznitelik seçiminde, uygunluk fonksiyonu ayırt edici özniteliklerin belirlenmesinde önem taşıdığından etkili bir biçimde belirlenmeli, eğitim-test kümesi ayrımı sağlanmalıdır. Ayrıca, topluluk öğrenme tabanlı yöntemler bir arada kullanılması durumunda sınıflandırıcıların kalitesi iyileştirilecektir.

6. DENEYSEL ÇALIŞMALAR

Bu bölümde Flavia ve Caltech-101 verisetleri için sadece manuel olarak çıkarılan öznitelikler, sadece derin öğrenme ile çıkarılan öznitelikler, manuel olarak ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı ve öznitelik seçimi ile farklı başarımlar ölçütlerine göre elde edilen sonuçlar sunulmaktadır. Ayrıca geliştirilen çerçevenin COIL-20 ve COIL-100 verisetlerinde test sonuçları da yer almaktadır.

6.1 Deney Ortamı

Tez sürecinde, gerekli yazılımın geliştirilmesinde Matlab ortamı kullanılmıştır. Test donanımları için ise i7-8700K 3.7Ghz işlemcili 64 GB RAM ve 8 GB NVIDIA GeForce GTX 1080 ekran kartına sahip masaüstü bilgisayardan yararlanılmıştır. Kullanılan verisetleri ve verisetlerine ilişkin özellikler Bölüm 5.4.1 ve Bölüm 5.4.2’de sunulmuş olsa da ayrıntılı olarak bu bölümde de deney ortamına ait bilgiler Çizelge 6.1’de gösterilmektedir.

Öznitelik seçiminde uygunluk değerinin belirlenmesinde eğitim kümesi üzerinde 5 katlı çapraz geçişleme yapılarak doğruluk oranı hesaplanmıştır.

Çizelge 6.1: Deney ortamı

Geliştirme Ortamı	Matlab
Verisetleri	Flavia, Caltech-101
Eğitim-Test Kümesi Oranı	~9
Başarım Ölçütleri	Doğruluk oranı, özgüllük, yanlış pozitif oranı
Kullanılan Derin Öğrenme Modeli	AlexNet, VGG-16, VGG-19
Manuel Öznitelik Sayısı	194
Derin Öğrenme Öznitelik Sayısı	4096
Toplam Öznitelik Sayısı	4290

6.2 Başarım Ölçütleri

Bu bölümde tez kapsamında kullanılan başarımların ölçütleri açıklanmaktadır. İki ve çok sınıflı sınıflandırma problemlerinde kullanılan başarımların ölçütleri hakkında ayrıntılı olarak bilgi verilmektedir.

2 sınıflı bir sınıflandırma probleminde her bir örnek, p pozitif ve n negatif temsil etmek üzere {p,n} kümesinden bir etikete eşlenmektedir. Gerçek sınıf ve tahminlenen sınıfı ayırt etmek amacıyla tahminlenen sınıflarda Y, N harfleri kullanılmaktadır (Fawcett, 2006). Buna göre, 4 farklı durum ortaya çıkmaktadır. Verilen örnek pozitif ve tahminlenen sınıf pozitif ise gerçek pozitif (True Positive) (TP), verilen örnek pozitif ve tahminlenen sınıf negatif ise yanlış negatif (False Negative) (FN), verilen örnek negatif ve tahminlenen sınıf pozitif ise yanlış pozitif (False Positive) (FP) ile verilen örnek negatif ve tahminlenen sınıf negatif ise gerçek negatif (True Negative) (TN) olarak kabul edilmektedir. Bu durumlar hata matrisinde (confusion matrix) gösterilmektedir (Şekil 6.1).

Gerçek Sınıf - Tahminlenen Sınıf	p	n
Y	Gerçek Pozitif (TP)	Yanlış Pozitif (FP)
N	Yanlış Negatif (FN)	Gerçek Negatif (TN)
Sütun Toplamı	P	N

Şekil 6.1: Hata Matrisi (Fawcett, 2006)

Şekil 6.1'deki hata matrisinden birtakım başarımların ölçütleri çıkartılabilmektedir. Gerçek pozitif oranı (True Positive Rate) (TPR), yanlış pozitif oranı (False Positive Rate) (FPR), kesinlik (Precision), hassasiyet (duyarlılık) (recall), özgüllük (specificity) (True Negative Rate) (TNR), doğruluk oranı (accuracy), F-ölçütü (F-measure) gibi kriterler Eşitlik 6.1'de gösterilmektedir (Fawcett, 2006).

$$\begin{aligned}
 TPR &= \frac{TP}{P} & FPR &= \frac{FP}{N} & Precision &= \frac{TP}{TP + FP} & Recall &= \frac{TP}{P} \\
 Specificity &= TNR = \frac{TN}{N} = \frac{TN}{TN + FP} \\
 Accuracy &= \frac{TP + TN}{P + N} & F - measure &= \frac{2}{1/precision + 1/recall} & & & (6.1)
 \end{aligned}$$

Çok sınıflı sınıflandırma işlemlerinde uygulanan ölçütler sınırlıdır ve genel sınıflandırma işleminin kalitesi makro-ortalama ve mikro-ortalama hesaplamaları ile belirlenmektedir (Sokolava and Lapalme, 2009). Bunun için, ortalama doğruluk oranı, hata oranı, kesinlik, recall ve F-skor değerleri gibi ölçütler uygulanmaktadır. Her sınıf C_i için tp_i , tn_i , fp_i , fn_i , $Accuracy_i$, $Precision_i$, $Recall_i$ değerleri hesaplanmaktadır. Makro-ortalamada her bir C_i sınıfı için aynı ölçütlerin ortalaması alınarak hesaplama yapılırken, mikro-ortalamada kümülatif biçimde tp , tn , fp , fn değerleri hesaplanıp başarımlı ölçütünün değeri belirlenmektedir (Sokolava and Lapalme, 2009). Makro-ortalama bütün sınıflara eşit oranda davranmakta, mikro-ortalama büyük sınıflar lehine çalışmaktadır (Sokolava and Lapalme, 2009).

Makro-ortalama ile tp , fp , fn değerlerinin farklı sınıflar için 0 değeri çıkabilmesinden dolayı, işlem yapıldığında sıfıra bölme hatası alınabilmektedir. Mikro-ortalama, farklı sınıflardan çeşitli boyutlarda örnekler bulunduğunda uygun bir ölçüttür. Mikro-ortalama ile hesaplama yapıldığında doğruluk oranı, kesinlik, hassasiyet, F-ölçütü değerleri birbirine eşit çıkmaktadır (PyActLearn, 2018). Tez kapsamında mikro-ortalama ile deneysel sonuçlar alınmıştır. 4 farklı ölçütün eşit çıkmasından dolayı sadece doğruluk oranı çizelgelerde belirtilmiştir.

6.3 Parametre Değerleri

Bu bölümde, öznitelik çıkarma ve seçimi ile sınıflandırıcılarda kullanılan parametre değerleri hakkında bilgi verilmekte, parametrelerin belirlenmesinde hangi durumlardan yararlanıldığı açıklanmaktadır.

6.3.1 Öznitelik çıkarmada kullanılan parametre değerleri

Tez kapsamında, 32 adet Zernike moment öznitelik çıkarmada kullanılmıştır. Kullanılan öznitelikler için Tahmasbi et al. (2011)'den yararlanılmıştır. Bu aşamada 32 adet düşük dereceli Zernike momentleri kullanılmış olup, uygulanan n derece ve m tekrarlama değerleri Çizelge 6.2'de ve değerlerin özellikleri Eşitlik 6.1'de gösterilmektedir.

$$\{Z_{n,m}\} \forall \begin{cases} 3 \leq n \leq 10 \\ m \leq n \\ n - m = 2k \\ k \in \mathbb{N} \end{cases} \quad (6.1)$$

Çizelge 6.2: Zernike moment için kullanılan n ve m değerleri (Tahmasbi et al., 2011)

n	m
3	1, 3
4	0, 2, 4
5	1, 3, 5
6	0, 2, 4, 6
7	1, 3, 5, 7
8	0, 2, 4, 6, 8
9	1, 3, 5, 7, 9
10	0, 2, 4, 6, 8, 10

DCT ile öznitelik çıkarma sürecinde, ilk 50, 100 ve 150 katsayı için yapılan denemeler ile en iyi doğruluk oranı 50 katsayı için sağlanmıştır ve bu nedenle DCT ile 50 adet öznitelik çıkartılmıştır.

6.3.2 Öznitelik seçiminde genetik algoritmalar için kullanılan parametre değerleri

Öznitelik seçiminde etkili deneysel sonuçların alınmasında genetik algoritmalarından yararlanılmıştır. Genetik algoritma kapsamında kullanılan parametre değerleri Çizelge 6.3'te gösterilmektedir. Çizelge 6.3'te bulunan P_c çaprazlama oranını, P_m ise mutasyon oranını belirtmektedir. Ayrıca, 1 ve 2 değerlerini içeren 2 farklı seed değeri öznitelik seçiminde kullanılmıştır. Rastgele sayıların üretiminde Mersenne twister üretici algoritması yer almaktadır.

Çizelge 6.3: Öznitelik seçiminde GA için kullanılan parametre değerleri

Çaprazlama Türü	Seçim Yöntemi	Birey Sayısı	Nesil Sayısı	Seçkin Birey Sayısı	P_c	P_m
Tek Noktalı	Rank	15	10	1	0.8	0.1

6.3.3 Sınıflandırıcılarda kullanılan parametre değerleri

Tez sürecinde; ECOC-SVM, NB, K-NN, PNN, CT, RF ve AdaBoost sınıflandırma modelleri uygulanmıştır. ECOC-SVM modelinde, çoklu sınıflandırma işlemi için OVA kodlama tasarımı kullanılmıştır. Bu tasarımla,

sınıflardan birisi (+) kabul edilirken diğer sınıflar (-) kabul edilerek sınıflandırma işlemi yapılmaktadır. Yeni bir örnek, en yüksek sınıflandırma çıktısı veren sınıfa atanmaktadır.

Bu kapsamda, K-NN, P-NN, RF ve AdaBoost sınıflandırıcıları için kullanılan parametre değerleri Çizelge 6.4'te sunulmaktadır. Çizelge 6.4'te yer alan değerler, farklı denemeler sonucunda elde edilmiştir ve başarılı sonuçlar verdiği için seçilmiştir.

Çizelge 6.4: Sınıflandırıcılarda kullanılan parametre değerleri

Sınıflandırıcı	Parametre Adı	Parametre Değeri
K-NN	k	1
P-NN	s (spread)	15
RF	Ağaç sayısı	50, 100, 150
AdaBoost	Ağaç Sayısı	100

6.4 Flavia Veriseti için Elde Edilen Sonuçlar

Flavia yaprak tanıma görüntü veriseti için farklı öznitelik türlerinin kullanımına ve öznitelik seçiminin uygulanmasına ilişkin deneysel sonuçlar bu bölümde sunulmaktadır.

6.4.1 Sadece manuel olarak çıkarılan öznitelikler ile elde edilen deneysel sonuçlar

Flavia veriseti üzerinde sadece manuel olarak çıkarılan öznitelikler kullanıldığında elde edilen deneysel sonuçlar Çizelge 6.5'te gösterilmektedir.

Çizelge 6.5: Flavia verisetinde sadece manuel olarak çıkarılan öznitelikler ile elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	95.16	99.84	0.16
RF (n=100)	96.24	99.88	0.12
RF (n=150)	96.24	99.88	0.12
ECOC-SVM	97.85	99.93	0.07
K-NN (k=1)	96.24	99.88	0.12
CT	87.10	99.58	0.42
AdaBoost (n=100)	94.09	99.81	0.19
PNN (s=15)	29.03	97.71	2.29

Çizelge 6.5’deki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM modelinden elde edildiği, %97.85’lik doğruluk oranına, %99.93’lük özgüllük oranına ve %0.07’lik yanlış pozitif oranına sahip olduğu gözlemlenmektedir.

6.4.2 Sadece derin öğrenme öznitelikleri ile elde edilen deneysel sonuçlar

Flavia veriseti üzerinde sadece derin öğrenme öznitelikleri kullanıldığında elde edilen deneysel sonuçlar bu bölümde sunulmaktadır. Derin öğrenme öznitelikleri çıkartılırken AlexNet, VGG-16 ve VGG-19 CNN modellerinden yararlanılmıştır. Bu modellerin FC6 ve FC7 katmanlarından ayrı ayrı 4096 adet öznitelik çıkartılmıştır.

3 tür CNN modelinin 2 farklı katmanından elde edilen öznitelikler için alınan sonuçlar alt başlıklar ile açıklanmaktadır.

AlexNet CNN Modeli – FC7 Katmanı

Flavia veriseti üzerinde sadece derin öğrenme öznitelikleri kullanıldığında AlexNet CNN modeli ve FC7 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.6’da gösterilmektedir.

Çizelge 6.6: Flavia verisetinde sadece derin öğrenme öznitelikleri ile AlexNet CNN modeli ve FC7 katmanından elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	96.77	99.90	0.10
RF (n=100)	97.85	99.93	0.07
RF (n=150)	98.39	99.95	0.05
ECOC-SVM	99.46	99.98	0.02
K-NN (k=1)	98.93	99.97	0.03
CT	84.40	99.50	0.50
AdaBoost (n=100)	96.77	99.90	0.10
PNN (s=15)	98.93	99.97	0.03

Çizelge 6.6'daki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM modelinden elde edildiği, %99.46'lık doğruluk oranına, %99.98'lik özgüllük oranına ve %0.02'lik yanlış pozitif oranına sahip olduğu gözlemlenmektedir.

Flavia veriseti üzerinde, AlexNet CNN modeli ile FC7 katmanından gelen derin öğrenme öznitelikleri kullanımının sadece manuel olarak uzman bilgisiyle öznitelik çıkarımına göre sınıflandırıcıların büyük çoğunluğunda daha iyi başarımlar verdiği sonucuna varılmıştır.

AlexNet CNN Modeli – FC6 Katmanı

Flavia veriseti üzerinde sadece derin öğrenme öznitelikleri kullanıldığında AlexNet CNN modeli ve FC6 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.7'de gösterilmektedir.

