T.C.
İSTANBUL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

DESEN SINIFLANDIRMA İÇİN KORTİKAL GÖSTERİMLERİN GELENEKSEL GÖRÜNTÜ İŞLEME YÖNTEMLERİ İLE KARŞILAŞTIRILMASI

Hatice NİZAM

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

DANIŞMAN
Prof. Dr. Ahmet SERTBAŞ

Haziran, 2017

İSTANBUL

Bu çalışma 13.06.2017 tarihinde aşağıdaki jüri tarafından Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Programında Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Prof. Dr. Ahmet SERTBAŞ (Danışman)
İstanbul Üniversitesi
Mühendislik Fakültesi

Doç. Dr. Atakan KURT
İstanbul Üniversitesi
Mühendislik Fakültesi

Doç. Dr. Zeynep ORMAN
İstanbul Üniversitesi
Mühendislik Fakültesi

Yrd. Doç. Dr. Oğuzhan ÖZTAŞ
İstanbul Üniversitesi
Mühendislik Fakültesi

Yrd. Doç. Dr. Cemal Okan ŞAKAR
Bahçeşehir Üniversitesi
Mühendislik ve Doğa Bilimleri
Fakültesi

20.04.2016 tarihli resmi gazetede yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi'nin abonesi olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü'nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

ÖNSÖZ

Bu çalışma, İstanbul Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Yüksek Lisans kapsamında hazırlanan "Desen Sınıflandırma için Kortikal Gösterimlerin Geleneksel Görüntü İşleme Yöntemleri ile Karşılaştırılması" başlıklı yüksek lisans tez çalışmasını içermektedir.

Tez çalışmam sırasında bilgi, birikim ve tecrübeleri ile bana destek olan değerli danışman hocam Sayın Prof. Dr. Ahmet SERTBAŞ'a,

Bu çalışmayı hazırlarken geçirdiğim süreçte bilgi ve deneyimleri ile bana yol gösteren ve yardımını esirgemeyen Sayın Araş. Gör. Dr. M. Erdem İSENKUL'a en içten duygular ile teşekkür ederim.

Hayatımın her aşamasında yanımda olan, her koşulda maddi ve manevi desteklerini benden esirgemeyen sevgili annem, babam ve ablalarıma sonsuz teşekkür ederim.

Haziran, 2017 Hatice NİZAM

İÇİNDEKİLER

Sayfa No

ÖNSÖZ ..... **vi**
İÇİNDEKİLER ..... **vii**
ŞEKİL LİSTESİ ..... **ix**
TABLO LİSTESİ ..... **xii**
SİMGE VE KISALTMA LİSTESİ ..... **xiii**
ÖZET ..... **xiv**
SUMMARY ..... **xv**
1. GİRİŞ **1**
2. GENEL KISIMLAR **4**
2.1. GÖRME SİSTEMLERİ 4
2.1.1. Görme (Vision) Nedir? 4
2.1.2. İnsan Biyolojik Görme Sistemi Yapısı 4
2.1.2.1. Retina 6
2.1.2.2. Lateral Geniculate Nucleus (LGN) 7
2.1.2.3. Birincil Görme Korteksi (V1) 9
2.2. GÖRÜNTÜ İŞLEME 11
2.2.1. İmge (görüntü) nedir? 11
2.2.2. İmgenin Sayısal Ortamda İşlenmesi 12
2.3. DESEN TİPİ GÖRÜNTÜLER 13
2.3.1. Desen Nedir? 13
2.3.2. Desen Analizi 15
2.3.3. Desen Sınıflandırılması 16
2.3.4. Desen Sınıflandırılmasında Kullanılan Yöntemler ve Uygulama Alanları 18
2.4. DOĞAL TİP GÖRÜNTÜLER 21
2.4.1. Doğal Görüntüler Nedir? 21
2.5. ÖZNİTELİK ÇIKARIMI VE İSTATİSTİKSEL MODELLER 22
2.5.1. Piksel Özniteliklerinin Çıkarılması 23
2.5.2. Gabor Dalgacık Dönüşümü (GWT) Öznitelik Çıkarım Metodu 23

2.5.3. Yerel İkili Desen (LBP) Öznitelik Çıkarım Metodu 25
2.5.4. Katman-3 (L3) Veri İşleme Modeli 27
2.6. YAPAY ÖĞRENME VE İSTATİSTİKSEL ANALİZ 30
2.6.1. Yapay Öğrenme Nedir? 30
2.6.2. Öğrenme Yöntemleri 30
2.6.2.1. Ezbere Dayalı Öğrenme 31
2.6.2.2. Talimatlardan Öğrenme 31
2.6.2.3. Benzetim Yoluyla Öğrenme 31
2.6.2.4. Örneklerden Öğrenme 31
2.6.3. Modelleme 33
2.6.3.1. Destek Vektör Makineleri (DVM) 34
2.6.4. Model Seçimi ve Değerlendirme 36
2.6.4.1. Model Performans Değerlendirme Yöntemleri 37
2.6.4.2. Model Performans Değerlendirme Ölçütleri 39
3. MALZEME VE YÖNTEM 41
3.1. GEOMETRİK GÖRÜNTÜ DÖNÜŞÜMLERİ 41
3.1.1. Afin (Affine) Dönüşümler 42
3.1.1.1. Öteleme işlemi 42
3.1.1.2. Döndürme işlemi 43
3.1.1.3. Ölçekleme işlemi 43
3.1.1.4. Kesme işlemi 44
3.1.2. Perspektif Dönüşümler 44
3.2. HİSTOGRAM EŞİTLEME 44
3.3. TALAMİK KATMAN FİLTRESİ (DIFFERENCE OF GAUSSIANS: MEXICAN HAT) 45
4. BULGULAR 48
4.1. ÖTELEME SINIFLANDIRMA PROBLEMİ TESTİ 48
4.2. EĞİTİM ÖRNEK SAYISININ SINIFLANDIRMA PROBLEMİ ÜZERİNDEKİ ETKİSİNİN ÖLÇÜMÜ TESTİ 51
4.3. ÖZELLİK ÇIKARIM YÖNTEMLERİNİN PERFORMANSLARININ KARŞILAŞTIRILMASI TESTİ 56
4.2. ÇOKLU-ÖLÇEKLİ İMGELERİN SINIFLANDIRMA PROBLEMİ TESTİ 60
5. TARTIŞMA VE SONUÇ 65
KAYNAKLAR 68
ÖZGEÇMİŞ 73

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: Elektromanyatik spektrum. 5

Şekil 2.2: İnsan gözünün anatomik yapısı. 5

Şekil 2.3: Lateral geniculate nucleus (LGN) yapısı (van der Helm, 2012). 7

Şekil 2.4: LGN alıcı alanları ((Wikipedia, 2016),(Torres, 2012)). 8

Şekil 2.5: LGN alıcı alanları çıktısı (sol: girdi resmi (gri ölçeklemeli), sağ: nöral çıktı) (Heeger, 2006). 9

Şekil 2.6: İnsan görme sistemi genel yapısı ve görme korteksi (Obay, 2016). 9

Şekil 2.7: V1 alanındaki katmanların (2/3, 4, 5, 6) LGN ile bağlantısı (Nassi ve diğ.,2009)..... 10

Şekil 2.8: MxN boyutlu bir imgenin fx, y ışık-yoğunluk fonksiyonunun gösterimi. 11

Şekil 2.9: Sayısal görüntünün oluşumu. 12

Şekil 2.10: Doğal ve yapay desen örnekleri: ayçiçeği (a), saman (b), yaprak (c), gökyüzündeki bulutların görünümü (d), zebranın derisi (e), ağaç kabuğu (f), ahşap mobilya (g), taş duvar (h), duvar kaplama kâğıdı (i). 13

Şekil 2.11: (a) Normal-dağılımlı imge örneği (Hyvärinen, ve diğ., 2009), (b) normal-dağılımlı olmayan imge örneği. 14

Şekil 2.12: Brodatz albümü içerisindeki farklı sınıflara ait desen tipi görüntüler kümesi. 15