Çizelge 6.7: Flavia verisetinde sadece derin öğrenme öznitelikleri ile AlexNet CNN modeli ve FC6 katmanından elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	96.77	99.90	0.10
RF (n=100)	97.85	99.93	0.07
RF (n=150)	97.85	99.93	0.07
ECOC-SVM	100.00	100.00	0.00
K-NN (k=1)	100.00	100.00	0.00
CT	88.71	99.64	0.36

Çizelge 6.7’deki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM ve K-NN modelinden elde edildiği, %100.00’lık doğruluk oranına, %100.00’lık özgüllük oranına ve %0.00’lık yanlış pozitif oranına sahip olduğu gözlemlenmektedir.

Flavia veriseti üzerinde, AlexNet CNN modeli ile FC6 katmanından gelen derin öğrenme öznitelikleri kullanımının sadece manuel olarak uzman bilgisiyle öznitelik çıkarımına göre daha iyi başarımlar verdiği sonucuna varılmıştır. Ayrıca bu model ve katmanla elde edilebilecek en iyi sonuca ulaşılmıştır.

VGG-16 CNN Modeli – FC7 Katmanı

Flavia veriseti üzerinde sadece derin öğrenme öznitelikleri kullanıldığında VGG-16 CNN modeli ve FC7 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.8’de gösterilmektedir.

Çizelge 6.8: Flavia verisetinde sadece derin öğrenme öznitelikleri ile VGG-16 CNN modeli ve FC7 katmanından elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	97.85	99.93	0.07
RF (n=100)	97.85	99.93	0.07
RF (n=150)	97.31	99.91	0.09
ECOC-SVM	98.93	99.97	0.03
K-NN (k=1)	97.85	99.93	0.07
CT	81.72	99.41	0.59

Çizelge 6.8’deki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM modelinden elde edildiği, %98.43’lük doğruluk oranına, %99.97’lik özgüllük oranına ve %0.03’lük yanlış pozitif oranına sahip olduğu gözlemlenmektedir.

Flavia veriseti üzerinde, VGG-16 CNN modeli ile FC7 katmanından gelen derin öğrenme öznitelikleri kullanımının sadece manuel olarak öznitelik çıkarımına göre sınıflandırıcıların büyük çoğunluğunda daha iyi başarım verdiği sonucuna varılmıştır.

VGG-16 CNN Modeli – FC6 Katmanı

Flavia veriseti üzerinde sadece derin öğrenme öznitelikleri kullanıldığında VGG-16 CNN modeli ve FC6 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.9’da gösterilmektedir.

Çizelge 6.9: Flavia verisetinde sadece derin öğrenme öznitelikleri ile VGG-16 CNN modeli ve FC6 katmanından elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	98.39	99.95	0.05
RF (n=100)	98.39	99.95	0.05
RF (n=150)	98.93	99.97	0.03
ECOC-SVM	99.46	99.98	0.02
K-NN (k=1)	99.46	99.98	0.02
CT	83.87	99.48	0.52

Çizelge 6.9'daki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM ve K-NN modelinden elde edildiği, %99.46'lık doğruluk oranına, %99.98'lik özgüllük oranına ve %0.02'lik yanlış pozitif oranına sahip olduğu gözlemlenmektedir.

Flavia veriseti üzerinde, VGG-16 CNN modeli ile FC6 katmanından gelen derin öğrenme öznitelikleri kullanımının sadece manuel olarak uzman bilgisiyle öznitelik çıkarımına göre sınıflandırıcıların büyük çoğunluğunda daha iyi başarımlar verdiği sonucuna varılmıştır.

VGG-19 CNN Modeli – FC7 Katmanı

Flavia veriseti üzerinde sadece derin öğrenme öznitelikleri kullanıldığında VGG-19 CNN modeli ve FC7 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.10'da gösterilmektedir.

Çizelge 6.10: Flavia verisetinde sadece derin öğrenme öznitelikleri ile VGG-19 CNN modeli ve FC7 katmanından elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	96.77	99.90	0.10
RF (n=100)	96.77	99.90	0.10
RF (n=150)	97.31	99.91	0.09
ECOC-SVM	97.85	99.93	0.07
K-NN (k=1)	97.31	99.91	0.09
CT	78.50	99.31	0.69

Çizelge 6.10'daki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM ve K-NN modelinden elde edildiği, %97.85'lik doğruluk oranına, %99.93'lük özgüllük oranına ve %0.07'lik yanlış pozitif oranına sahip olduğu gözlemlenmektedir.

Flavia veriseti üzerinde, VGG-19 CNN modeli ile FC7 katmanından gelen derin öğrenme öznitelikleri kullanımının sadece manuel olarak uzman bilgisiyle öznitelik çıkarımına göre sınıflandırıcıların büyük çoğunluğunda daha iyi başarımlar verdiği sonucuna varılmıştır.

VGG-19 CNN Modeli – FC6 Katmanı

Flavia veriseti üzerinde sadece derin öğrenme öznitelikleri kullanıldığında VGG-19 CNN modeli ve FC6 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.11’de gösterilmektedir.

Çizelge 6.11: Flavia verisetinde sadece derin öğrenme öznitelikleri ile VGG-19 CNN modeli ve FC6 katmanından elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	99.46	99.98	0.02
RF (n=100)	97.85	99.93	0.07
RF (n=150)	98.39	99.95	0.05
ECOC-SVM	98.93	99.97	0.03
K-NN (k=1)	98.39	99.95	0.05
CT	82.80	99.45	0.55

Çizelge 6.11’deki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM modelinden elde edildiği, %98.93’lük doğruluk oranına, %99.97’lik özgüllük oranına ve %0.03’lük yanlış pozitif oranına sahip olduğu gözlemlenmektedir.

Flavia veriseti üzerinde, VGG-19 CNN modeli ile FC6 katmanından gelen derin öğrenme öznitelikleri kullanımının sadece manuel olarak uzman bilgisiyle öznitelik çıkarımına göre sınıflandırıcıların büyük çoğunluğunda daha iyi başarımlar verdiği sonucuna varılmıştır.

6.4.3 Manuel olarak ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar

Flavia veriseti üzerinde manuel olarak ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar bu bölümde sunulmaktadır. Derin öğrenme öznitelikleri çıkartılırken AlexNet, VGG-16 ve VGG-19 CNN modellerinden yararlanılmıştır. Bu modellerin FC6 ve FC7 katmanlarından ayrı ayrı 4096 adet öznitelik çıkartılmıştır.

3 tür CNN modelinin 2 farklı katmanından elde edilen ve manuel olarak çıkartılan özniteliklerin birlikte kullanımına ilişkin alınan sonuçlar alt başlıklar ile açıklanmaktadır.

AlexNet CNN Modeli – FC7 Katmanı

Flavia veriseti üzerinde manuel olarak ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda AlexNet CNN modeli ve FC7 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.12’de gösterilmektedir.

Çizelge 6.12: Flavia verisetinde manuel olarak ve AlexNet CNN modeli ve FC7 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	98.39	99.95	0.05
RF (n=100)	97.85	99.93	0.07
RF (n=150)	97.85	99.93	0.07
ECOC-SVM	99.46	99.98	0.02
K-NN (k=1)	98.93	99.97	0.03
CT	89.25	99.65	0.35
AdaBoost (n=100)	97.31	99.91	0.09
PNN (s=15)	98.93	99.97	0.03

Çizelge 6.12’deki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM modelinden elde edildiği, %99.46’lık doğruluk oranına, %99.98’lik özgüllük oranına ve %0.02’lik yanlış pozitif oranına sahip olduğu gözlemlenmektedir.

Flavia veriseti üzerinde manuel olarak ve derin öğrenme ile AlexNet CNN modeli ile FC7 katmanından çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen en iyi başarımın sadece derin öğrenme öznitelikleri kullanılarak elde edilen en iyi başarımla aynı çıktığı sonucuna varılmıştır. Bu durum, manuel olarak çıkarılan özniteliklerin etkisinin bu verisetinde yüksek başarı oranlarında sınırlı kaldığını göstermektedir.

AlexNet CNN Modeli – FC6 Katmanı

Flavia veriseti üzerinde manuel olarak ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda AlexNet CNN modeli ve FC6 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.13'te gösterilmektedir.

Çizelge 6.13: Flavia verisetinde manuel olarak ve AlexNet CNN modeli ve FC6 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	98.93	99.97	0.03
RF (n=100)	98.93	99.97	0.03
RF (n=150)	98.93	99.97	0.03
ECOC-SVM	100.00	100.00	0.00
K-NN (k=1)	100.00	100.00	0.00
CT	88.71	99.64	0.36

Çizelge 6.13'deki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM ve K-NN modelinden elde edildiği, %100.00'lık doğruluk oranına, %100.00'lık özgüllük oranına ve %0.00'lık yanlış pozitif oranına sahip olduğu gözlemlenmektedir.

Flavia veriseti üzerinde manuel olarak ve derin öğrenme ile AlexNet CNN modeli ile FC6 katmanından çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen en iyi başarımın sadece derin öğrenme öznitelikleri kullanılarak elde edilen en iyi başarımla aynı ve olabilecek en yüksek oranlara çıktığı sonucuna varılmıştır.

VGG-16 CNN Modeli – FC7 Katmanı

Flavia veriseti üzerinde manuel olarak ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda VGG-16 CNN modeli ve FC7 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.14'te gösterilmektedir.

Çizelge 6.14: Flavia verisetinde manuel olarak ve VGG-16 CNN modeli ve FC7 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	98.39	99.95	0.05
RF (n=100)	98.93	99.97	0.03
RF (n=150)	98.93	99.97	0.03
ECOC-SVM	98.93	99.97	0.03
K-NN (k=1)	97.85	99.93	0.07
CT	92.47	99.76	0.24

Çizelge 6.14'teki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM ve RF modelinden elde edildiği, %98.93'lik doğruluk oranına, %99.97'lik özgüllük oranına ve %0.03'lük yanlış pozitif oranına sahip olduğu gözlemlenmektedir.

Flavia veriseti üzerinde manuel olarak ve derin öğrenme ile VGG-16 CNN modeli ile FC7 katmanından çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen en iyi başarımın sadece derin öğrenme öznitelikleri kullanılarak elde edilen en iyi başarımla aynı çıktığı sonucuna varılmıştır.

VGG-16 CNN Modeli – FC6 Katmanı

Flavia veriseti üzerinde manuel olarak ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda VGG-16 CNN modeli ve FC6 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.15'te gösterilmektedir.

Çizelge 6.15: Flavia verisetinde manuel olarak ve VGG-16 CNN modeli ve FC6 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	98.39	99.95	0.05
RF (n=100)	98.39	99.95	0.05
RF (n=150)	98.93	99.97	0.03
ECOC-SVM	99.46	99.98	0.02
K-NN (k=1)	99.46	99.98	0.02
CT	87.63	99.60	0.40

Çizelge 6.15'teki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM ve K-NN modelinden elde edildiği, %99.46'lık doğruluk oranına, %99.98'lik özgüllük oranına ve %0.02'lik yanlış pozitif oranına sahip olduğu gözlemlenmektedir.

Flavia veriseti üzerinde manuel olarak ve derin öğrenme ile VGG-16 CNN modeli ile FC6 katmanından çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen en iyi başarımın sadece derin öğrenme öznitelikleri kullanılarak elde edilen en iyi başarımla aynı çıktığı sonucuna varılmıştır.

VGG-19 CNN Modeli – FC7 Katmanı

Flavia veriseti üzerinde manuel olarak ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda VGG-19 CNN modeli ve FC7 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.16'da gösterilmektedir.

Çizelge 6.16: Flavia verisetinde manuel olarak ve VGG-19 CNN modeli ve FC7 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	98.93	99.97	0.03
RF (n=100)	99.46	99.98	0.02
RF (n=150)	98.93	99.97	0.03
ECOC-SVM	97.85	99.93	0.07
K-NN (k=1)	97.31	99.91	0.09
CT	91.40	99.72	0.28

Çizelge 6.16'daki sonuçlar incelendiğinde, en yüksek başarımın RF (n=100) modelinden elde edildiği, %99.46'lık doğruluk oranına, %99.98'lik özgüllük oranına ve %0.02'lik yanlış pozitif oranına sahip olduğu gözlemlenmektedir.

Flavia veriseti üzerinde manuel olarak ve derin öğrenme ile VGG-19 CNN modeli ile FC7 katmanından çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen en iyi başarımın sadece derin öğrenme öznitelikleri kullanılarak elde edilen en iyi başarımdan daha etkili olduğu sonucuna varılmıştır. Kullanılan bu derin öğrenme modeli için manuel özniteliklerin kullanımı da başarıyı olumlu yönde etkilemiştir.

VGG-19 CNN Modeli – FC6 Katmanı

Flavia veriseti üzerinde manuel olarak ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda VGG-19 CNN modeli ve FC6 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.17'de gösterilmektedir.

Çizelge 6.17: Flavia verisetinde manuel olarak ve VGG-19 CNN modeli ve FC6 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	98.93	99.97	0.03
RF (n=100)	98.39	99.95	0.05
RF (n=150)	100.00	100.00	0.00
ECOC-SVM	98.93	99.97	0.03
K-NN (k=1)	98.39	99.95	0.05
CT	87.63	99.60	0.40

Çizelge 6.17’deki sonuçlar incelendiğinde, en yüksek başarımın RF (n=150) modelinden elde edildiği, %100.00’lık doğruluk oranına, %100.00’lık özgüllük oranına ve %0.00’lık yanlış pozitif oranına sahip olduğu gözlemlenmektedir.

Flavia veriseti üzerinde manuel olarak ve derin öğrenme ile VGG-19 CNN modeli ile FC6 katmanından çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen en iyi başarımın sadece derin öğrenme öznitelikleri kullanılarak elde edilen en iyi başarımdan daha etkili olduğu sonucuna varılmıştır. Kullanılan bu derin öğrenme modeli için manuel özniteliklerin kullanımı da başarıyı olumlu yönde etkileyerek elde edilebilecek en iyi sonuca ulaşılmasını sağlamıştır.

6.4.4 Sadece seçilen manuel özniteliklerin kullanımı ile elde edilen deneysel sonuçlar

Flavia veriseti üzerinde sadece seçilen manuel öznitelikler kullanıldığında elde edilen deneysel sonuçlar Çizelge 6.18’de gösterilmektedir. Öznitelik seçiminde doğruluk oranı en yüksek orana sahip olan ECOC-SVM modeli kullanılmıştır. Deneysel sonuçlar alınan en iyi değerleri göstermektedir.

Çizelge 6.18: Flavia verisetinde sadece seçilen manuel öznitelikler kullanıldığında elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
ECOC-SVM	98.39	99.95	0.05

Çizelge 6.18’deki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM modelinden elde edildiği, %98.39’luk doğruluk oranına, %99.95’lik özgüllük oranına ve %0.05’lik yanlış pozitif oranına sahip olduğu gözlemlenmektedir.


Buna göre, Flavia verisetinde seçilen özniteliklerin kullanımı ile sadece manuel olarak çıkarılan özniteliklerin kullanılmasına göre daha yüksek başarılı sonuçlar alınmıştır. Bu durum, hem veri boyutunun indirgenmesi hem de başarımının artırılması açısından önem taşımaktadır.

6.4.5 Seçilen öznitelikler ile derin öğrenme özniteliklerinin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar

Flavia veriseti üzerinde seçilen öznitelikler ile 3 farklı derin öğrenme modeli ve katmanlarından çıkartılan derin öğrenme özniteliklerinin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar Çizelge 6.19’da ve Şekil 6.2’de gösterilmektedir. Öznitelik seçiminde ECOC-SVM modeli kullanılmıştır. Derin öğrenme öznitelikleri çıkartılırken AlexNet, VGG-16, VGG-19 CNN modellerinden FC7 ve FC6 katmanlarından ayrı ayrı 4096 adet öznitelik çıkartılmıştır.

Çizelge 6.19: Flavia verisetinde seçilen öznitelikler ile derin öğrenme özniteliklerinin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar

Model ve Katman	Ön bilgi Oranı	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
AlexNet, FC7	0.90	99.46	99.98	0.02
AlexNet, FC6	0.90	100.00	100.00	0.00
VGG-16, FC7	0.90	98.93	99.97	0.03
VGG-16, FC6	0.90	99.46	99.98	0.02
VGG-19, FC7	0.90	97.85	99.93	0.07
VGG-19, FC6	0.90	98.93	99.97	0.03
AlexNet, FC7	0.95	99.46	99.98	0.02
AlexNet, FC6	0.95	100.00	100.00	0.00
VGG-16, FC7	0.95	98.93	99.97	0.03
VGG-16, FC6	0.95	99.46	99.98	0.02
VGG-19, FC7	0.95	97.85	99.93	0.07
VGG-19, FC6	0.95	98.93	99.97	0.03



Şekil 6.2: Flavia verisetinde seçilen özniteliklerle derin öğrenme özniteliklerinin birlikte kullanımı sonucunda elde edilen doğruluk oranlarını gösteren grafik

Çizelge 6.19'daki sonuçlar incelendiğinde, en yüksek başarımın AlexNet CNN modeli FC6 katmanından elde edildiği, %100.00'lık doğruluk oranına, %100.00'lık özgüllük oranına ve %0.00'lık yanlış pozitif oranına sahip olduğu gözlemlenmektedir. İki farklı ön bilgi oranında başarım değişikliği görülmemiştir.


Bu sonuçlara göre, Flavia veriseti üzerinde seçilen öznitelikler ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen başarımın sadece derin öğrenme öznitelikleri kullanılarak elde edilen başarımla aynı çıktığı sonucuna varılmıştır. Bu durum, manuel olarak çıkarılan öznitelik sayısının derin öğrenme özniteliklerine oranla oldukça az olmasından kaynaklanabileceği biçiminde yorumlanabilir.

6.4.6 Özet tablo gösterimi

Flavia verisetinde, sadece derin öğrenme öznitelikleri kullanımına (DL) bağlı olarak alınan en iyi doğruluk oranı sonuçları ile derin öğrenme ve manuel özniteliklerin birlikte kullanımı (DL+HC) sonucunda elde edilen en iyi doğruluk oranlarına ait sonuçlar özet tablo halinde Çizelge 6.20'de ve grafik halinde Şekil 6.3'te sunulmuştur. Koyu olarak yazılan sonuçlar her iki türde öz niteliğin kullanımı durumunda daha iyi sonuç alındığını göstermektedir.

Çizelge 6.20: Flavia verisetinde farklı türdeki öznitelik kullanımına ilişkin alınan en iyi sonuçları gösteren özet tablo

	DL	DL + HC	
AlexNet, FC7	99.46	99.46	=
AlexNet, FC6	100.00	100.00	=
VGG-16, FC7	98.93	98.93	=
VGG-16, FC6	99.46	99.46	=
VGG-19, FC7	97.85	99.46	+
VGG-19, FC6	98.93	100.00	+



Şekil 6.3: Flavia verisetinde farklı türdeki öznitelik kullanımına ilişkin alınan en iyi sonuçları gösteren grafik

6.4.7 Geliştirilen manuel örüntü tanıma çerçevesi başarımının literatürdeki yöntemlerle karşılaştırılması


Flavia veriseti üzerinde, manuel olarak çıkarılan öznitelik kümesi ve bu küme üzerinde uygulanan öznitelik seçimi işlemlerinden oluşan örüntü tanıma çerçevesinin başarımları sonuçları, doğruluk oranı bakımından literatürdeki diğer handcrafted öznitelikleri içeren çalışmalarla karşılaştırılmıştır. Literatürde yapılmış çalışmalar, kullanılan yöntemler, sınıflandırıcı ve doğruluk oranlarına ilişkin sonuçlar Çizelge 6.21’de ve Şekil 6.4’te gösterilmektedir.

Çizelge 6.21’e göre, geliştirilen manuel öznitelik çerçevesi karşılaştırılan çalışmalar içinde Flavia verisetinde en iyi sınıflandırma doğruluk oranına ulaşmaktadır. Bu durum, önerilen yöntemin kullanılabilirliği açısından önem taşımaktadır.

Çizelge 6.21: Flavia verisetinde manuel örüntü tanıma çerçevesi başarımının literatürdeki yöntemlerle karşılaştırılması

Yayın	Yöntem	Sınıflandırıcı	Doğruluk Oranı %
Bu çalışma	Önerilen yöntem: Şekilsel, dokusal öznitelikler + FS	SVM (ECOC)	98.39
Prasad et al., 2017	AVP+DCT	K-NN	97.9592
Yousefi et al., 2017	RIWD + 12 Morfolojik ve dokusal öznitelik	MLP	97.50
Kumar et al., 2016	Kenar ve şekil tabanlı öznitelikler	K-NN	94.37
Eid et al., 2015	Şekil ve damar öznitelikleri	NB	97.00
Munisami et al., 2015	Şekil öznitelikleri ve renk histogramı	K-NN	87.30
Satti et al., 2013	Şekil ve renk öznitelikleri	ANN	93.30
Ulutürk and Uğur, 2012	Şekil öznitelikleri	PNN	92.50
Kadir et al., 2011	Şekil, renk ve dokusal öznitelikler	PNN	93.75
Hossain and Amin, 2010	Şekil öznitelikleri	PNN	91.41
Wu et al., 2007	Morfolojik öznitelikler + PCA	PNN	90.00

Şekil 6.4'te yer alan MPRF kısaltması tez çalışmasında geliştirilen manuel örüntü tanıma çerçevesini ifade etmektedir.



Şekil 6.4: Flavia verisetinde manuel örüntü tanıma çerçevesi doğruluk oranının literatürdeki diğer çalışmalar ile karşılaştırılmasını gösteren grafik


6.4.8 Geliştirilen manuel ve derin öğrenmeli örüntü tanıma çerçevesi başarımının literatürdeki yöntemlerle karşılaştırılması

Flavia veriseti üzerinde, manuel ve derin öğrenme ile çıkarılan öznitelik kümesi ve bu küme üzerinde uygulanan öznitelik seçimi işlemlerinden oluşan örüntü tanıma çerçevesinin başarımları, doğruluk oranı bakımından literatürdeki diğer derin öğrenme içeren çalışmalarla karşılaştırılmıştır. Literatürde yapılmış çalışmalar, kullanılan yöntemler ve doğruluk oranlarına ilişkin sonuçlar Çizelge 6.22’de ve Şekil 6.5’te gösterilmektedir.

Çizelge 6.22’ye göre, geliştirilen manuel ve derin öğrenmeli örüntü tanıma çerçevesi (MDPRF) ile karşılaştırılan çalışmalar içinde Flavia verisetinde ulaşılabilecek en iyi sınıflandırma doğruluk oranına ulaşmaktadır. Bu durum, önerilen yöntemin kullanılabilirliği açısından önem taşımaktadır.

Çizelge 6.22: Flavia verisetinde manuel ve derin öğrenmeli örüntü tanıma çerçevesi başarımının literatürle karşılaştırılması

Yayın	Yöntem	Doğruluk Oranı %
Bu çalışma	Önerilen yöntem: Handcrafted öznitelikler + Derin öğrenme öznitelikleri + FS	100.00
Çuğu et al., 2017	CNN + HCF	99.68
Sun et al., 2017	ResNet26	99.65
Lee et al., 2017	Fine Tuning CNN	99.40
Shah et al., 2017	Dual-Path CNN	99.28
Liu and Kan, 2016	DBNs with “dropout”	99.37



Şekil 6.5: Flavia verisetinde manuel ve derin öğrenmeli örüntü tanıma çerçevesi doğruluk oranının literatürdeki diğer çalışmalar ile karşılaştırılmasını gösteren grafik

6.5 Caltech-101 Veriseti için Elde Edilen Sonuçlar

Caltech-101 nesne tanıma görüntü veriseti için manuel özniteliklerle, derin öğrenme öznitelikleriyle, her ikisi birlikte kullanıldığında elde edilen sonuçlar bu bölümde sunulmuştur. Ayrıca deneyler öznitelik seçimi aşaması eklenerek de tekrarlanmıştır.

6.5.1 Sadece manuel olarak çıkarılan öznitelikler ile elde edilen deneysel sonuçlar

Caltech-101 veriseti üzerinde sadece manuel olarak çıkarılan öznitelikler kullanıldığında elde edilen deneysel sonuçlar Çizelge 6.23'te gösterilmektedir.

Çizelge 6.23: Caltech-101 verisetinde sadece manuel olarak çıkarılan özniteliklerin kullanımı sonucunda elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	76.14	99.76	0.24
RF (n=100)	78.81	99.79	0.21
RF (n=150)	79.05	99.79	0.21
ECOC-SVM	82.19	99.82	0.18
K-NN (k=1)	67.87	99.68	0.32
CT	61.00	99.61	0.39
AdaBoost (n=100)	49.24	99.49	0.51
PNN (s=15)	18.51	99.19	0.81
NB	66.59	99.67	0.33

Çizelge 6.23'deki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM modelinden elde edildiği, %82.19'luk doğruluk oranına, %99.82'lik özgüllük oranına ve %0.18'lik yanlış pozitif oranına ulaşıldığı gözlemlenmektedir.

6.5.2 Sadece derin öğrenme öznitelikleri ile elde edilen deneysel sonuçlar

Caltech-101 veriseti üzerinde sadece derin öğrenme öznitelikleri kullanıldığında elde edilen deneysel sonuçlar bu bölümde sunulmaktadır. Derin öğrenme öznitelikleri çıkartılırken AlexNet, VGG-16 ve VGG-19 CNN modellerinden yararlanılmıştır. Bu modellerin FC6 ve FC7 katmanlarından ayrı ayrı 4096 adet öznitelik çıkartılmıştır.

3 tür CNN modelinin 2 farklı katmanından elde edilen öznitelikler için alınan sonuçlar alt başlıklar ile açıklanmaktadır.

AlexNet CNN Modeli – FC7 Katmanı

Caltech-101 veriseti üzerinde sadece derin öğrenme öznitelikleri kullanıldığında AlexNet CNN modeli ve FC7 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.24'te gösterilmektedir.

Çizelge 6.24: Caltech-101 verisetinde sadece derin öğrenme öznitelikleri ile AlexNet CNN modeli ve FC7 katmanından elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	82.65	99.83	0.17
RF (n=100)	83.00	99.83	0.17
RF (n=150)	83.82	99.84	0.16
ECOC-SVM	90.80	99.91	0.09
K-NN (k=1)	83.00	99.83	0.17
CT	56.81	99.57	0.43
AdaBoost (n=100)	50.06	99.50	0.50
PNN (s=15)	82.89	99.83	0.17
NB	79.16	99.79	0.21

Çizelge 6.24'teki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM modelinden elde edildiği, %90.80'lik doğruluk oranına, %99.91'lik özgüllük oranına ve %0.09'luk yanlış pozitif oranına ulaşıldığı gözlemlenmektedir.

Caltech-101 veriseti üzerinde, sadece AlexNet CNN modeli ile FC7 katmanından gelen derin öğrenme öznitelikleri kullanımında sadece uzman bilgisiyle öznitelik çıkarımına göre sınıflandırıcıların büyük çoğunluğunda daha iyi başarımlar alındığı sonucuna varılmıştır.

AlexNet CNN Modeli – FC6 Katmanı

Caltech-101 veriseti üzerinde sadece derin öğrenme öznitelikleri kullanıldığında AlexNet CNN modeli ve FC6 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.25'te gösterilmektedir.

Çizelge 6.25: Caltech-101 verisetinde sadece derin öğrenme öz nitelikleri ile AlexNet CNN modeli ve FC6 katmanından elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	77.80	99.78	0.22
RF (n=100)	81.14	99.81	0.19
RF (n=150)	83.59	99.84	0.16
ECOC-SVM	91.04	99.91	0.09
K-NN (k=1)	81.61	99.82	0.18
CT	54.95	99.55	0.45

Çizelge 6.25'teki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM modelinden elde edildiği, %91.04'lik doğruluk oranına, %99.91'lik özgüllük oranına ve %0.09'luk yanlış pozitif oranına ulaşıldığı gözlemlenmektedir.

Caltech-101 veriseti üzerinde, sadece AlexNet CNN modeli ile FC6 katmanından gelen derin öğrenme öz nitelikleri kullanımında sadece uzman bilgisiyle öz nitelik çıkarımına göre sınıflandırıcıların büyük çoğunluğunda daha iyi başarım alındığı sonucuna varılmıştır.

VGG-16 CNN Modeli – FC7 Katmanı

Caltech-101 veriseti üzerinde sadece derin öğrenme öz nitelikleri kullanıldığında VGG-16 CNN modeli ve FC7 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.26'da gösterilmektedir.