Şekil 2.13: Desen sınıflandırılması probleminin görsel gösterimi (Varma ve diğ., 2005). 18

Şekil 2.14: Tez kapsamında kullanılan beş farklı doğal görüntü veri kümesi (Favorov ve Kursun, 2011). 22

Şekil 2.15: Gabor filtresinin 3 ölçek ve 8 yönelimdeki büyüklük imgelerinin (ilk 3 satır) ve gerçel imgelerinin (son 3 satır) görünümü. 24

Şekil 2.16: (a) Orijinal LBP operatörü, (b) dairesel (8,1), (16,1) ve (8,2) komşuluklar (Zhao ve diğ., 2011). 25

Şekil 2.17: Parmak izi görüntüsünün orijinal LBP ve düzenli LBP histogramı (Tan ve diğ., 2016). 27

Şekil 2.18: Girdi uzayının "öznitelik" uzayına dönüşümü (Favorov ve Kursun, 2011). 27

Şekil 2.19: Kortikal sütundaki fonksiyon doğrusallaştırma yöntemi (Favorov ve Kursun, 2011). 29

Şekil 2.20: Yapay öğrenme modelleri (Mishchenko, 2017). 33

Şekil 2.21: İki sınıflı bir problem için hiper düzlemler (Wikipedia, 2017). 34

Şekil 2.22: Optimum hiper düzlem ve destek vektörleri (Wikipedia, 2017). 35

Şekil 2.23: Çoklu sınıf problemleri için hiper düzlemler. 36

Şekil 2.24: 5-kat çapraz geçerleme (Wikipedia, 2017). 38

Şekil 2.25: Bootstrap metodunun şematik gösterimi (Takma ve Atıl, 2003). 39

Şekil 3.1: Afin dönüşüm ve perpektif dönüşüm (Bradski ve Kaehler, 2008). 41

Şekil 3.2: Öteleme işlemi (Wikipedia, 2017). 42

Şekil 3.3: Döndürme işlemi (Wikipedia, 2017). 43

Şekil 3.4: Ölçekleme işlemi (Wikipedia, 2017). 43

Şekil 3.5: Kesme işlemi (Wikipedia, 2017). 44

Şekil 3.6: Histogram eşitleme (Wikipedia, 2017). 45

Şekil 3.7: Gaussların farkı: Meksikalı şapka dalgacık. 46

Şekil 3.8: Orijinal görüntü (a), talamik katman çıktısı (b). 46

Şekil 4.1: İmge pencerelerinin öteleme sınıflandırma testi için yerleşimleri. 48

Şekil 4.2: Öteleme sınıflandırma problemi testi DVM (rbf) performansları. 49

Şekil 4.3: Öteleme sınıflandırma problemi testi DVM (lineer) performansları. 50

Şekil 4.4: Test 1 sınıflandırma problemi testi DVM performansları. 52

Şekil 4.5: Test 2 sınıflandırma problemi testi DVM performansları. 52

Şekil 4.6: Test 3 sınıflandırma problemi testi DVM performansları. 53

Şekil 4.7: Test 4 sınıflandırma problemi testi DVM performansları. 53

Şekil 4.8: Test 5 sınıflandırma problemi testi DVM performansları. 54

Şekil 4.9: Orijinal desen imgelerinde özellik çıkarım yöntemlerinin performanslarının karşılaştırılması. 57

Şekil 4.10: Histogram eşitleme uygulanan desen imgelerinde özellik çıkarım yöntemlerinin performanslarının karşılaştırılması. 57

Şekil 4.11: Talamik katman filtresi uygulanan desen imgelerinde Katman-3 ve LBP yöntemlerinin performanslarının karşılaştırılması. 58

Şekil 4.12: Çoklu-ölçekli imgelerden LBP özniteliklerinin çıkarılması yöntemi. 61

Şekil 4.13: Orijinal ve çoklu-ölçekli imgelerin LBP öznitelikleri DVM (lineer) performansı. . 62

Şekil 4.14: Orijinal ve çoklu-ölçekli imgelerin LBP öznitelikleri DVM (rbf) performansı..... 62

TABLO LİSTESİ

Sayfa No

Tablo 2.1: Karışıklık matrisi (Wikipedia, 2017). 39

Tablo 4.1: Farklı sayıda eğitim ve test kümelerinin oluşturulması. 51

Tablo 4.2: Eğitim örnek sayısının sınıflandırma problemi üzerindeki etkisinin ölçümü testi DVM sınıflandırıcı ortalama başarım oranları. 55

Tablo 4.3: Özellik çıkarım yöntemlerinin performanslarının karşılaştırılması testi DVM sınıflandırıcı ortalama başarım oranları. 59

Tablo 4.4: Çoklu-ölçekli imgelerin sınıflandırma problemi testi DVM sınıflandırıcı ortalama başarım oranları. 63

SİMGE VE KISALTMA LİSTESİ

Kısaltmalar	Açıklama
V1	: Birincil Görme Korteksi
L2/3	: Katman 2/3
L4	: Katman 4
L5	: Katman 5
L6	: Katman 6
LGN	: Lateral Geniculate Nucleus
LBP	: Yerel İkili Desen
GWT	: Gabor Dalgacık Dönüşümü
DVM	: Destek Vektör Makinesi

ÖZET

YÜKSEK LİSANS TEZİ

DESEN SINIFLANDIRMA İÇİN KORTİKAL GÖSTERİMLERİN GELENEKSEL GÖRÜNTÜ İŞLEME YÖNTEMLERİ İLE KARŞILAŞTIRILMASI

Hatice NİZAM

İstanbul Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Ahmet SERTBAŞ

Desen, bir görüntüdeki ilgili bölgelerin tespitinde veya bir nesnenin tanımlanmasında kullanılan önemli bir özelliktir. Desenlerin sınıflandırılması çalışmalarının başlıca araştırma konuları bir deseni temsil edecek özellik kümesinin nasıl belirleneceği ve desenler arasındaki güçlü benzerlik/farklılık ölçümünün nasıl yapılacağıdır. Bu konuda önerilen birçok öznitelik çıkarım yöntemi mevcuttur. Son zamanlarda, insan beyninin desenleri algılama, sınıflandırma ve analiz yapabilme kapasitesi örnek alınarak birçok yapay öğrenme yöntemi geliştirilmektedir. İnsan görme sisteminin en çok bilinen ve en çok çalışılan alanı birincil görme korteksidir (V1). V1'in görsel bilgileri aldığı ve görsel veri işlemenin ilk adımı olan Katman-4 için birçok matematiksel veri işleme modeli geliştirilmiştir. Tez kapsamında, Favorov'un Katman-4 için geliştirmiş olduğu hesaplamalı modelin doğrusal boyut indirgeme sonucu elde edilen 5-boyutlu Katman-3 gösterimi öznitelikleri ile öznitelik çıkarım yöntemlerinden piksel, GWT ve LBP özniteliklerinin çeşitli testler üzerindeki sınıflandırma performansları karşılaştırılmıştır. Bu tez çalışması ile desen tipi imgelerde desen sınıflandırılması problemlerinin daha iyi anlaşılması, ileride geliştirilebilecek yöntemlere ve doğal tip imgelerde desen sınıflandırılması konusunda literatüre katkı sağlanması amaçlanmıştır.

Haziran 2017, 86 sayfa.

Anahtar kelimeler: Desen sınıflandırılması, katman-3, yapay öğrenme, öznitelik çıkarım yöntemleri.