Çizelge 6.26: Caltech-101 verisetinde sadece derin öğrenme öznitelikleri ile VGG-16 CNN modeli ve FC7 katmanından elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	84.17	99.84	0.16
RF (n=100)	86.96	99.87	0.13
RF (n=150)	87.08	99.87	0.13
ECOC-SVM	89.06	99.89	0.11
K-NN (k=1)	82.77	99.83	0.17
CT	60.65	99.61	0.39

Çizelge 6.26'daki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM modelinden elde edildiği, %89.06'lık doğruluk oranına, %99.89'luk özgüllük oranına ve %0.11'lik yanlış pozitif oranına ulaşıldığı gözlemlenmektedir.

Caltech-101 veriseti üzerinde, sadece VGG-16 CNN modeli ile FC7 katmanından gelen derin öğrenme öznitelikleri kullanımında sadece uzman bilgisiyle öznitelik çıkarımına göre sınıflandırıcıların büyük çoğunluğunda daha iyi başarım alındığı sonucuna varılmıştır.

VGG-16 CNN Modeli – FC6 Katmanı

Caltech-101 veriseti üzerinde sadece derin öğrenme öznitelikleri kullanıldığında VGG-16 CNN modeli ve FC6 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.27'de gösterilmektedir.

Çizelge 6.27: Caltech-101 verisetinde sadece derin öğrenme öznitelikleri ile VGG-16 CNN modeli ve FC6 katmanından elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	83.00	99.83	0.17
RF (n=100)	86.03	99.86	0.14
RF (n=150)	85.80	99.86	0.14
ECOC-SVM	91.62	99.92	0.08
K-NN (k=1)	82.19	99.82	0.18
CT	56.46	99.57	0.43

Çizelge 6.27’deki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM modelinden elde edildiği, %91.62’lik doğruluk oranına, %99.92’lik özgüllük oranına ve %0.08’lik yanlış pozitif oranına ulaşıldığı gözlemlenmektedir.

Caltech-101 veriseti üzerinde, sadece VGG-16 CNN modeli ile FC6 katmanından gelen derin öğrenme öznitelikleri kullanımında sadece uzman bilgisiyle öznitelik çıkarımına göre sınıflandırıcıların büyük çoğunluğunda daha iyi başarım alındığı sonucuna varılmıştır.

VGG-19 CNN Modeli – FC7 Katmanı

Caltech-101 veriseti üzerinde sadece derin öğrenme öznitelikleri kullanıldığında VGG-19 CNN modeli ve FC7 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.28’de gösterilmektedir.

Çizelge 6.28: Caltech-101 verisetinde sadece derin öğrenme öznitelikleri ile VGG-19 CNN modeli ve FC7 katmanından elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	82.65	99.83	0.17
RF (n=100)	84.75	99.85	0.15
RF (n=150)	85.68	99.86	0.14
ECOC-SVM	88.48	99.89	0.11
K-NN (k=1)	83.70	99.84	0.16
CT	62.17	99.62	0.38

Çizelge 6.28'deki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM modelinden elde edildiği, %88.48'lik doğruluk oranına, %99.89'luk özgüllük oranına ve %0.11'lik yanlış pozitif oranına ulaşıldığı gözlemlenmektedir.

Caltech-101 veriseti üzerinde, sadece VGG-19 CNN modeli ile FC7 katmanından gelen derin öğrenme öznitelikleri kullanımında sadece manuel olarak uzman bilgisiyle öznitelik çıkarımına göre daha iyi başarımlar alındığı sonucuna varılmıştır.

VGG-19 CNN Modeli – FC6 Katmanı

Caltech-101 veriseti üzerinde sadece derin öğrenme öznitelikleri kullanıldığında VGG-19 CNN modeli ve FC6 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.29'da gösterilmektedir.

Çizelge 6.29: Caltech-101 verisetinde sadece derin öğrenme öznitelikleri ile VGG-19 CNN modeli ve FC6 katmanından elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	82.54	99.83	0.17
RF (n=100)	84.98	99.85	0.15
RF (n=150)	85.91	99.86	0.14
ECOC-SVM	92.55	99.93	0.07
K-NN (k=1)	84.28	99.84	0.16
CT	59.49	99.60	0.40

Çizelge 6.29'daki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM modelinden elde edildiği, %92.55'lik doğruluk oranına, %99.93'lük özgüllük oranına ve %0.07'lik yanlış pozitif oranına ulaşıldığı gözlemlenmektedir.

Caltech-101 veriseti üzerinde, sadece VGG-19 CNN modeli ile FC7 katmanından gelen derin öğrenme öznitelikleri kullanımında sadece manuel olarak uzman bilgisiyle öznitelik çıkarımına göre sınıflandırıcıların büyük çoğunluğunda daha iyi başarımlar alındığı sonucuna varılmıştır.

6.5.3 Manuel olarak ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar

Caltech-101 veriseti üzerinde manuel olarak ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar bu bölümde sunulmaktadır. AlexNet, VGG-16 ve VGG-19 CNN modellerinden yararlanılmıştır. Bu modellerin FC6 ve FC7 katmanlarından ayrı ayrı 4096 adet öznitelik çıkartılmıştır.

3 tür CNN modelinin 2 farklı katmanından elde edilen ve manuel olarak çıkartılan özniteliklerin birlikte kullanımına ilişkin alınan sonuçlar alt başlıklar ile açıklanmaktadır.

AlexNet CNN Modeli – FC7 Katmanı

Caltech-101 veriseti üzerinde manuel olarak ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda AlexNet CNN modeli ve FC7 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.30'da gösterilmektedir.

Çizelge 6.30: Caltech-101 verisetinde manuel olarak ve AlexNet CNN modeli ve FC7 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	86.03	99.86	0.14
RF (n=100)	88.71	99.89	0.11
RF (n=150)	89.41	99.89	0.11
ECOC-SVM	90.69	99.91	0.09
K-NN (k=1)	82.89	99.83	0.17
CT	66.59	99.67	0.33
AdaBoost (n=100)	57.63	99.58	0.42
PNN (s=15)	82.77	99.83	0.17
NB	80.91	99.81	0.19

Çizelge 6.30'daki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM modelinden elde edildiği, %90.69'luk doğruluk oranına, %99.91'lik özgüllük oranına ve %0.09'luk yanlış pozitif oranına ulaşıldığı gözlemlenmektedir.

Caltech-101 veriseti üzerinde manuel olarak ve AlexNet CNN modeli, FC7 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen başarımın sadece derin öğrenme öznitelikleri kullanılarak elde edilen eniyi özgüllük ve yanlış pozitif oranı başarımlarıyla aynı çıktığı sonucuna varılmıştır. Buna karşın, doğruluk oranı ile her iki türde özneliğin birlikte kullanımı sağlandığında sadece derin öğrenme özniteliklerine göre daha düşük bir başarıma ulaşıldığı gözlemlenmiştir. Bu durum, manuel olarak çıkarılan özniteliklerin etkisinin bu verisetinde kullanılan modelle yüksek başarı oranlarında sınırlı kaldığını ve azalttığını göstermektedir.

AlexNet CNN Modeli – FC6 Katmanı

Caltech-101 veriseti üzerinde manuel olarak ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda AlexNet CNN modeli ve FC6 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.31'de gösterilmektedir.

Çizelge 6.31: Caltech-101 verisetinde manuel olarak ve AlexNet CNN modeli ve FC6 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	83.70	99.84	0.16
RF (n=100)	88.24	99.88	0.12
RF (n=150)	89.17	99.89	0.11
ECOC-SVM	91.27	99.91	0.09
K-NN (k=1)	81.61	99.82	0.18
CT	62.05	99.62	0.38

Çizelge 6.31'deki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM modelinden elde edildiği, %91.27'lik doğruluk oranına, %99.91'lik özgüllük oranına ve %0.09'luk yanlış pozitif oranına ulaşıldığı gözlemlenmektedir.

Caltech-101 veriseti üzerinde manuel olarak ve AlexNet CNN modeli, FC6 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen başarımın sadece derin öğrenme öznitelikleri kullanılarak elde edilen en iyi özgüllük ve yanlış pozitif oranı başarımlarıyla aynı çıktığı sonucuna varılmıştır. Buna karşın, doğruluk oranı ile her iki türde özneliğin birlikte kullanımı sağlandığında sadece derin öğrenme özniteliklerine göre daha yüksek bir başarıma ulaşıldığı gözlemlenmiştir. Bu durum, manuel olarak çıkarılan özniteliklerin etkisinin bu verisetinde kullanılan modelle olumlu yönde etkiye sahip olduğunu göstermektedir.

VGG-16 CNN Modeli – FC7 Katmanı

Caltech-101 veriseti üzerinde manuel olarak ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda VGG-16 CNN modeli ve FC7 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.32'de gösterilmektedir.

Çizelge 6.32: Caltech-101 verisetinde manuel olarak ve VGG-16 CNN modeli ve FC7 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	87.66	99.88	0.12
RF (n=100)	88.71	99.89	0.11
RF (n=150)	89.52	99.90	0.10
ECOC-SVM	88.59	99.89	0.11
K-NN (k=1)	82.54	99.83	0.17
CT	68.34	99.68	0.32

Çizelge 6.32’deki sonuçlar incelendiğinde, en yüksek başarımın RF (n=150) modelinden elde edildiği, %89.52’lik doğruluk oranına, %99.90’lık özgüllük oranına ve %0.10’luk yanlış pozitif oranına ulaşıldığı gözlemlenmektedir.

Caltech-101 veriseti üzerinde manuel olarak ve VGG-16 CNN modeli, FC7 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen başarımın sadece derin öğrenme öznitelikleri kullanımına göre daha yüksek olduğu gözlemlenmiştir. Bu durum, manuel olarak çıkarılan özniteliklerin etkisinin bu verisetinde kullanılan modelle olumlu yönde etkiye sahip olduğunu göstermektedir.

VGG-16 CNN Modeli – FC6 Katmanı

Caltech-101 veriseti üzerinde manuel olarak ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda VGG-16 CNN modeli ve FC6 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.33’te gösterilmektedir.

Çizelge 6.33: Caltech-101 verisetinde manuel olarak ve VGG-16 CNN modeli ve FC6 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	85.10	99.85	0.15
RF (n=100)	88.13	99.88	0.12
RF (n=150)	89.29	99.89	0.11
ECOC-SVM	91.62	99.92	0.08
K-NN (k=1)	82.31	99.82	0.18
CT	64.61	99.65	0.35

Çizelge 6.33'teki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM modelinden elde edildiği, %91.62'lik doğruluk oranına, %99.92'lik özgüllük oranına ve %0.08'lik yanlış pozitif oranına ulaşıldığı gözlemlenmektedir.

Caltech-101 veriseti üzerinde manuel olarak ve VGG-16 CNN modeli, FC7 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen en iyi başarımın sadece derin öğrenme öznitelikleri kullanılarak elde edilen en iyi doğruluk oranı, özgüllük ve yanlış pozitif oranı başarımlarıyla aynı çıktığı sonucuna varılmıştır. Bu durum, manuel olarak çıkarılan özniteliklerin etkisinin bu verisetinde kullanılan modelle yüksek başarı oranlarında sınırlı kaldığını göstermektedir.

VGG-19 CNN Modeli – FC7 Katmanı

Caltech-101 veriseti üzerinde manuel olarak ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda VGG-19 CNN modeli ve FC7 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.34'te gösterilmektedir.

Çizelge 6.34: Caltech-101 verisetinde manuel olarak ve VGG-19 CNN modeli ve FC7 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	86.73	99.87	0.13
RF (n=100)	88.01	99.88	0.12
RF (n=150)	89.29	99.89	0.11
ECOC-SVM	88.36	99.88	0.12
K-NN (k=1)	83.35	99.83	0.17
CT	64.26	99.64	0.36

Çizelge 6.34'teki sonuçlar incelendiğinde, en iyi başarımın RF (n=150) modeliyle sağlandığı %89.29'luk doğruluk oranına, %99.89'luk özgüllük oranına ve %0.11'lik yanlış pozitif oranına ulaşıldığı gözlemlenmektedir.

Caltech-101 veriseti üzerinde manuel olarak ve VGG-19 CNN modeli, FC7 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen en iyi başarımın sadece derin öğrenme öznitelikleri kullanılarak elde edilen özgüllük ve yanlış pozitif oranı başarımlarıyla aynı çıkmış, doğruluk oranı olarak daha yüksek sonucuna varılmıştır. Bu durum, manuel olarak çıkarılan özniteliklerin bu verisetinde kullanılan modelle yüksek başarı oranlarında olumlu yönde etkiye bulunduğunu göstermektedir.

VGG-19 CNN Modeli – FC6 Katmanı

Caltech-101 veriseti üzerinde manuel olarak ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda VGG-19 CNN modeli ve FC6 katmanı ile elde edilen deneysel sonuçlar Çizelge 6.35'te gösterilmektedir.

Çizelge 6.35: Caltech-101 verisetinde manuel olarak ve VGG-19 CNN modeli ve FC6 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
RF (n=50)	86.38	99.86	0.14
RF (n=100)	88.48	99.89	0.11
RF (n=150)	89.99	99.90	0.10
ECOC-SVM	92.55	99.93	0.07
K-NN (k=1)	84.28	99.84	0.16
CT	64.49	99.65	0.35

Çizelge 6.35’deki sonuçlar incelendiğinde, en iyi başarımın, ECOC-SVM modelinden elde edildiği, %92.55’lik doğruluk oranına, %99.93’lük özgüllük oranına ve %0.07’lik yanlış pozitif oranına ulaşıldığı gözlemlenmektedir.

Caltech-101 veriseti üzerinde manuel olarak ve VGG-19 CNN modeli, FC6 katmanından derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen en iyi başarımın sadece derin öğrenme öznitelikleri kullanılarak elde edilen doğruluk oranı, özgüllük ve yanlış pozitif oranı başarımlarıyla aynı çıktığı sonucuna varılmıştır. Bu durum, manuel olarak çıkarılan özniteliklerin etkisinin bu verisetinde kullanılan modelle yüksek başarı oranlarında sınırlı kaldığını göstermektedir.