SUMMARY

M.Sc. THESIS

COMPARISON OF CORTICAL REPRESENTATIONS WITH THE TRADITIONAL IMAGE PROCESSING METHODS FOR TEXTURE CLASSIFICATION

Hatice NİZAM

Istanbul University

Institute of Graduate Studies in Science and Engineering

Department of Computer Engineering

Supervisor: Prof. Dr. Ahmet SERTBAŞ

A texture is an important feature used in the identification of the regions in an image or in the identification of an object. The main research topics of classification studies of textures are how to determine the feature set to represent a texture and how to measure the strong similarity/difference between textures. On this regard, there are many suggested feature extraction methods. Recently, many artificial learning methods are being developed by taking as an example the capacity of the human brain to perceive, classify and analyze textures. The primary visual cortex is the best-known and best-studied area of the human visual system (V1). Several mathematical data processing models have been developed for Layer-4, the first step of V1's visual information and visual data processing. Within the context of the thesis, the classification performance of the pixel, GWT and LBP features of feature extraction methods with the 5-dimensional Layer-3 representation features obtained from the linear dimension reduction result of the computational model developed Favorov's Layer-4 have been compared. This thesis study aims to provide a better understanding of texture classification problems in texture type images, to methods that can be developed in the future and to the literary contribution to texture classification in natural type images.

June 2017, 86 pages.

Keywords: Texture classification, layer-3, machine learning, feature extraction methods.

1. GİRİŞ

Gerçek dünyada bütün nesneler bir desen (texture) ile kaplanmıştır. Görsel karmaşık bir özellik olan desen renk, doku, parlaklık ve şekil karakterlerinin düzenli bir şekilde bir araya gelmesiyle oluşur. Desen özelliği bir görüntüdeki ilgili bölgelerin tespitinde veya bir nesnenin tanımlanmasında kullanılan önemli bir karakterdir.

Son zamanlarda desen tipi görüntülerin analiz ve sınıflandırılması konusu bilgisayar görüsü (computer vision) ve görüntü işleme (image processing) alanında yapılan çalışmalarda önemli bir rol almaya başlamıştır. Nesneler ile ilgili önemli bilgileri içeren desen özelliği biyomedikal yüzey tanıma uygulamalarına ait biyomedikal görüntülerden bir hastalık veya bozukluğun teşhis edilmesi, endüstriyel yüzey tanıma uygulamalarında kullanılan endüstriyel ürünlerin sınıflandırılması, hava veya uydu görüntülerinin bölümlendirilmesi (segmentation) ve doküman analizinde kullanılan desen bölgelerinin bölümlendirilmesi gibi farklı alanlara ait çeşitli uygulamalarda kullanılmaktadır. Desen tipi imgelerin analizi ve sınıflandırılması çalışmalarında literatürde çeşitli özellik çıkarım metotları önerilmiştir. Önerilen bu metotlar içerisinde en popüler olanları Gabor Dalgacık Dönüşümü (GWT) ve Yerel İkili Desen (LBP) öznitelik çıkarım yöntemleridir. GWT öznitelik çıkarım yöntemi, çeşitli ölçek ve yönelim değerlerine sahip filtre temsilleri yakalama kapasiteleri ile ölçek ve dönme değerlerinden bağımsız imge tanımlayıcıları tasarlamak için kullanılabilir (Riaz ve diğ., 2013). Ayrıca, en uygun uzay-frekans çözünürlüğü ve birincil görme korteksindeki (V1) benzerlikleri ile başka hiçbir geleneksel görüntü işleme yönteminde olmayan iki özelliğe sahiptir (Daugman, 1985). LBP öznitelik çıkarım yöntemi, bir imgeye ait yerel desen bilgileri ile yapısal bilgilerinin de histogram olarak tutulmasından dolayı literatürde yer alan geleneksel öznitelik çıkarım yöntemlerine göre imge deseni hakkında daha güçlü ayrımı sağlayacak öznitelikleri çıkarılmasını sağlar (Ataş ve diğ., 2013). Ayrıca, gerçek dünyada ışık yoğunluğundan oluşabilecek değişimlere karşı etkili olduğundan desen analizinde kullanışlı ve etkili bir yöntemdir.

Bu tez çalışması, desen sınıflandırılması problemlerinde literatürde sıklıkla kullanılan geleneksel görüntü işleme yöntemleri ile tez kapsamında geliştirilen Favorov'un Katman-3 veri işleme modeli (Tübitak Projesi, 2016) performanslarının karşılaştırılması amacıyla düzenlenmiştir. Desen analizi ve sınıflandırılması çalışmalarında sıklıkla kullanılan Brodatz veri kümesi (Wikipedia, 2016) ve doğal imgeleri içeren YARD veri kümesi (Favorov ve Kursun, 2011) kullanılarak elde edilen geleneksel görüntü işleme yöntemleri öznitelik çıkarım yöntemlerine ait piksel, GWT ve LBP öznitelikleri ile Katman-3 özniteliklerinin DVM sınıflandırıcısındaki performansları karşılaştırılmıştır. Bu tez çalışmasında gerçekleştirilen deneysel sonuçlar ile desen tipi imgelerde desen sınıflandırılması problemlerinin daha iyi anlaşılmasına ve ileride geliştirilecek yöntemlere katkıda bulunabileceği düşünülmektedir. Ayrıca, bu çalışmayla birlikte doğal imgelerde desen sınıflandırılması konusunda da literatüre katkı sağlanacağı düşünülmektedir.

Tez kapsamında, Katman-3 öznitelikleri ile öznitelik çıkarım yöntemlerinden elde edilen özniteliklerin başarımlarını ölçmek amacıyla yapay öğrenme ve geleneksel görüntü işleme yöntemleri kullanılarak çeşitli sınıflandırma problemi testleri geliştirilmiştir. Bu testlerden ilk olarak, desen imgelerinin belli bir boyut ve farklı pozisyonlardaki desenlerinin sınıflandırma başarısını ve bu imge parçasının x-y koordinat sisteminde hangi yöne ötelendiğinin sınıflandırılabilir olup olmadığını ölçmek amacıyla afin dönüşümler kullanılarak öteleme sınıflandırma problemi testi geliştirilmiştir. İkinci test, DVM sınıflandırıcısının eğitiminde kullanılacak imge desenleri sayısının sınıflandırma başarım oranına ne ölçüde etki edeceğini belirlemek amacıyla geliştirilmiştir. Üçüncü test, özellik çıkarım yöntemleri ve Katman-3 modeline ait özniteliklerin DVM sınıflandırma başarımlarını karşılaştırabilmek amacıyla geliştirilmiştir. Son test olarak, bir imgenin farklı boyutlarda ölçeklenmesi sonucu elde edilen LBP özniteliklerinin desenlerin sınıflandırılması üzerinde etkisini ölçmek amacıyla çoklu-ölçekli sınıflandırma problemi testi geliştirilmiştir.

"Genel Kısımlar" bölümünde, insan biyolojik görme sisteminin yapısı, görüntü işleme yöntemleri, veri kümelerinin tanıtılması, yapay öğrenme ve istatistiksel analiz, öznitelik çıkarım yöntemleri, Favorov'un Katman-3 modeli, Destek Vektör Makineleri (DVM), model performans değerlendirme yöntemleri ve literatürde yer alan desen sınıflandırılması çalışmaları anlatılmaktadır.

“Malzeme ve Yöntemler” bölümünde, tez kapsamında geliştirilen model performanslarını ortaya koyan geometrik görüntü dönüşümü test yöntemleri, imge desenlerine uygulanan histogram eşitleme ve Talamik katman filtresi anlatılmaktadır.

“Bulgular” bölümünde, öznitelik çıkarım yöntemleri ve Favorov’un Katman-3 modeli sonucu elde edilen özniteliklerin tez kapsamında geliştirilen sınıflandırma testleri üzerindeki başarım sonuçlarının karşılaştırılması ve elde edilen bulgular anlatılmaktadır.

Son olarak “Tartışma ve Sonuç” bölümünde, elde edilen test sonuçlarının değerlendirilmesi, literatürdeki çalışmalar ile olan karşılaştırılması ve tez sonrası yapılması planlanan çalışmalardan bahsedilmektedir.

2. GENEL KISIMLAR

2.1. GÖRME SİSTEMLERİ

2.1.1. Görme (Vision) Nedir?

Görme (vision), göz veya benzeri bir organ yardımıyla doğal dünyadaki nesnelerin renklerini ve şekillerini ayırt etmeyi sağlayan fizyolojik bir süreçtir. Görme kavramı, ışık kaynağından yayılan beyaz ışığın çevresel nesneler veya olayların içerdiği bilgilerin bulunduğu nesnelerde yansıması ya da emilmesi olayına göre değerlendirilmesidir.