6.5.4 Sadece seçilen manuel özniteliklerin kullanımı ile elde edilen deneysel sonuçlar

Caltech-101 veriseti üzerinde sadece seçilen manuel öznitelikler kullanıldığında elde edilen deneysel sonuçlar Çizelge 6.36’da gösterilmektedir. Öznitelik seçiminde doğruluk oranı en yüksek orana sahip olan ECOC-SVM modeli kullanılmıştır. Deneysel sonuçlar alınan en iyi değerleri göstermektedir.

Çizelge 6.36: Caltech-101 verisetinde sadece seçilen manuel öznitelikler kullanıldığında elde edilen deneysel sonuçlar

Sınıflandırıcı – Başarım Ölçütü	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
ECOC-SVM	82.77	99.83	0.17

Çizelge 6.36'daki sonuçlar incelendiğinde, en yüksek başarımın ECOC-SVM modelinden elde edildiği, %82.77'lik doğruluk oranına, %99.83'lük özgüllük oranına ve %0.17'lik yanlış pozitif oranına sahip olduğu gözlemlenmektedir.

Buna göre, Caltech-101 verisetinde seçilen özniteliklerin kullanımı ile sadece manuel olarak çıkarılan özniteliklerin kullanılmasına göre daha iyi başarımlı sonuçlar alınmıştır. Bu durum, hem veri boyutunun indirgenmesi hem de başarımının artırılması açısından önem taşımaktadır.

6.5.5 Seçilen özniteliklerle derin öğrenme özniteliklerinin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar


Caltech-101 veriseti üzerinde seçilen özniteliklerle derin öğrenme özniteliklerinin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar Çizelge 6.37'de gösterilmektedir. Öznitelik seçiminde doğruluk oranı en yüksek orana sahip olan ECOC-SVM modeli kullanılmıştır. Derin öğrenme öznitelikleri çıkartılırken AlexNet, VGG-16, VGG-19 CNN modellerinden FC7 ve FC6 katmanlarından ayrı ayrı 4096 adet öznitelik çıkartılmıştır.

Çizelge 6.37: Caltech-101 verisetinde seçilen özniteliklerle derin öğrenme özniteliklerinin birlikte kullanımı sonucunda elde edilen deneysel sonuçlar

Model ve Katman	Önbilgi Oranı	Doğruluk Oranı %	Özgüllük %	Yanlış Pozitif Oranı %
AlexNet, FC7	0.90	90.69	99.91	0.09
AlexNet, FC6	0.90	91.15	99.91	0.09
VGG-16, FC7	0.90	60.89	99.61	0.39
VGG-16, FC6	0.90	58.21	99.58	0.42
VGG-19, FC7	0.90	59.84	99.60	0.40
VGG-19, FC6	0.90	58.79	99.59	0.41
AlexNet, FC7	0.95	90.80	99.91	0.09
AlexNet, FC6	0.95	91.15	99.91	0.09
VGG-16, FC7	0.95	88.94	99.89	0.11
VGG-16, FC6	0.95	91.62	99.92	0.08
VGG-19, FC7	0.95	88.36	99.88	0.12
VGG-19, FC6	0.95	92.67	99.93	0.07

Çizelge 6.37’deki sonuçlar incelendiğinde, en yüksek başarımın VGG-19 CNN modeli, FC6 katmanından %95 oranında önbilgi ile elde edildiği, %92.67’lik doğruluk oranına, %99.93’lük özgüllük oranına ve %0.07’lik yanlış pozitif oranına sahip olduğu gözlemlenmektedir. Ayrıca, %95 oranında önbilgi ile elde edilen doğruluk oranlarına ilişkin sonuçlar Şekil 6.6’dan incelenebilir.

Bu sonuçlara göre, Caltech-101 veriseti üzerinde seçilen öznitelikler ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen en iyi başarımın sadece derin öğrenme öznitelikleri kullanılmasına ve tüm özniteliklerin birlikte kullanımına göre daha iyi başarımlar verdiği sonucuna varılmıştır.




Şekil 6.6: Caltech-101 verisetinde seçilen öz niteliklerle derin öğrenme öz niteliklerinin birlikte kullanımı sonucunda elde edilen doğruluk oranlarını gösteren grafik

6.5.6 Özet tablo gösterimi

Caltech-101 verisetinde, sadece derin öğrenme öz nitelikleri kullanımı (DL) ile alınan en iyi doğruluk oranı sonuçları ile derin öğrenme ve manuel öz niteliklerin birlikte kullanımı (DL+HC) sonucunda elde edilen en iyi doğruluk oranlarına ait sonuçlar özet tablo halinde Çizelge 6.38’de ve grafik halinde Şekil 6.7’de sunulmuştur. Koyu olarak yazılan sonuçlar her iki türde öz niteliğin kullanımı durumunda daha iyi sonuç alındığını göstermektedir.

Çizelge 6.38: Caltech-101 verisetinde farklı türdeki öz nitelik kullanımına ilişkin alınan en iyi sonuçları gösteren özet tablo

	DL	DL + HC	
AlexNet, FC7	90.80	90.69	-
AlexNet, FC6	91.04	91.27	+
VGG-16, FC7	89.06	89.52	+
VGG-16, FC6	91.62	91.62	=
VGG-19, FC7	88.48	89.29	+
VGG-19, FC6	92.55	92.55	=



Şekil 6.7: Caltech-101 verisetinde farklı türdeki öznitelik kullanımına ilişkin alınan en iyi sonuçları gösteren grafik

6.5.7 Geliştirilen manuel örüntü tanıma çerçevesi başarımının literatürdeki yöntemlerle karşılaştırılması


Caltech-101 veriseti üzerinde, manuel olarak çıkarılan öznitelik kümesi ve bu küme üzerinde uygulanan öznitelik seçimi işlemlerinden oluşan örüntü tanıma çerçevesinin başarımları, doğruluk oranı bakımından literatürdeki diğer handcrafted öznitelikleri içeren çalışmalarla karşılaştırılmıştır. Literatürde yapılmış çalışmalar, kullanılan yöntemler, sınıflandırıcı ve doğruluk oranlarına ilişkin sonuçlar Çizelge 6.39’da ve Şekil 6.8’de gösterilmektedir.

Çizelge 6.39’a göre, yapılmış çalışmalarda farklı sayıda eğitim ve test örneği kullanılmaktadır. Caltech-101 verisetinde genellikle 30 adet görüntü eğitim, kalan görüntüler veya rastgele seçilen 50 görüntü test için seçilmiştir. Geliştirilen manuel öznitelik çerçevesinin test edilmesinde ise %90-%10 oranında eğitim-test kümesi oranı kullanılmıştır. Önerilen yöntem karşılaştırılan çalışmalar içinde en iyi ikinci sınıflandırma doğruluk oranına ulaşmıştır. Bu durum, önerilen yöntemin kullanılabilirliği açısından önem taşımaktadır.

Şekil 6.8’de yer alan MPRF kısaltması tez çalışmasında geliştirilen manuel örüntü tanıma çerçevesini ifade etmektedir.

Çizelge 6.39: Caltech-101 verisetinde manuel örüntü tanıma çerçevesi başarımının literatürle karşılaştırılması

Yayın	Yöntem	Sınıflandırıcı	Doğruluk Oranı %
Bu çalışma	Önerilen yöntem: Şekilsel, dokusal öznitelikler + FS	SVM (ECOC)	82.19
Kabbai et al., 2018	Renksel ve dokusal öznitelikler (CLGC)	LS-SVM	79.85
Ramesh et al., 2017	Renk, görünüm, şekil tabanlı BoW modeli	SVM	80.15
Rahman et al., 2017	Discriminative ternary census transform histogram (DTCTH)	SVM	78.56
Mansourian et al., 2017	SDCD renk tanımlayıcısı ve PHOW	SVM	75.37
Khan et al., 2015	SPS _{ad+}	SVM	68.40
Satpathy et al., 2014	DRLTP (kenarsal ve dokusal öznitelik)	SVM	93.10
Wang et al., 2011	RBC+FC	SVM	77.09
Lazebnik et al., 2006	SPF (Spatial Pyramid Framework)	SVM	64.60
Mutch and Lowe, 2006	Seyrek, yerelleştirilmiş öznitelikler+FS	SVM	56.00



Şekil 6.8: Caltech101 verisetinde manuel örüntü tanıma çerçevesi doğruluk oranının literatürdeki diğer çalışmalar ile karşılaştırılmasını gösteren grafik


6.5.8 Geliştirilen manuel ve derin öğrenmeli örüntü tanıma çerçevesinin literatürdeki yöntemlerle karşılaştırılması

Caltech-101 veriseti üzerinde, manuel ve derin öğrenme ile çıkarılan öznitelik kümesi ve bu küme üzerinde uygulanan öznitelik seçimi işlemlerinden oluşan örüntü tanıma çerçevesinin başarımları sonuçları, doğruluk oranı bakımından literatürdeki diğer derin öğrenme içeren çalışmalarla karşılaştırılmıştır. Literatürde yapılmış çalışmalar, kullanılan yöntemler ve doğruluk oranlarına ilişkin sonuçlar Çizelge 6.40'da ve Şekil 6.9'da gösterilmektedir.

Çizelge 6.40'a göre, geliştirilen manuel ve derin öğrenmeli örüntü tanıma çerçevesi ile karşılaştırılan çalışmalar içinde Caltech-101 verisetinde ulaşılabilecek en iyi sınıflandırma doğruluk oranıyla karşılaştırılabilir bir sonuca ulaşmaktadır. Varolan çalışmalarda farklı sayıda eğitim ve test örneği kullanıldığına dikkat edilmelidir. Caltech-101 verisetinde genellikle 30 adet görüntü eğitim, kalan görüntüler veya rastgele seçilen 50 görüntü test için seçilmiştir. Geliştirilen manuel ve derin öğrenmeli örüntü tanıma çerçevesinin test edilmesinde ise %90-%10 oranında eğitim-test kümesi oranı kullanılmıştır. Daha adil ve güvenilir bir karşılaştırma yapmak için sabit ve bilinen bir eğitim-test kümesi ve oranı kullanmak gereklidir. Bu durum, önerilen yöntemin uygulanabilirliğini göstermek açısından önem taşımaktadır.

Çizelge 6.40: Caltech-101 verisetinde manuel ve derin öğrenmeli örüntü tanıma çerçevesi başarımlarının literatürle karşılaştırılması

Yayın	Yöntem	Doğruluk Oranı %
Bu çalışma	Önerilen yöntem: Handcrafted öznitelikler + Derin öğrenme öznitelikleri + FS	92.67
Bui et al, 2018	Pretrained Alexnet CNN	90.80
Khan et al., 2017	CoSen CNN	90.80
He et al., 2015	SPP-Net	93.42
Chatfield et al., 2014	CNN S TUNE-CLS	88.35
Donahue et al., 2013	DeCAF	86.91



Şekil 6.9: Caltech-101 verisetinde manuel ve derin öğrenmeli örüntü tanıma çerçevesi doğruluk oranının literatürdeki diğer çalışmalar ile karşılaştırılmasını gösteren grafik

6.6 Geliştirilen Çerçevenin Test Edilmesi

Geliştirilen örüntü tanıma çerçevesi 2 farklı görüntü veriseti (Flavia ve Caltech-101) üzerinde uygulanmasının dışında test edilmesi için de ayrı görüntü verisetleri kullanılmıştır. Bu kapsamda çerçeveyi test etmek amacıyla, Kolombiya Üniversitesi görüntü kütüphanesinden COIL-20 (Nene et al., 1996a) ve COIL-100 (Nene et al., 1996b) görüntü verisetlerinden yararlanılmıştır. Test kümesi tüm verisetinin %10'u olacak şekilde rastgele belirlenmiştir. Handcrafted (HC) ve seçili handcrafted özniteliklerin doğruluk oranlarına ilişkin sonuçlar Çizelge 6.41'de sunulmaktadır. Bu çizelgeye göre alınan sonuçlar, seçili özniteliklerin kullanımı ile her iki verisetinde eniyi veya eniyiye yakın sonuçların sağlandığını, bu çerçevenin kullanılabilirliğini göstermek açısından önem taşımaktadır.

Çizelge 6.41: Çerçevenin test edilmesi sonucunda elde edilen doğruluk oranları

	HC%	Seçili HC %
COIL-20	97.14	100.00
COIL-100	99.29	99.86

7. SONUÇ VE ÖNERİLER

Bu bölümde, tez sürecinde gerçekleştirilen çalışmanın genel değerlendirmesi yapılmakta, deneysel çalışmalar kapsamında alınan sonuçlar özetlenmekte, gelecekteki çalışmalar hakkı bilgi verilmektedir ve öneriler sunulmaktadır.

7.1 Sonuç

Öznitelik çıkarma ve seçimi aşamaları örüntü tanıma, makine öğrenmesi, görüntü işleme, bilgisayarlı görü ve veri madenciliği alanlarında çalışan araştırmacılar için önem arz etmektedir. Farklı alanlarda çalışan araştırmacılar, farklı görüntü türleri üzerinde çalışabilmekte, bu görüntü türleri üzerinden uzman bilgisi ile öznitelikler çıkartılmaya ihtiyaç duyulmaktadır. Öznitelik çıkarma işlemi maliyetli bir işlemdir. Alan uzmanlığı, istatistik, bilgisayar bilimleri, matematik, geometri gibi çeşit alanlarda bilgili olmayı gerektirmektedir.

Öznitelik çıkarma ve seçimi, sınıflandırma sürecinde başarıyı yükseltmek amacıyla kullanılmakta, ayırt edici özniteliklerin çeşitliliğinin artırılması ve sınıflarla ilişkisiz özniteliklerin elenmesi gibi durumlar ile sağlanmaktadır.

Literatürde, çeşitli görüntü türleri üzerinde çıkartılmış öznitelikler farklı çalışmalarda bulunsa da kullanılan öznitelik kümelerinin ve seçiminin bir arada olarak çerçeve biçiminde sunulduğu çalışmaya rastlanılmamıştır.

Bu çalışmada, görüntüler üzerinde öznitelik çıkarma ve seçimine odaklı özgün bir örüntü tanıma çerçevesi geliştirilmiştir. Bu çerçeve ile araştırmacılar çeşitli görüntü verisetleri üzerinde kolaylıkla öznitelikler çıkartabilecek, seçilen özniteliklerle veri boyutunu azaltıp, başarıyı artırabileceklerdir.