Görme sistemleri biyolojik ve yapay görme sistemleri olarak ikiye ayrılmıştır. Biyolojik görme sistemleri, çevreden gelen uyartıların reseptörler tarafından algılanarak duyu nöronlarında uyartı (impuls) oluşturduktan sonra duyu sinirleri yardımıyla merkezi sinir sistemine (beyin) iletilmesi olayıdır. Yapay görme sistemleri ise, bir görüntüyü yakalayan ve bu görüntüyü işleyerek görüntü ile ilgili istenilen bilgileri dış dünyaya aktaran sistemler olarak tanımlanabilir. Her iki görme sisteminde de ortak ilk adım, ışığı iki boyutlu imge ögesine dönüştürmektir. İmge üzerinden alınan ışığın yoğunluğu birçok uzamsal konum içerisinde hesaplanır veya örneklenir. Biyolojik görme sisteminin temel ögesi olan göz bu işlemi foto-reseptör hücreleri yardımıyla gerçekleştirir. Yapay görme sistemleri ise bu işlemi farklı teknolojik modelleri kullanarak gerçekleştirir. Ancak temelde tüm sistemler aynı temel işlem olan ışığı önce iki boyutlu bir imgeye, sonrasında bu imgedeki her bir piksel üzerindeki ışık yoğunluğunu bir çeşit sinyale dönüştürür (İsenkul, 2016).

2.1.2. İnsan Biyolojik Görme Sistemi Yapısı

İnsan algılama sistemi; görüntü yakalama, görüntü gruplama ve görüntü analizi konusunda en karmaşık sistemdir. İnsan görme sistemi göz ve beyin olmak üzere iki fonksiyonel yapıdan oluşur ve bu iki organın işbirliği ile çalışması sonucu görme olayı gerçekleşir. Çevresel ışık kaynağından gelen ışığın çok kanallı ve elektromanyetik spektrumdaki dalga boyları her biri algılama sistemi olan gözler yardımıyla algılanır ve gelen ışığın sinyale çevrilmesinde rol oynar. Beyin ise karmaşık imge işleme sürecini

yürütür. Doğal dünyada gördüğümüz tüm nesnelerin canlılar tarafından algılanabilmesi işlemi çevresel ışık kaynağından yayılan ışığın nesneler tarafından emilmesi veya yansıması olayı sonucu gerçekleşir. Işık elektromanyetik bir dalgadır. Şekil 2.1'de ışığın elektromanyetik spektrum aralığı gösterilmektedir (Bohren ve diğ., 2006).

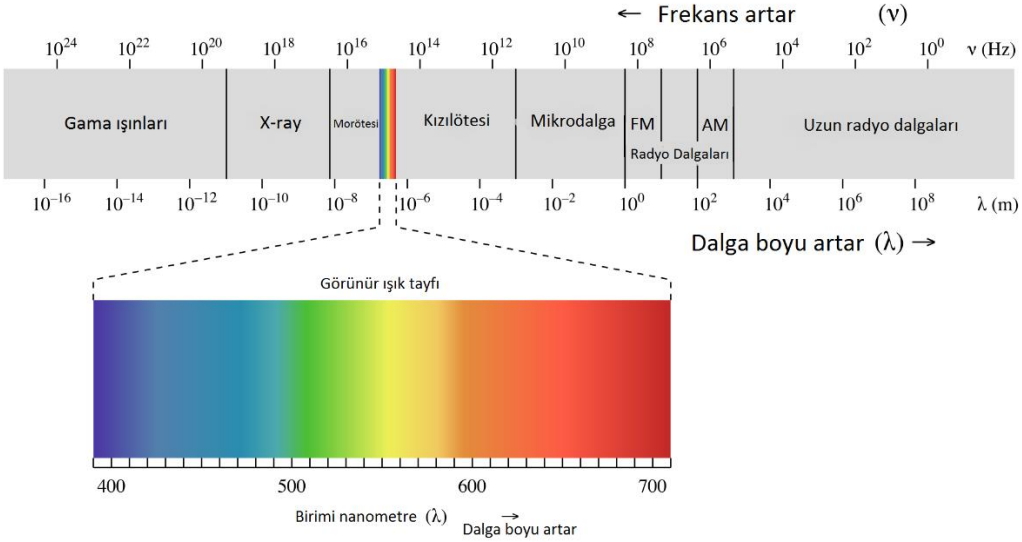

Şekil 2.1: Elektromanyatik spektrum.

Elektromanyetik dalgalar birbirine dik olarak salınan elektrik alan ve manyetik alandan oluşur. Bu elektromanyetik dalgalar frekanslarına göre gama ışınları, X-ray, mor ötesi, görünür ışık, kızılötesi, mikrodalga, radyo dalgaları (FM, AM) ve uzun radyo dalgaları gibi çeşitli isimler alır. İnsan gözü elektromanyetik spektrumun küçük bir bölgesi olan görünür ışık kısmını görür. Görünür ışık 380 nm ile 760 nm arasındaki dalga boyu ile temsil edilmektedir (Bohren ve diğ., 2006).

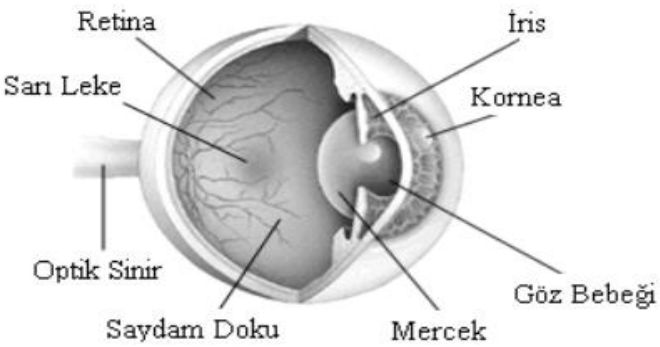

Şekil 2.2: İnsan gözünün anatomik yapısı.

İnsan biyolojik görme sisteminin bir parçası olan insan gözünün anatomik yapısı Şekil 2.2'de verilmiştir. Çevresel kaynaklardan yayılan ışık enerjisi elektronik spektrumda 380 nm ile 760 nm aralığında olduğunda göz optik sinirler yardımıyla beyne elektrik sinyali göndererek bu tür ışınlara tepki gösterir. Bu ışık ışını göze ulaştığı anda korneadan geçtikten sonra sırasıyla göz sıvısı, iris, lens ve camsı cisimden geçerek retinaya ulaşır. Gözbebeği iris sayesinde ışık şiddeti miktarına göre büyüyüp küçülür. Karanlık bir ortamda iris olabildiğinde açılarak gözbebeğinin büyümesini, ışıklı bir ortamda olabildiğince küçülerek gözbebeğinin küçülmesini sağlar. Mercek ise görüntüyü algılayıcı hücrelerin olduğu retina üzerine düşürmek için ayarlanarak görüntüyü sarı lekeye odaklar (Maintz, 2005).

2.1.2.1. Retina

Retinada ışık ışınları foto-reseptör hücreleri tarafından algılanarak burada elektrik sinyaline dönüştürülür. Gözde yapısal şekillerinden dolayı koni (rod) ve çubuk (cone) olmak üzere iki foto-reseptör hücresi bulunur. İnsan gözü içerisinde yaklaşık 100 milyon adet çubuk reseptörleri bulunmaktadır ve göz çukuru (fovea) hariç tüm retina bölgesinde eşit miktarda yayılmışlardır. Koni reseptörleri ise koni reseptörlerinin aksine göz çukuru bölgesinde yoğunlaşmışlardır ve yaklaşık 6-7 milyon adettir. Fakat tüm retina içerisinde çok daha az yoğunlukta koni reseptörleri bulunmaktadır. Optik sinirlerin göz ile bağlantısının bulunduğu bölgede foto-reseptörler bulunmamakta ve bu bölge kör nokta olarak adlandırılmıştır. Çubuk türü reseptörler koni türü reseptörlere göre ışığa karşı daha duyarlı olduklarından ışık ışınları geldiğinde daha çabuk tepki verirler ve böylece üç tip görüşü ayırt edebilmemizi sağlar. Karanlık ortamlarda sadece çubuk reseptörler aktiftir ve renkleri ayırt edememesinden dolayı nesneleri grinin tonları olarak algılarlar. Bu durum gece görüşü olarak adlandırılmaktadır. Aydınlık ortamlarda ise koni reseptörler aktiftir ve renkleri algılamamızı sağlar. Bu durum gündüz görüşü olarak adlandırılır. Loş aydınlanmanın olduğu ortamlarda ise her iki reseptörlerde aktiftir ve bu durum mezopik görüş olarak adlandırılmaktadır (Maintz, 2005).

Yukarıda bahsedilen koni ve çubuk foto-reseptörleri sayesinde ışık bir takım kimyasal reaksiyon olayı başlatarak elektriksel sinyale dönüşür. İmgenin beyinde analizi ve işlenmesi için imgedeki gerekli bilgiler elektrik sinyalleri yardımıyla optik sinirlerin sahip olduğu %90'ı talamus içerisindeki lateral geniculate nucleus (LGN)'a iletilir (Maintz, 2005).

2.1.2.2. Lateral Geniculate Nucleus (LGN)

Leteral Geniculate Nucleus (LGN) (Şekil 2.3), görme olayı için talamustaki bir geçiş noktasıdır. "Geniculate" kelimesi LGN'nin yapısından dolayı diz şekli anlamına gelmektedir. LGN'nin uyaranları azaltma, güçlendirme, iletmeme fonksiyonları mevcuttur. LGN optik sinirler için opsipital loba ana merkez bağlantısını sağlamaktadır. Duyusal girdilerin büyük çoğunluğunu retinadan almakta ve retinadan yola çıkan bu sinyaller LGN'ye ulaşarak opsipital lobtaki birinci görme korteksine iletilmektedir (V1) (İsenkul, 2016).

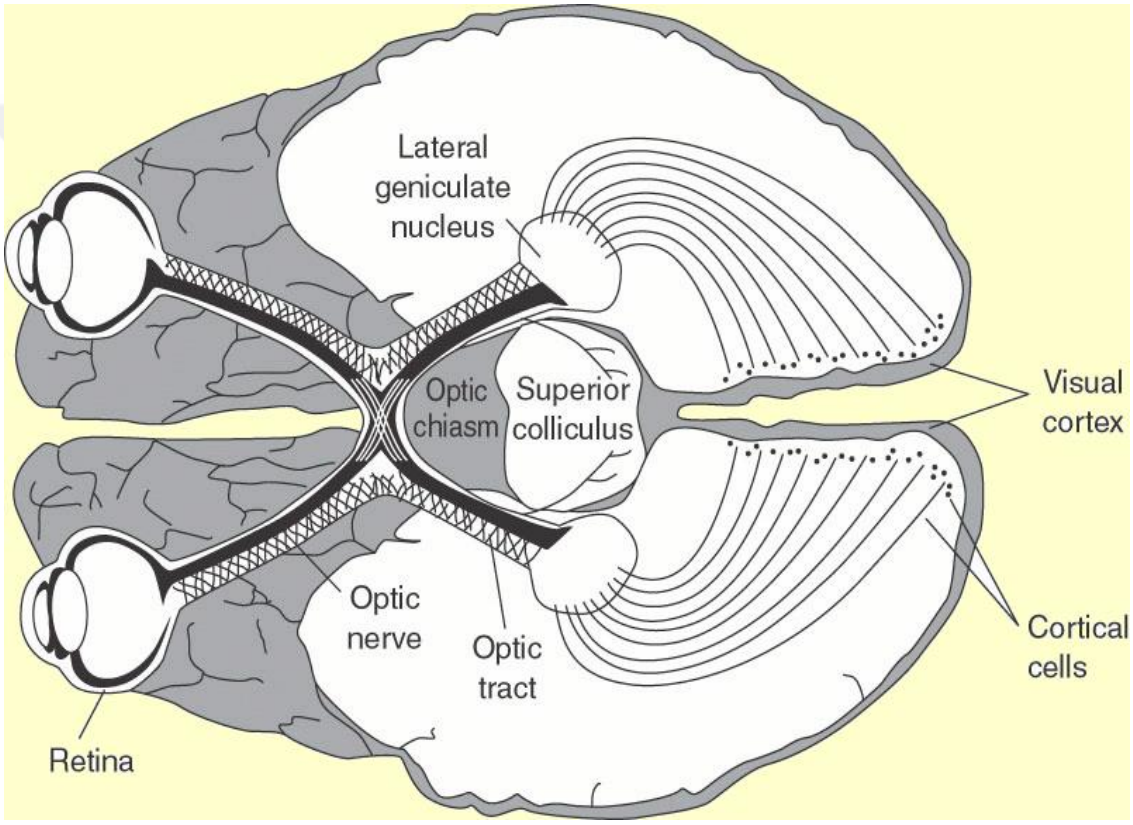

Şekil 2.3: Lateral geniculate nucleus (LGN) yapısı (van der Helm, 2012).

LGN alıcıları, retina tarafından elektrik sinyaline çevrilmiş bilgileri girdi olarak almaktadır. Retina bölgesine düşen ışık iki farklı alan olan merkez ve çevrede bulunan koni ve çubuk foto-reseptörlerini tetikler. Dairesel bu alanlar sayesinde ışığa haritalama yapılmaktadır. Haritalanan sinyal, ON-merkez ve OFF-merkez olarak adlandırılan LGN hücrelerine girdi olarak verilerek uyartıların üretilmesi sağlanır (Şekil 2.4) (İsenkul, 2016).

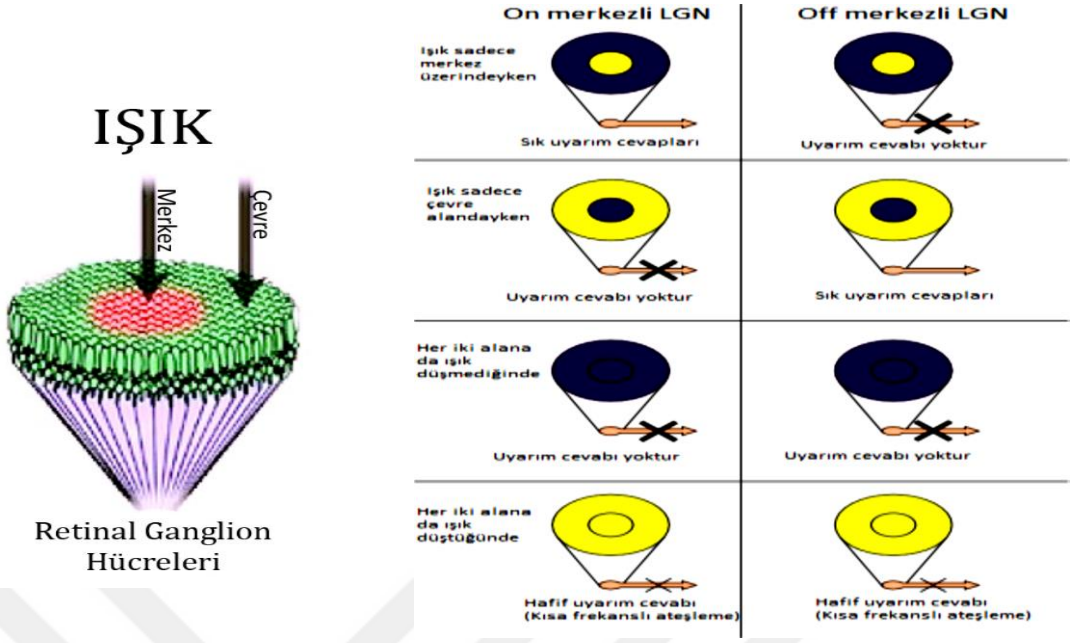

Şekil 2.4: LGN alıcı alanları ((Wikipedia, 2016),(Torres, 2012)).