Geliştirilen çerçeve, 3 farklı açıdan özgünlük içermektedir. İlk olarak, uzman bilgisi dahilinde çıkartılan 194 adet manuel öznitelik kümesini ve öznitelik seçimini kapsayan bir özgün örüntü tanıma çerçevesi sunulmuştur. İkinci olarak, bu manuel özniteliklere günümüzde yaygın olarak kullanılan CNN modelleri vasıtasıyla 4096 adet derin öğrenme özniteliği çıkartılıp manuel öznitelik kümesine eklenerek 4290 adet özniteliği içeren bir çerçeve alt modeli de literatüre kazandırılmıştır. Üçüncü olarak ise geliştirilen manuel öznitelik kümesi içerisinde yer alan merkez noktasına göre ikiye ayrılmış görüntülerden türetilen 4 adet özgün özniteliktir. Öznitelik çerçevesini genişletmek, öznitelik kalitesini artırmak, ayırt

ediciliği artırmak ve özgünlük kazandırmak amacıyla bu öznitelikler de çerçeveye eklenmiştir.

Tez kapsamında, 10 farklı deneysel çalışma yapılmıştır. Bunlar, Flavia ve Caltech-101 verisetleri üzerinde olmak üzere sadece manuel olarak çıkarılan öznitelikler ile elde edilen deneysel sonuçları, sadece derin öğrenme öznitelikleri ile elde edilen deneysel sonuçları, manuel olarak ve derin öğrenme ile çıkarılan özniteliklerin birlikte kullanımı sonucunda elde edilen deneysel sonuçları, sadece seçilen manuel özniteliklerin kullanımı ile elde edilen deneysel sonuçları ve seçilen özniteliklerle derin öğrenme özniteliklerinin birlikte kullanımı sonucunda elde edilen deneysel sonuçları içermektedir. Ayrıca, geliştirilen çerçeve COIL-20 ve COIL-100 verisetlerinde test edilmiştir.

Yapılan deneysel çalışmalar sonucunda, derin öğrenme ve uzman bilgisi ile çıkarılan özniteliklerin (handcrafted) birlikte kullanımıyla en iyi sonuca varıldığı gözlemlenmiştir. Ayrıca, sarmalayıcı yöntemler kapsamında genetik algoritmalar ile öznitelik seçimi yapılarak veri boyutu indirgenmesi sağlanmış, sistemin başarımının daha da artırılması amaçlanmıştır. Türetilen özgün özniteliklerin hepsi Flavia verisetinde seçilmiş, Caltech-101 verisetinde ise sadece ilk ikisi olan ana eksen ve kısa eksen oranları kullanılmıştır. Verilen bir görüntünün ilgili aşamaları içererek sınıflandırılması için geçen süre yaklaşık 1.21 saniye olarak ölçülmüştür.

Bu tez çalışması, özgün bir öznitelik havuzu oluşturmanın dışında genel bir çerçeve sunmanın sağladığı yararlar bakımından önemlidir. Tıp, güvenlik, nesne tanıma, biyometrik sistemler gibi çok çeşitli uygulama alanlarında kullanılabilirliğe sahip olmanın avantajlarını da içermektedir.

7.2 Öneriler ve Gelecek Çalışmalar

Geliştirilen çerçevede, görüntü verilerinin elde edilmesi aşamasında 2 farklı görüntü veriseti (Flavia ve Caltech-101) kullanılmasına rağmen literatürde çok sayıda görüntü veriseti bulunmaktadır. Çerçeveyi test etmek amacıyla da 2 farklı görüntü veriseti (COIL-20 ve COIL-100) kullanılmasının dışında, veriseti çeşitliliği artırılarak sınıflandırma başarımları değerleri elde edilip karşılaştırılabilir.

Bu çalışmada, görüntü bölütlemeye ayrıntılı olarak odaklanılmamıştır. Bölütlemeyi de içeren ön işleme aşaması farklı görüntü türlerine göre değişiklik gösterebilmektedir. Bu nedenle, görüntü bölütleme her farklı problem için ilgili

görüntü türlerine özel olarak gerçekleştirilmelidir. Bu kapsamda, bölütlemenin hazır olarak sağlandığı ya da kolay bölütlenebilen görüntülerin kullanılması önerilmektedir.

Tez çalışmasında 194 adet handcrafted öznitelik kullanılsa da literatürde uygulanan öznitelik çıkarma yöntemleri oldukça geniştir ve çeşitlidir. Bu nedenle, 194'ten çok daha fazla sayıda öznitelik çıkartılabilir ve çalışmalarda kullanılabilir. İleriki çalışmalarda, daha farklı öznitelik çıkarma yöntemlerinin uygulanması da hedeflenmektedir. Bu kapsamda, şekle ve dokuya dayalı öznitelikler dışında renge dayalı öznitelikler kullanılarak da renkli görüntülerde daha başarılı sonuçların alınması sağlanabilir.

Derin öğrenme modellerinde farklı mimarilerin ve katmanlarının öznitelik çıkarmada başarımı değişkenlik gösterebilmektedir. Bu durum, kullanılan mimarinin özelliklerine, verisetine bağlı olarak farklı sonuçlar alınabileceği biçiminde yorumlanabilir.

Öznitelik çıkarmaya benzer biçimde literatürde öznitelik seçiminde sarmalayıcı yöntemler kapsamında farklı metasezgisel algoritmalar kullanılarak sonuçlar alınabilir. Metasezgisel algoritmalar parametre farklılıklarına ve kendi algoritma başarımlarına göre karşılaştırılabilir. Çalışma kapsamında büyük boyutlu öznitelik sayısı ve farklı verisetleri ile çalışıldığından uygunluk hesaplama işlemi oldukça zaman almaktadır. Ayrıca, uygunluk fonksiyonunun etkin bir biçimde çalışması adına 5 katlı çapraz geçerleme yöntemi de uygulanmıştır. Bu nedenle, sadece ECOC-SVM modeli dikkate alınarak öznitelik seçimi sağlanmıştır. Filtre tabanlı öznitelik seçim yöntemlerinin uygulanması ile daha hızlı sonuçlar alınabilir.

Sınıflandırma aşamasında, sınıflandırıcı çeşitliliği artırılarak veya topluluk sınıflandırıcıları kullanılarak başarımlarını yükseltilebilir. İleriki çalışmalarda, çeşitli topluluk sınıflandırıcılarının (Bagging, Boosting, Stacking vb.) kullanılması da hedeflenmektedir.

KAYNAKLAR DİZİNİ

- Abbas, Q.**, 2017, Glaucoma-Deep: detection of glaucoma eye disease on retinal fundus images using deep learning, International Journal of Advanced Computer Science and Applications, 8(6):41-45pp.
- Acharya, U. R., Faust, O., Molinari, F., Sree, S. V., Junnarkar, S. P., and Sudarshan, V.**, 2015, Ultrasound-based tissue characterization and classification of fatty liver disease: A screening and diagnostic paradigm. Knowledge-Based Systems, 75:66-77pp.
- Ahonen, T., Hadid, A. and Pietikainen, M.**, 2006, Face description with local binary patterns: Application to face recognition, IEEE Transactions on Pattern Analysis and Machine Intelligence, 28(12):2037-2041pp.
- ali Bagheri, M., Montazer, G. A. and Escalera, S.**, 2012, Error correcting output codes for multiclass classification: application to two image vision problems. In Artificial Intelligence and Signal Processing (AISP), 2012 16th CSI International Symposium on IEEE, 508-513pp.
- Allwein, E. L., Schapire, R. E. and Singer, Y.**, 2000, Reducing multiclass to binary: A unifying approach for margin classifiers. Journal of machine learning research, 1(Dec):113-141pp.
- Arel, I., Rose, D. C. and Karnowski, T. P.**, 2010, Deep machine learning-a new frontier in artificial intelligence research [research frontier], IEEE computational intelligence magazine, 5(4):13-18pp.
- Arevalo, J., González, F. A., Ramos-Pollán, R., Oliveira, J. L. and Lopez, M. A. G.**, 2016, Representation learning for mammography mass lesion classification with convolutional neural networks, Computer methods and programs in biomedicine, 127:248-257pp.
- Asht, S. And Dass, R.**, 2012, Pattern Recognition Techniques: A Review, International Journal of Computer Science and Telecommunications, 3(8):25-29pp.
- Bengio, Y.**, 2009, Learning deep architectures for AI, Foundations and trends® in Machine Learning, 2(1), 127p.

KAYNAKLAR DİZİNİ (devam)

- Bhatia, N. and Vandana, S.**, 2010, Survey of Nearest Neighbor Techniques, International Journal of Computer Science and Information Security, 8(2):302-305pp.
- Bianconi, F. and Fernández, A.**, 2014, Rotation invariant co-occurrence features based on digital circles and discrete Fourier transform. *Pattern Recognition Letters*, 48:34-41pp.
- Bishop, C.M.**, 2006, Pattern Recognition and Machine Learning, Springer, 738p.
- Born, M. and Wolf, E.**, 1975, Principles of Optics, Newyork:Pergamon.
- Breiman, L.**, 2001, Random forests, Machine learning, 45(1):5-32pp.
- Bui, H. M., Lech, M., Cheng, E., Neville, K., Wilkinson, R. and Burnett, I. S.**, 2018, Randomized dimensionality reduction of deep network features for image object recognition, In Recent Advances in Signal Processing, Telecommunications & Computing (SigTelCom), 2018 2nd International Conference on, 136-141pp.
- Busuttil, S., Abela, J., and Pace, G. J.**, 2004, Support vector machines with profile-based kernels for remote protein homology detection, Genome Informatics, 15(2):191-200pp.
- Caltech University**, "Computational Vision at Caltech", http://www.vision.caltech.edu/Image_Datasets/Caltech101/ (2006) (Erişim Tarihi: 28 Ekim 2017)
- Chamasemani, F. F. and Singh, Y. P.**, 2011, Multi-class support vector machine (SVM) classifiers--an application in hypothyroid detection and classification. In Bio-Inspired Computing: Theories and Applications (BIC-TA), 2011 Sixth International Conference on IEEE, 351-356pp.
- Chandrashekar, G. and Sahin, F.**, 2014, A survey on feature selection methods. Computers and Electrical Engineering, 40(1):16-28pp.
- Chatfield, K., Simonyan, K., Vedaldi, A. and Zisserman, A.**, 2014, Return of the devil in the details: Delving deep into convolutional nets, arXiv preprint arXiv:1405.3531.

KAYNAKLAR DİZİNİ (devam)

- Chellappa, R. and Chatterjee, S.,** 1985, Classification of textures using Gaussian Markov random fields, IEEE Transactions on Acoustics, Speech, and Signal Processing, 33(4):959-963pp.
- Chen, J., Ou, Q., Chi, Z. and Fu, H.,** 2017, Smile detection in the wild with deep convolutional neural networks, Machine vision and applications, 28(1-2):173-183pp.
- Cornell Univ.,** JPEG compression and ethernet communication on an FPGA, https://people.ece.cornell.edu/land/courses/ece5760/FinalProjects/f2009/jl589_jbw48/jl589_jbw48/index.html, (Erişim Tarihi: 3 Aralık 2017)
- Cover, T. and Hart, P.,** 1967, Nearest neighbor pattern classification. IEEE transactions on information theory, 13(1):21-27pp.
- Cross, G. R. and Jain, A. K.,** 1983, Markov random field texture models. IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-5(1):25-39pp.
- Cruz-Roa, A. A., Ovalle, J. E. A., Madabhushi, A. and Osorio, F. A. G.,** 2013, A deep learning architecture for image representation, visual interpretability and automated basal-cell carcinoma cancer detection, International Conference on Medical Image Computing and Computer-Assisted Intervention, Springer, 403-410pp.
- Çuğu, İ., Şener, E., Erciyes, Ç., Balcı, B., Akın, E., Önal, I. ve Akyüz, A. O.,** 2017, Treelogy: A Novel Tree Classifier Utilizing Deep and Hand-crafted Representations, arXiv preprint arXiv:1701.08291.
- Dabbaghchian, S., Ghaemmaghami, M. P. and Aghagolzadeh, A.,** 2010, Feature extraction using discrete cosine transform and discrimination power analysis with a face recognition technology, Pattern Recognition, 43(4):1431-1440pp.
- Dash, M. and Liu, H.,** 1997, Feature selection for classification. Intelligent data analysis, 1(1-4):131-156pp.

KAYNAKLAR DİZİNİ (devam)

- Derin, H. and Elliott, H.,** 1987, Modeling and segmentation of noisy and textured images using Gibbs random fields, IEEE Transactions on pattern analysis and machine intelligence, PAMI-9(1), 39-55pp.
- De Sa, J. P. M.,** 2001, Pattern Recognition: Concepts, Methods and Applications. Springer Science & Business Media, 318p.
- Dietterich, T. G. and Bakiri, G.,** 1995, Solving multiclass learning problems via error-correcting output codes, Journal of artificial intelligence research, 2:263-286pp.
- Donahue, J., Jia, Y., Vinyals, O., Hoffman, J., Zhang, N., Tzeng, E. and Darrell, T.,** 2014, Decaf: A deep convolutional activation feature for generic visual recognition, In International conference on machine learning, 647-655pp.
- Dutt, V., Chaudhry, V. and Khan, I.,** 2012, Pattern recognition: an overview, American Journal of Intelligent Systems, 2(1):23-27pp.
- Ehsanirad, A.,** 2010, Plant classification based on leaf recognition, International Journal of Computer Science and Information Security (IJCSIS), 8(4):78-81pp.
- Eid, H. F., Hassanien, A. E. and Kim, T. H.,** 2015, Leaf plant identification system based on Hidden Naïve bays classifier, In Advanced Information Technology and Sensor Application (AITS), 2015 4th International Conference on IEEE, 76-79pp.
- Eleyan, A. and Demirel, H.,** 2011, Co-occurrence matrix and its statistical features as a new approach for face recognition, *Turk J Elec Eng & Comp Sci*, 19(1):97-107pp.
- Escalera, S., Tax, D. M., Pujol, O., Radeva, P. And Duin, R. P.,** 2011, Multi-class classification in image analysis via error-correcting output codes. In Innovations in Intelligent Image Analysis, Springer, Berlin, Heidelberg, 7-29pp.