ON-merkez türü LGN hücrelerinde merkeze düşen ışığın elektriksel sinyali hücrenin uyarım cevaplarını artırır ve çevreye düşen ışık ise hücrenin uyarım cevaplarını azaltır. OFF-merkez türü LGN hücrelerinde merkeze düşen ışık hücrenin cevaplarını azaltır ve çevreye düşen ışık ise hücrenin uyarım cevaplarını artırır. ON-merkez ve OFF-merkez hücreleri görüldüğü üzere birbirinin tam tersi şekilde çalışmaktadır. Örneğin; ışık sadece çevre alana düştüğünde ON-merkezli hücrelerde uyarım cevabı olmazken OFF-merkezli hücrelerde ise uyarım cevabı olacaktır (İsenkul, 2016).

Yukarıdaki işlem sayesinde bir görüntüde ışığın düştüğü alandaki pikseller daha belirgin olurken, diğer alanlar düşük uyarımlı olacaktır ve bir görüntüde az bilgi içeren piksel bölgeleri yok sayılacaktır (Şekil 2.5). Nöral çıktı olarak verilen bir görüntü için LGN çıktı sonucu Şekil 2.5'te gösterilmektedir. Burada gerçekleşen işlemde siyahın yoğun olduğu pikseller OFF-merkezli LGN hücrelerinin yoğun uyarımlarını gösterirken, beyazın yoğun olduğu pikseller ise ON-merkezli LGN hücrelerinin yoğun olduğu uyarımları göstermektedir. Grinin yoğun olduğu pikseller ise ON-merkezli ve OFF-merkezli LGN hücrelerinin eşit sayıda bulunduğunu ifade etmektedir. Nöral çıktı sonucunda bilgilerin bulunduğu piksel bölgeleri belirgin hale getirilmiştir. Beyaz piksel bölgesinden siyah piksel bölgesine geçilirken beyaz piksel değeri, siyah piksel bölgesinden beyaz piksel bölgesine geçilirken siyah piksel değeri kullanılmıştır.

Böylece nöral çıktı bilgisine (sağ) bakılarak girdi resmindeki (sol) renk geçiş bilgilerine ulaşılmaktadır (İsenkul, 2016).

Şekil 2.5: LGN alıcı alanları çıktısı (sol: girdi resmi (gri ölçeklemeli), sağ: nöral çıktı) (Heeger, 2006).

2.1.2.3. Birincil Görme Korteksi (V1)

V1 beynin en arka kısmında olup birincil görme korteksi olarak isimlendirilmiştir. V1 basit retinal girdileri organize eder. Görme korteksi görsel-uzamsal işleme, renk işleme ve hareket algılama gibi farklı görevleri yerine getirmek üzere V1, V2, V3, V4 katmanları şeklinde ayrılmıştır. Kortikal görme işlemlerinin ilk ve en az karmaşık adımları V1 katmanında yapılmaktadır. V1 katmanı, statik ve hareketli nesneler hakkında yapılan bilgi işlenmesi ve örüntü tanıma işlemleri üzerine özelleşmiştir. Görme korteksinde bir görüntünün işlenmesi için gelen görüntü bilgisi ilk olarak V1 katmanında işlendikten sonra sinyal sırasıyla V2, V3 ve V4 üst katmanlara iletilerek yüksek seviyede görüntünün işlenmesi sağlanır (Şekil 2.6).

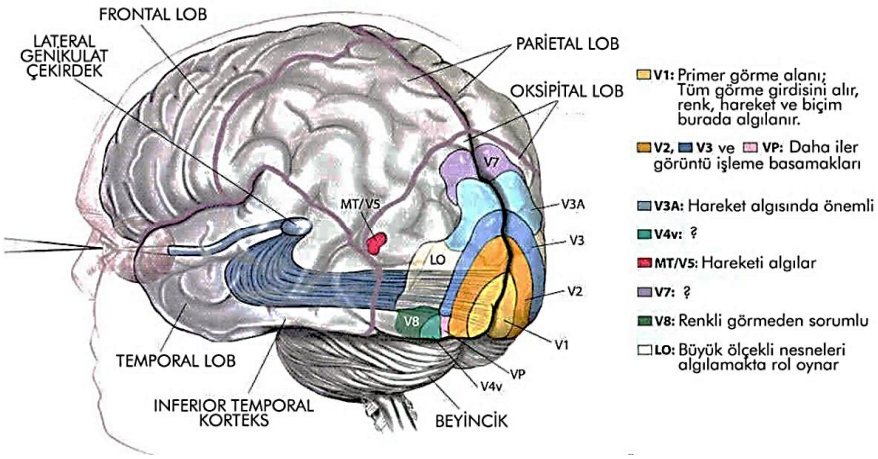

Şekil 2.6: İnsan görme sistemi genel yapısı ve görme korteksi (Obay, 2016).

V1 bir insanda yaklaşık olarak 2 mm kalınlığında pial yüzey ve beyaz madde arasında 6 farklı katmandan oluşmaktadır (Şekil 2.7).

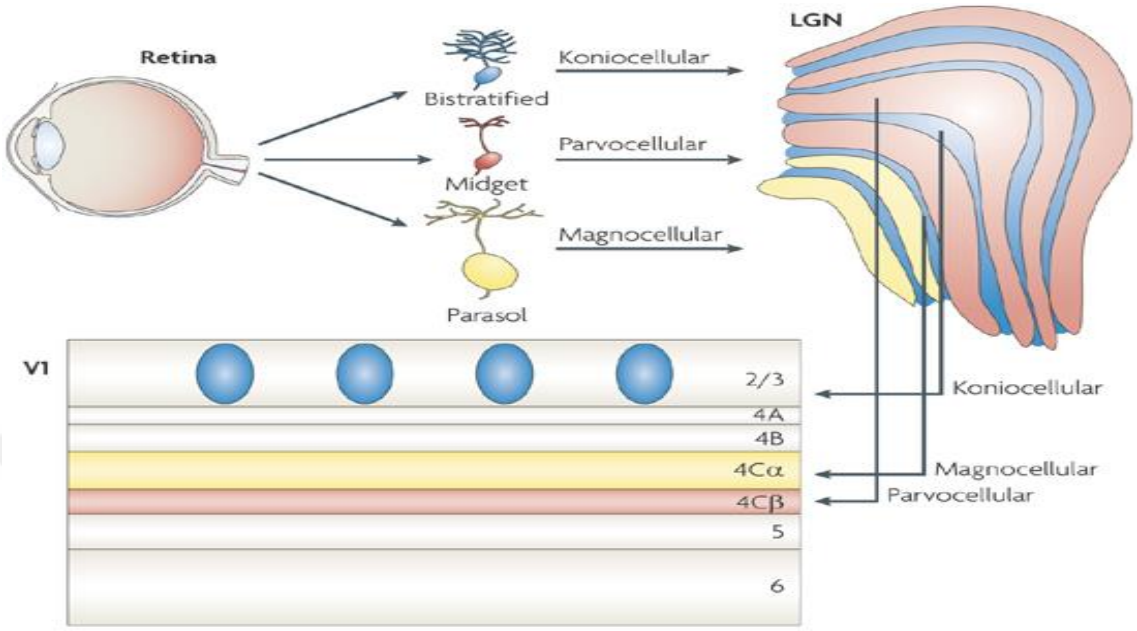

Şekil 2.7: V1 alanındaki katmanların (2/3, 4, 5, 6) LGN ile bağlantısı (Nassi ve diğ.,2009).

LGN'den gelen giriş değerleri 4. tabakada (4A, 4B, 4Cα, 4Cβ) sonlanır. M hücrelerinin aksonları 4Cα alt katmanında; P hücrelerinin aksonlarının çoğu 4Cβ alt katmanında, az bir kısmı 4A ve birincil görme korteksinde (V1) sonlanır. LGN'nin katmanlar arası bölgesinde bulunan üçüncü bir grup hücrenin aksonları 2. ve 3. katman bölgelerinde sonlanır.