KAYNAKLAR DİZİNİ (devam)

- Fawcett, T.**, 2006, An introduction to ROC analysis, Pattern recognition letters, 27(8):861-874pp.
- Fei-Fei, L., Fergus, R. and Perona, P.**, 2006, One-shot learning of object categories. IEEE Transactions on Pattern Analysis and Machine Intelligence, 28(4):594-611pp.
- Flusser, J., Zitova, B. and Suk, T.**, 2009, Moments and moment invariants in pattern recognition, John Wiley & Sons, 312p.
- Fraiwan, L., Lweesy, K., Khasawneh, N., Wenz, H. and Dickhaus, H.**, 2012, Automated sleep stage identification system based on time–frequency analysis of a single EEG channel and random forest classifier, Computer methods and programs in biomedicine, 108(1): 10-19pp.
- Freund, Y. and Schapire, R. E.**, 1997, A decision-theoretic generalization of on-line learning and an application to boosting, Journal of computer and system sciences, 55(1):119-139pp.
- Friedman, M. and Kandel A.**, 1999, Introduction to Pattern Recognition: Statistical, Structural, Neural and Fuzzy Logic Approaches, World Scientific, Series in Machine Perception and Artificial Intelligence Volume 32, 329p.
- Fu, J.J.C., Yu, Y.W., Lin, H.M., Chai, J.W. and Chen, C.C.C.**, 2014, Feature extraction and pattern classification of colorectal polyps in colonoscopic imaging, Computerized Medical Imaging and Graphics, 38(4): 267-275pp.
- Fukunaga, K.**, 1990, Introduction to Statistical Pattern Recognition, Second Edition, Academic Press, 591p.
- Ghazi, M. M., Yanikoglu, B. and Aptoula, E.**, 2017, Plant identification using deep neural networks via optimization of transfer learning parameters, Neurocomputing, 235:228-235pp.
- Gnana, D. A. A., Appavu, S. and Leavline, E. J.**, 2016, Literature Review on Feature Selection Methods for High-Dimensional Data, International Journal of Computer Applications, 136(1):9-17pp.

KAYNAKLAR DİZİNİ (devam)

- Gonzalez, R. C. and Woods, R. E.,** 2002, Digital image processing, Prentice Hall, 793p.
- Goodfellow I., Bengio Y. and Courville A.,** 2016, Deep Learning, MIT Press, 787p.
- Gopalakrishnan, K., Khaitan, S. K., Choudhary, A. and Agrawal, A.,** 2017, Deep Convolutional Neural Networks with transfer learning for computer vision-based data-driven pavement distress detection. Construction and Building Materials, 157:322-330pp.
- Grenander, U.,** 1994, General Pattern Theory, Oxford Univ. Press, 906p.
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S. and Lew, M. S.,** 2016, Deep learning for visual understanding: A review. Neurocomputing, 187:27-48pp.
- Gutierrez-Osuna, R.,** 2017a, "Lecture 1: Course Introduction", http://www.nada.kth.se/~stefanc/DATORSEENDE_AK/pr_11.pdf (Erişim tarihi: 23 Ağustos 2017)
- Gutierrez-Osuna, R.,** 2017b, "L11: Sequential Feature Selection", http://research.cs.tamu.edu/prism/lectures/pr/pr_111.pdf, (Erişim Tarihi: 12 Mayıs 2017).
- Guyon, I. and Elisseeff, A.,** 2003, An Introduction to Variable and Feature Selection, Journal of Machine Learning Research, 3:1157-1182pp.
- Hall, D., McCool, C., Dayoub, F., Sunderhauf, N. and Upcroft, B.,** 2015, Evaluation of features for leaf classification in challenging conditions. IEEE Winter Conference on Applications of Computer Vision (WACV), 797-804pp.
- Haralick, R. M.,** 1979, Statistical and structural approaches to texture, Proceedings of the IEEE, 67(5):786-804pp.
- Haralick, R. M., Shanmugam, K. and Dinstein, I.,** 1973, Textural Features for Image Classification, IEEE Transactions on Systems, Man, and Cybernetics, SMC-3 (6): 610–621pp.

KAYNAKLAR DİZİNİ (devam)

- He, K., Zhang, X., Ren, S. and Sun, J.,** 2015, Spatial pyramid pooling in deep convolutional networks for visual recognition. *IEEE transactions on pattern analysis and machine intelligence*, 37(9):1904-1916pp.
- Hoque, N., Bhattacharyya, D. K. and Kalita, J. K.,** 2014, MIFS-ND: a mutual information-based feature selection method, *Expert Systems with Applications*, 41(14):6371-6385pp.
- Hossain, J. and Amin, M. A.,** 2010, Leaf shape identification based plant biometrics, *IEEE 13th International Conference on Computer and Information Technology (ICCIT)*, 458-463pp.
- Hsu, P. H.,** 2007, Feature extraction of hyperspectral images using wavelet and matching pursuit, *ISPRS Journal of Photogrammetry & Remote Sensing*, 62(2):78-92pp.
- Hu, M-K,** 1962, Visual Pattern Recognition by Moment Invariants, *Information Theory (IEEE Transactions on)*, 8(2):179-187pp.
- Huang, Z., and Leng, J.,** 2010, Analysis of Hu's moment invariants on image scaling and rotation, In *Computer Engineering and Technology (ICCET)*, IEEE 2nd International Conference on, 7:V7-476-V7-480pp.
- ImageNet,** 2018, <http://www.image-net.org>, (Erişim Tarihi: 17 Nisan 2018).
- Ishwaran, H. and Rao, J. S.,** Decision Tree: Introduction, http://web.ccs.miami.edu/~hishwaran/papers/decisionTree_intro_IR2009_EMDM.pdf (Erişim Tarihi: 1 Mart 2018), 323-328pp.
- Jain, A.K. and Duin, R.P.W,** “Introduction to Pattern Recognition”, <https://pdfs.semanticscholar.org/d3c5/b56265658256f51b8abcb8048f5ff4281c09.pdf> (Erişim Tarihi: 9 Ağustos 2017)
- Jain, A.K., Duin, R.P.W. and Mao, J.,** 2000, Statistical Pattern Recognition: A Review, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(1):4-37pp.

KAYNAKLAR DİZİNİ (devam)

- Jin, L., Gao, S., Li, Z. and Tang, J.,** 2014, Hand-crafted features or machine learnt features? together they improve RGB-D object recognition. IEEE International Symposium on Multimedia (ISM), 311-319pp.
- Jović, A., Brkić, K. and Bogunović, N.,** 2015, A Review Of Feature Selection Methods with Applications, MIPRO, 1200-1205pp.
- Kabbai, L., Abdellaoui, M. and Douik, A.,** 2018, Image classification by combining local and global features. The Visual Computer, 1-15pp.
- Kadir, A., Nugroho, L. E., Susanto, A. and Santosa, P. I.,** 2013, Leaf classification using shape, color, and texture features, arXiv preprint arXiv:1401.4447.
- Keller, J. M., Gray, M. R. and Givens, J. A.,** 1985, A fuzzy k-nearest neighbor algorithm. IEEE transactions on systems, man, and cybernetics, (4):580-585pp.
- Khan, R., Barat, C., Muselet, D. and Ducottet, C.,** 2015, Spatial histograms of soft pairwise similar patches to improve the bag-of-visual-words model, Computer Vision and Image Understanding, 132, 102-112pp.
- Khan, S. H., Hayat, M., Bennamoun, M., Sohel, F. A. and Togneri, R.,** 2017, Cost-Sensitive learning of deep feature representations from imbalanced data. IEEE transactions on neural networks and learning systems.
- Kingsford, C., and Salzberg, S. L.,** 2008, What are decision trees?, Nature biotechnology, 26(9), 1011-1013pp.
- Kpalma, K. and Ronsin J.,** 2007, An Overview of Advances of Pattern Recognition Systems in Computer Vision, Vision Systems: Segmentation and Pattern Recognition, 169-194pp.
- Krizhevsky, A., Sutskever, I. and Hinton, G. E.,** 2012, Imagenet classification with deep convolutional neural networks, In Advances in neural information processing systems, 1097-1105pp.

KAYNAKLAR DİZİNİ (devam)

- Kumar, P. S., Rao, K. N. V., Raju, A. S. N. and Kumar, D. N.,** 2016, Leaf classification based on Shape and Edge feature with k-NN Classifier, In Contemporary Computing and Informatics (IC3I), 2016 2nd International Conference on IEEE, 548-552pp.
- Kumar, V. and Minz, S.,** 2014, Feature Selection: A literature Review. SmartCR, 4(3):211-229pp.
- Kunaver, M. and J. F. Tasic.,** 2005, Image feature extraction-an overview, *Computer as a Tool, EUROCON, The International Conference on*, 1:183-186pp.
- Kusy, M. and Zajdel, R.,** 2015, Probabilistic Neural Network Training Procedure with the Use of SARSA Algorithm, In International Conference on Artificial Intelligence and Soft Computing, Springer, Cham, 49-58pp.
- Lazebnik, S., Schmid, C. and Ponce, J.,** 2006, Beyond bags of features: Spatial pyramid matching for recognizing natural scene categories. In Computer vision and pattern recognition, IEEE computer society conference on, 2:2169-2178pp.
- Lee, S. H., Chan, C. S., Mayo, S. J. and Remagnino, P.,** 2017, How deep learning extracts and learns leaf features for plant classification, Pattern Recognition, 71, 1-13pp.
- Levine, M. D.,** 1985, Vision in man and machine. McGraw-Hill College, 574p.
- Liu, N. and Kan, J. M.,** 2016, Plant leaf identification based on the multi-feature fusion and deep belief networks method. Journal of Beijing Forestry University, 38(3):110-119pp.
- Lin, Y., Lv, F., Zhu, S., Yang, M., Cour, T., Yu, K., Cao, L. and Huang, T.,** 2011, Large-scale image classification: fast feature extraction and svm training. In Computer Vision and Pattern Recognition (CVPR), 2011 IEEE Conference on, 1689-1696pp.

KAYNAKLAR DİZİNİ (devam)

- Liu, H. and Setiono, R.**, 1996, A probabilistic approach to feature selection-a filter solution, International Conference on Machine Learning (ICML), 96:319-327pp.
- Liu, H. and Yu, L.**, 2005, Toward Integrating Feature Selection Algorithms for Classification and Clustering, IEEE Transactions on Knowledge and Data Engineering, 17(4):491-502pp.
- Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y. and Alsaadi, F. E.**, 2017, A survey of deep neural network architectures and their applications. Neurocomputing, 234:11-26pp.
- Liu, Z., He, Y., Xie, Y., Gu, H., Liu, C. and Pei, M.**, 2016, Pedestrian detection using deep channel features in monocular image sequences, International Conference on Neural Information Processing, Springer International Publishing, 608-615pp.
- Loh, W. Y.**, 2011, Classification and regression trees. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 1(1):14-23pp.
- Mago, V. K. and Bhatia, N.**, 2011, Cross-Disciplinary Applications of Artificial Intelligence and Pattern Recognition: Advancing Technologies, IGI Global, 786p.
- Maldonado, S. and Weber, R.**, 2009, A wrapper method for feature selection using support vector machines, Information Sciences, 179(13):2208-2217pp.
- Man, K. F., Tang, K. S. and Kwong, S.**, 1996, Genetic algorithms: concepts and applications [in engineering design], IEEE transactions on Industrial Electronics, 43(5), 519-534pp.
- Mani, K. and Kalpana, P.**, 2016, A review on filter based feature selection, International Journal of Innovative Research in Computer and Communication Engineering (IJIRCCE), 4(5):9146-9156pp.
- Manjunath, B. S. and Chellappa, R.**, 1991, Unsupervised texture segmentation using Markov random field models, IEEE Transactions on Pattern Analysis and Machine Intelligence, 13(5):478-482pp.

KAYNAKLAR DİZİNİ (devam)

- Mansourian, L., Abdullah, M. T., Abdullah, L. N., Azman, A. and Mustaffa, M. R.**, 2017, An effective fusion model for image retrieval. Multimedia Tools and Applications, 1-24pp.
- Markovitch, S. and Rosenstein, D.**, 2002, Feature Generation Using General Constructor Functions, Machine Learning, 49:59-98pp.
- Martinez-Arroyo, M. and Sucar, L. E.**, 2006, Learning an optimal naive bayes classifier, In Pattern Recognition, ICPR 18th International Conference on IEEE, 3:1236-1239pp.
- Materka, A. and Strzelecki, M.**, 1998, Texture Analysis Methods – A Review, COST B11 Report, Technical University of Lodz, Brussels, 33p.
- MathWorks Inc.**, 2018, alexnet, <https://www.mathworks.com/help/nnet/ref/alexnet.html>, (Erişim Tarihi: 17 Nisan 2018).
- MathWorks Inc.**, mapminmax, https://www.mathworks.com/help/nnet/ref/mapminmax.html?s_tid=gn_loc_drop (Erişim Tarihi: 18 Şubat 2018).
- MathWorks Inc.**, Matlab R2017b documentation, <http://www.mathworks.com/help/index.html> (Erişim Tarihi: 30 Ekim 2017).
- MathWorks Inc.**, vgg16, <https://www.mathworks.com/help/nnet/ref/vgg16.html>, (Erişim Tarihi: 10 Mayıs 2018).
- MathWorks Inc.**, vgg19, <https://www.mathworks.com/help/nnet/ref/vgg19.html>, (Erişim Tarihi: 10 Mayıs 2018).
- Minitab Inc.**, Select the statistics for descriptive statistics (Statistics tab), <http://support.minitab.com/en-us/minitab-express/1/help-and-how-to/basic-statistics/summary-statistics/descriptive-statistics/perform-the-analysis/select-the-statistics-to-display/#interquartile-range> (Erişim Tarihi: 11 Kasım 2017).
- Mitchell, M.**, 1998, An introduction to genetic algorithms, MIT press, 158p.