- ***Katman 4 (L4):*** Gönderilen LGN hücre çıktıları ilk bu katmanda işlenir. Daha sonra L4 işlenen bilgileri Katman 2/3'e iletir (İsenkul, 2016).
- ***Katman 5 (L5):*** Korteksin altı yapısının (beyin sapı, orta beyin vb.) her birine geri bildirim sinyallerinin gönderildiği katmandır (İsenkul, 2016).
- ***Katman 6 (L6):*** Geri bildirimlerin Talamusa gönderilmesi işlemini gerçekleştiren katmandır (İsenkul, 2016).
- ***Katman 2/3 (L2/3):*** Alt katmandan gelen bilgilerin tekrar işlenerek bir üst alana iletilmesi ve Katman 4'e geri bildirimlerin gönderilmesi işlemleri bu katmanda yapılır. Katman 2/3 içerisindeki hücreler V2, V3 ve V4 kortikal görme alanlarına çıktı üretir (İsenkul, 2016).

2.2. GÖRÜNTÜ İŞLEME

2.2.1. İmge (görüntü) nedir?

İmge kavramı Türk Dil Kurumu (TDK) sözlüğüne göre herhangi bir nesnenin mercek, ayna gibi araçlarla oluşturulmuş biçimi, hayal olarak tanımlanmaktadır (Wikipedia, 2016). İmge kavramı bir nesnenin farklı bir ortamda veya insan beyninde modellenmesi ile ilgilidir.

İmge (görüntü) çeşitli yollarla elde edilen bilgilerin görüntüsel olarak saklanmasına ve gösterimine olanak sağlayan görüntülerdir. Her türlü iki boyutlu bilgi imge olarak adlandırılabilir. Bir imge x ve y değişkenlerinden oluşan $f(x,y)$ ışık-yoğunluk fonksiyonu ile temsil edilir. Burada x ve y değerleri 2-boyutlu imge uzayının koordinatlarını belirtmekte, $f(x,y)$ fonksiyonu ise imgenin x ve y koordinatlarındaki pikselinin ışık şiddetini (intensity) göstermektedir. Şekil 2.8'de M satır ve N sütundan oluşan MxN boyutlu bir imgenin 2-boyutlu koordinat sistemindeki temsili ve her bir piksel değerinin ışık şiddeti miktarını belirten $f(x,y)$ fonksiyonu gösterilmiştir.

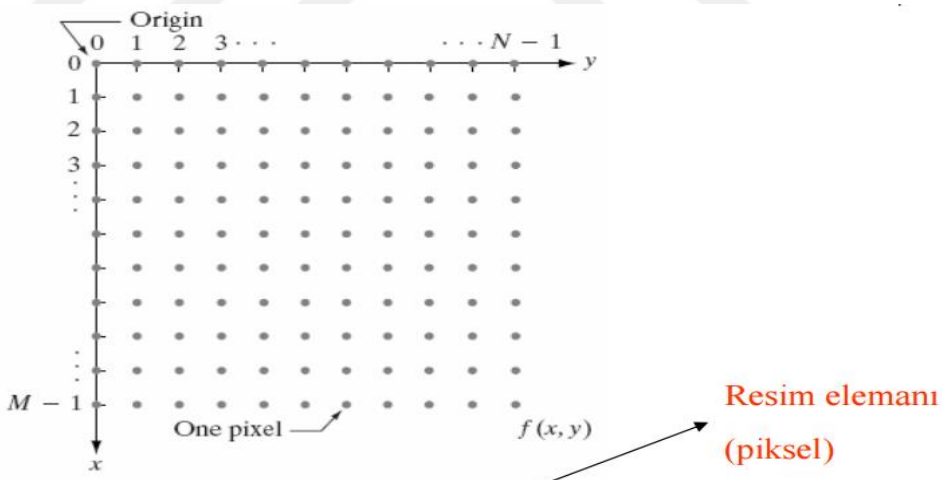

$$f(x,y) = \begin{bmatrix} f(0,0) & f(0,1) & \cdots & f(0,N-1) \\ f(1,0) & f(1,1) & \cdots & f(1,N-1) \\ \vdots & \vdots & & \vdots \\ f(M-1,0) & f(M-1,1) & \cdots & f(M-1,N-1) \end{bmatrix}$$

Şekil 2.8: MxN boyutlu bir imgenin $f(x,y)$ ışık-yoğunluk fonksiyonunun gösterimi.

2.2.2. İmgenin Sayısal Ortamda İşlenmesi

Doğal dünyada gördüğümüz tüm nesneler 3-boyutlu bir uzaydadır ve bu görüntülerin görüntü işleme teknikleri ile işlenebilmesi için 2-boyutlu uzaya dönüştürülmesi gerekmektedir. Bir imgenin sayısal imgeye dönüştürülmesi iki aşamada gerçekleşir: Örnekleme ve nicemleme. Örnekleme, sinyalden belirli bir zaman aralıklarında örneklerin alınması anlamına gelir. İki boyutlu imgelerde x ve y koordinat sisteminin sayısallaştırılması işlemidir. Nicemleme, genlik değerlerinin sadece bir değer alarak sayısallaştırılması işlemidir. Örneğin; gri seviyeli analog bir imge sayısala dönüştürülürken ilk olarak iki boyutlu uzay örneklenerek görüntü ayrıklaştırılır ve sonrasında ortalama parlaklık sayısı (nicemleme) ölçeklenerek en yakın tamsayıya yuvarlanır. Sayısal renkli imgeler genellikle her bir pikselinin Kırmızı (Red), Yeşil (Green) ve Mavi (Blue) bileşenleri (kanalları) ayrı ayrı belirli bir bit oranında nicemlenmesi ile saklanırlar (Örn: her biri 8-bit ile nicemlenirse, bir piksel için toplam 24-bit saklama alanı kullanılır). Gri-seviyeli veya renksel boyutlarda dönüştürülmüş imgeler bulunabilir. Ancak tez kapsamında sadece statik veya diğer bir deyişle monokrom (gri-gösterimli) imgeler üzerinde çalışılmıştır. Monokrom imgelerle çalışılmasının nedeni desen sınıflandırılmasındaki amacın nesnenin rengi ile değil nesnenin şekli, görünümü ile ilgili olmasıdır. Şekil 2.9'da doğal dünyada yer alan bir nesneden renkli sayısal bir görüntünün oluşturulma aşamaları şematize edilmiştir.

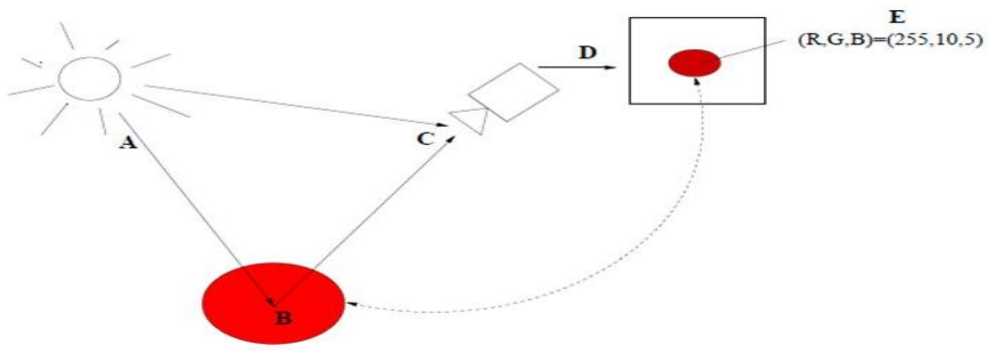

Şekil 2.9: Sayısal görüntünün oluşumu.

Burada A; ışık kaynağını (görünen elektromanyetik enerji kaynağı), B; doğal dünyada karşılaşabileceğimiz herhangi bir nesneyi, C; sensörü (kamera), D; kamera aracının ışığa duyarlı 2-boyutlu yüzeyinde 3-boyutlu nesneden yansıyan ışık kullanılarak sayısal imgenin oluşturulması aşamasını (gözlemcinin renk algısını oluşturma süreci) ve E; renkli sayısal görüntüyü ifade etmektedir.