KAYNAKLAR DİZİNİ (devam)

- Mohammadi, S.M., Helfroush M.S. and Kazemi, K.,** 2012, Novel Shape-Texture Feature Extraction for Medical X-Ray Image Classification, International Journal of Innovative Computing, Information and Control, 8(1B):659-676pp.
- Motoda, H. and Liu, H.,** 1998, Feature Extraction, Construction and Selection: A Data Mining Perspective, Kluwer Academic Publishers Norwell, USA, 410p.
- Munisami, T., Ramsurn, M., Kishnah, S. and Pudaruth, S.,** 2015, Plant leaf recognition using shape features and colour histogram with K-nearest neighbour classifiers, Procedia Computer Science, 58:740-747pp.
- Mutch, J., and Lowe, D. G.,** 2006, Multiclass object recognition with sparse, localized features, In Computer Vision and Pattern Recognition, 2006 IEEE Computer Society Conference on, 1:11-18pp.
- Nabiyev, V. V. and Günay, A.,** 2010, LBP yardımıyla görüntüdeki kişinin yaşının bulunması, Çankaya University Journal of Science and Engineering, 8(1):27-41pp.
- Nene, S. A., Nayar, S. K. and Murase, H.,** 1996a, Columbia Object Image Library (COIL-20), Technical Report CUCS-005-96.
- Nene, S. A., Nayar, S. K. and Murase, H.,** 1996b, Columbia Object Image Library (COIL-100), Technical Report CUCS-006-96.
- Ojala, T., Pietikäinen, M. and Harwood, D.,** 1996, A comparative study of texture measures with classification based on featured distributions, Pattern recognition, 29(1):51-59pp.
- Ojala, T., Pietikainen, M., and Maenpaa, T.,** 2002, Multiresolution gray-scale and rotation invariant texture classification with local binary patterns, IEEE Transactions on pattern analysis and machine intelligence, 24(7):971-987pp.
- Otsu, N.,** 1979, A threshold selection method from gray-level histograms. IEEE Trans. Syst. Man Cybern., 9(1):62–66pp.

KAYNAKLAR DİZİNİ (devam)

- Pei, Y. and Cao, W.**, 2010, A Method for Regional Feature Extraction of Flower Images, International Conference on Intelligent Control and Information Processing, 384-388pp.
- Pentland, A. P.**, 1984, Fractal-based description of natural scenes. IEEE transactions on pattern analysis and machine intelligence, PAMI-6(6), 661-674pp.
- Prasad, S., Kumar, P. S. and Ghosh, D.**, 2017, An efficient low vision plant leaf shape identification system for smart phones, Multimedia Tools and Applications, 76(5), 6915-6939pp.
- PyActLearn**, Multi-Class Performance Metrics, <http://pyactlearn.readthedocs.io/en/latest/performance/multiclass.html>, (Erişim Tarihi: 10 Mayıs 2018)
- Rahman, M. M., Rahman, S., Rahman, R., Hossain, B. M. and Shoyaib, M.**, 2017, DTCTH: a discriminative local pattern descriptor for image classification. EURASIP Journal on Image and Video Processing, 2017(1):30.
- Ramesh, B., Xiang, C. and Lee, T. H.**, 2017, Multiple object cues for high performance vector quantization. Pattern Recognition, 67:380-395pp.
- Rojas-Hernández, R., López-Chau, A., Trujillo-Mora, V. and Rojas-Hernández, C. A.**, 2016, Plant identification using new geometric features with standard data mining methods. IEEE International Conference on Networking, Sensing, and Control (ICNSC), 1-4pp.
- Rosenfeld, A. and Kak, A.**, 1982, Digital Picture Processing Volume 1, Academic Press, 435p.
- Ruiz, L. A., Fdez-Sarría, A. and Recio, J. A.**, 2004, Texture Feature Extraction for Classification of Remote Sensing Data Using Wavelet Decomposition: a Comparative Study, 20th ISPRS Congress, 35(B):1109-1114pp.

KAYNAKLAR DİZİNİ (devam)

- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., et al.,** 2015, Imagenet large scale visual recognition challenge, International Journal of Computer Vision, 115(3):211-252pp.
- R Tutorial,** Central Moment, <http://www.r-tutor.com/elementary-statistics/numerical-measures/moment> (Erişim Tarihi: 15 Kasım 2017).
- Saeys, Y., Inza, I. and Larranaga, P.,** 2007, A Review of Feature Selection Techniques in Bioinformatics, Bioinformatics, 23(19):2507-2517pp.
- Satpathy, A., Jiang, X. and Eng, H. L.,** 2014, LBP-based edge-texture features for object recognition. IEEE Transactions on Image Processing, 23(5):1953-1964pp.
- Satti, V., Satya, A. and Sharma, S.,** 2013, An automatic leaf recognition system for plant identification using machine vision technology. International journal of engineering science and technology, 5(4):874-879pp.
- Schapire, R. E.,** 2013, Explaining adaboost, In Empirical inference, Springer, Berlin, Heidelberg, 37-52pp.
- Scholarpedia,** Local binary patterns, http://www.scholarpedia.org/article/Local_Binary_Patterns, (Erişim Tarihi: 4 Aralık 2017).
- Scikit-learn,** Decision Trees, <http://scikit-learn.org/stable/modules/tree.html>, (Erişim Tarihi: 1 Mart 2018).
- Sebastian, V., Unnikrishnan, A. and Balakrishnan, K.,** 2012, Gray level co-occurrence matrices: generalisation and some new features, arXiv preprint arXiv:1205.4831, International Journal of Computer Science, Engineering and Information Technology, 2(2):151-157pp.
- Shah, M. P., Singha, S. and Awate, S. P.,** 2017, Leaf classification using marginalized shape context and shape+ texture dual-path deep convolutional neural network. In Image Processing (ICIP), 2017 IEEE International Conference on, 860-864pp.

KAYNAKLAR DİZİNİ (devam)

- Shutler, J.,** Complex Zernike moments, https://homepages.inf.ed.ac.uk/rbf/CVonline/LOCAL_COPIES/SHUTLER3/node11.html, (2002) (Erişim Tarihi: 3 Aralık 2017)
- Simonyan, K. and Zisserman, A.,** 2014, Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
- Soh, L. K. and Tsatsoulis, C.,** 1999, Texture analysis of SAR sea ice imagery using gray level co-occurrence matrices, IEEE Transactions on geoscience and remote sensing, 37(2):780-795pp.
- Sokolova, M. and Lapalme, G.,** 2009, A systematic analysis of performance measures for classification tasks. Information Processing & Management, 45(4):427-437pp.
- Specht, D. F.,** (1988, July), Probabilistic neural networks for classification, mapping, or associative memory, In IEEE international conference on neural networks, 1(24):525-532pp.
- Specht, D. F.,** 1992, Enhancements to probabilistic neural networks, In Neural Networks, IJCNN., International Joint Conference on IEEE, 1:761-768pp.
- Srinivas, M. and Patnaik, L. M.,** 1994, Genetic algorithms: A survey. computer, 27(6), 17-26pp.
- Srinivasan, G.N. and Shobha, G.,** 2008, Statistical Texture Analysis, Proceedings of World Academy of Science, Engineering and Technology, 36:6pp.
- Stein, G., Chen, B., Wu, A. S. and Hua, K. A.,** 2005, Decision tree classifier for network intrusion detection with GA-based feature selection, ACM Proceedings of the 43rd annual Southeast regional conference, Volume 2:136-141pp.
- Strzelecki, M. and Materka, A.,** 1997, Markov random fields as models of textured biomedical images, In Proc. 20th National Conf. Circuit Theory and Electronic Networks, 493-498pp.

KAYNAKLAR DİZİNİ (devam)

- Suk, H. I., Lee, S. W., Shen, D. and Alzheimer's Disease Neuroimaging Initiative,** 2014, Hierarchical feature representation and multimodal fusion with deep learning for AD/MCI diagnosis, *NeuroImage*, 101:569-582pp.
- Sun, Y., Liu, Y., Wang, G. and Zhang, H.,** 2017, Deep Learning for Plant Identification in Natural Environment, *Computational intelligence and neuroscience*, 2017.
- Sutton, R. S. and Barto, A. G.,** 2012, Reinforcement Learning: An Introduction, Second Edition, (Vol. 1, No. 1). Cambridge: MIT press, 320p.
- Tahmasbi, A., Saki, F. and Shokouhi, S. B.,** 2011, Classification of benign and malignant masses based on Zernike moments. *Computers in biology and medicine*, 41(8):726-735pp.
- Taşcı, E.,** 2013, Akciğer tomografileri kullanılarak yapay zeka ve görüntü işleme tekniklerine dayalı otomatik nodül bölge tespit yöntemi geliştirilmesi, Yüksek Lisans Tezi, Ege Üniversitesi, 104s (yayınlanmamış).
- Taşcı, E. and Uğur, A.,** 2018, Image Classification Using Ensemble Algorithms with Deep Learning and Hand-Crafted Features, In *Signal Processing and Communications Applications Conference (SIU)*, 2018 26th, IEEE.
- Teh, C. H. and Chin, R. T.,** 1988, On image analysis by the methods of moments. *IEEE Transactions on pattern analysis and machine intelligence*, 10(4):496-513pp.
- Theodoridis, S. and Koutroumbas, K.,** 2009, *Pattern Recognition*, Fourth Edition, Academic Press, US, 967p.
- Tian, D. P.,** 2013, A review on image feature extraction and representation techniques, *International Journal of Multimedia and Ubiquitous Engineering*, 8(4):385-396pp.
- Turkoglu, M. ve Hanbay, D.,** 2015, Classification of the grape varieties based on leaf recognition by using SVM classifier. In *Signal Processing and Communications Applications Conference (SIU)*, 2674-2677pp.

KAYNAKLAR DİZİNİ (devam)

- Uluturk, C. and Ugur, A.,** 2012, Recognition of leaves based on morphological features derived from two half-regions, International Symposium on Innovations in Intelligent Systems and Applications, 1-4pp.
- Vamvakas, G., Gatos, B. and Perantonis, S.J.,** 2009, A Novel Feature Extraction and Classification Methodology for the Recognition of Historical Documents, International Conference on Document Analysis and Recognition, 491-495pp.
- Vapnik, V.,** 1979, Estimation of Dependences Based on Empirical Data [in Russian]. Nauka, Moscow, (English translation: Springer Verlag, New York, 1982).
- Venguerov, M. and Cunningham, P.,** 1998, Generalised syntactic pattern recognition as a unifying approach in image analysis, Advances in Pattern Recognition, 1451:913-920pp.
- Vidaurreta, V. A.,** 2015, Ultrasound Image Discrimination Between Benign and Malignant Adnexal Masses, Master Thesis, Public University of Navarre, 64p (yayınlanmamış).
- Wang, R.,** 2012, AdaBoost for feature selection, classification and its relation with SVM, a review, Physics Procedia, 25:800-807pp.
- Wang, X., Bai, X., Liu, W. and Latecki, L. J.,** 2011, Feature context for image classification and object detection. In Computer Vision and Pattern Recognition (CVPR), 2011 IEEE Conference on, 961-968pp.
- Wang, C., Elazab, A., Wu, J., and Hu, Q.,** 2017, Lung nodule classification using deep feature fusion in chest radiography, Computerized Medical Imaging and Graphics, 57:10-18pp.
- Wäldchen, J. and Mäder, P.,** 2017, Plant Species Identification Using Computer Vision Techniques: A Systematic Literature Review, Archives of Computational Methods in Engineering, 1-37pp.
- Webb, A. R.,** 2002, Statistical Pattern Recognition, Second Edition, John Wiley & Sons, 496p.

KAYNAKLAR DİZİNİ (devam)

- Wolfram MathWorld**, Kurtosis, <http://mathworld.wolfram.com/Kurtosis.html> (Erişim Tarihi: 16 Kasım 2017).
- Wu, S. G., Bao, F. S., Xu, E. Y., Wang, Y., Chang, Y. and Xiang, Q., L.** 2007a, A leaf recognition algorithm for plant classification using probabilistic neural network, IEEE 7th International Symposium on Signal Processing and Information Technology, 11-16pp.
- Wu, S. G., Bao, F. S., Xu, E. Y., Wang, Y., Chang, Y. and Xiang, Q.,** “Flavia”, <http://flavia.sourceforge.net/> (2007b) (Erişim Tarihi: 12 Aralık 2016)
- Xue, B., Zhang, M., Browne, W. N. and Yao, X.,** 2016, A survey on evolutionary computation approaches to feature selection, IEEE Transactions on Evolutionary Computation, 20(4):606-626pp.
- Yadav, A.R., Anand, R.S., Dewal, M.L. and Gupta, S.,** 2015, Multiresolution local binary pattern variants based texture feature extraction techniques for efficient classification of microscopic images of hardwood species, Applied Soft Computing, 32:101-112pp.
- Yang, M., Kpalma, K. and Ronsin, J.,** 2008, A survey of shape feature extraction techniques, . Pattern Recognition, IN-TECH, 43-90pp.
- Yanikoglu, B., Aptoula, E. and Tirkaz, C.,** 2014, Automatic plant identification from photographs. Machine Vision and Applications, 25(6):1369-1383pp.
- Yousefi, E., Baleghi, Y. and Sakhaei, S. M.,** 2017, Rotation invariant wavelet descriptors, a new set of features to enhance plant leaves classification. Computers and Electronics in Agriculture, 140:70-76pp.
- Yu, L. and Liu, H.,** 2003, Feature selection for high-dimensional data: A fast correlation-based filter solution, Proceedings of the 20th international conference on machine learning (ICML-03), 2:856-863pp.
- Zhang, D. and Lu, G.,** 2004, Review of Shape Representation and Description Techniques, Pattern Recognition, 37(1):1-19pp.

KAYNAKLAR DİZİNİ (devam)

- Zhang, J., Marszałek, M., Lazebnik, S. And Schmid, C.,** 2007, Local features and kernels for classification of texture and object categories: A comprehensive study. International journal of computer vision, 73(2):213-238pp.
- Zhang, S. W., Shang, Y. J. and Wang, L.,** 2015, Plant disease recognition based on plant leaf image. Journal of Animal & Plant Sciences, 25(3):42-45pp.
- Zhong, G., Zheng, Y., Zhang, P., Li, M. and Dong, J.,** 2016, Deep Error-Correcting Output Codes.
- Zhu, X.,** “Semi-supervised learning literature survey”, Computer Sciences, University of Wisconsin-Madison,
http://pages.cs.wisc.edu/~jerryzhu/pub/ssl_survey.pdf (2008) (Erişim tarihi: 17 Ağustos 2017)
- Zhuo, L., Zheng, J., Li, X., Wang, F., Ai, B. and Qian, J.,** 2008, A genetic algorithm based wrapper feature selection method for classification of hyperspectral images using support vector machine, Proc. Geoinformat. Joint Conf. GIS Built Environ. Classif. Remote Sens. Images Int. Soc. Opt. Photonics, 7147.