2.3. DESEN TİPİ GÖRÜNTÜLER

2.3.1. Desen Nedir?

Desen (texture) uzaktan algılanabilen verilerden mikroskobik fotoğrafçılığa kadar birçok görüntüde görülebilir. Bir desenin yüzeyi görüntü desen hücresi (texel) olarak bilinen desen veya elementlerin düzenli tekrarının bir araya gelmesiyle oluşur. Doğal dünyada görülebilir tüm nesneler bir desen ile kaplanmıştır. Desenler ahşap mobilya, yer döşemesi, duvar kaplaması gibi yapay nesnelerin dış yüzeyinde görülebileceğinin yanı sıra bir zebranın derisi, gökyüzündeki bulutların görünümü, çimlerle kaplı bir alan, bir ağaç kabuğu gibi doğal nesnelerin dış yüzeyinde de görülebilir. Bu yüzden desen tipi görüntülerin doğal dünyadaki örnekleri oldukça çeşitlidir. Doğal ve yapay nesnelerin oluşturduğu birkaç desen tipi imge örneği Şekil 2.10'da verilmiştir.

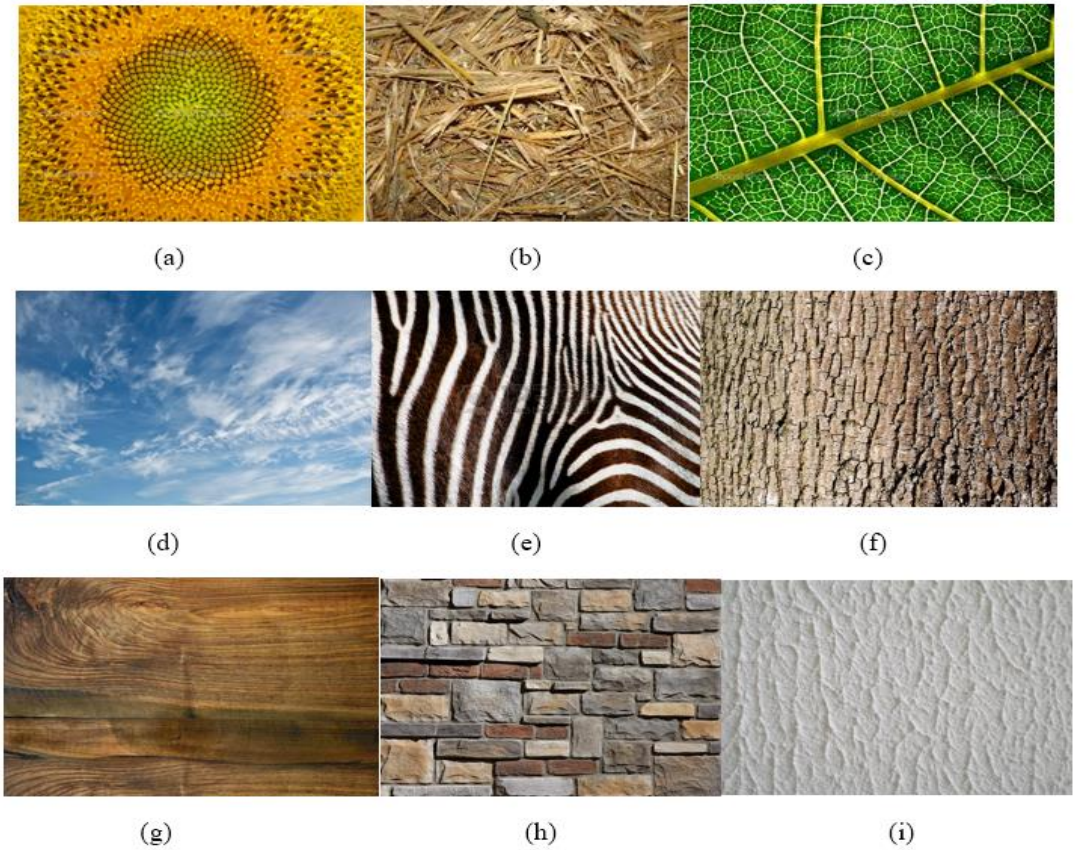

Şekil 2.10: Doğal ve yapay desen örnekleri: ayçiçeği (a), saman (b), yaprak (c), gökyüzündeki bulutların görünümü (d), zebranın derisi (e), ağaç kabuğu (f), ahşap mobilya (g), taş duvar (h), duvar kaplama kâğıdı (i).

Desen tipi görüntüler kolaylıkla fark edilebilmesine rağmen ortak bir tanımı bulunmamaktadır. Araştırmacılar tarafından desenin farklı tanımlamaları yapılmıştır.

Bu tanımlamalardan bazıları şu şekildedir:

- Tamura ve diğ. (1978) tarafından gözle görülebilir bir bölgeden oluşan doku olarak kabul edilebilir olan desenin yapısı elementlerin veya onu oluşturan temel ögelerin yerleşim kuralına göre düzenlendiği birbirini tekrarlayan dokular olarak basitçe tanımlanmıştır.
- Sklansky (1978) tarafından desenin işlevsel tanımı bir imgedeki bir bölge eğer yerel istatistikler kümesi veya imgedeki fonksiyonların diğer yerel özellikleri sabit, yavaş değişen ya da yaklaşık olarak periyodik ise sabit bir desen olarak tanımlanmıştır.
- Haralick (1979) tarafından bir imgenin deseni onu oluşturan ögelerin uzaysal düzeni, türü ve sayısı ile tanımlanabilir. Uzaysal düzen rastgele olabilir, komşu ögeler üzerinde bir ikili ögeye bağlı olabilir veya n adet ögeye bağlı olabilir. Bağımlılık olasılıksal, istatistiksel veya fonksiyonel olabilir.
- Whitman ve diğ. (1974) tarafından desen düzenli (regular) görülen hiçbir ögeye sahip olmayan bir alanın bir özelliği olarak tanımlanmıştır (Şekil 2.11). Deseni oluşturan ögeler arasındaki ilişkiler bu yüzden belli değildir. Bu alan belli bir eğim içermemelidir. Buradaki tanımın amacı gözlemcinin dikkatini imgenin genel özelliklerine (kaba, kabarcık, incelik gibi) yönlendirmektir. Fiziksel olarak düzensiz (irregular) desenler deterministik (kesin) süreçler yerine stokastik (rastlantısal) yöntemler tarafından üretilir. Ama algısal olarak tüm desen kümeleri birçok deterministik desenler içerecektir.

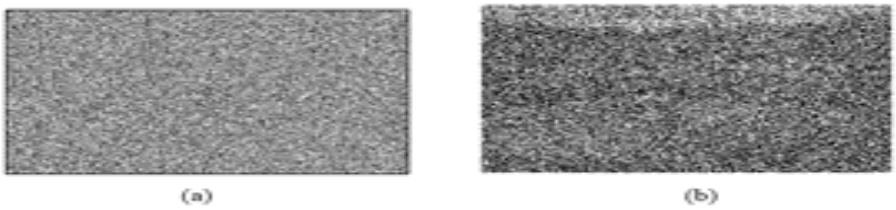

Şekil 2.11: (a) Normal-dağılımlı imge örneği (Hyvärinen, ve diğ., 2009)[1], (b) normal-dağılımlı olmayan imge örneği.

[1] Her bir piksel, siyah-beyaz yoğunluklarından rastgele bir değer seçilerek üretilmiştir.

Bu tez kapsamında desen sınıflandırılması çalışmasına ait deneylerde Brodatz albümü (Wikipedia, 2016) içerisindeki 13 farklı sınıfa ait (çim, ağaç kabuğu, duvar, su, saman gibi) desen tipi imgeler kullanılmıştır. Bu imgelerin her biri 512x512 boyutunda ve gri-seviyeli piksel değerlerine sahiptir. Şekil 2.12'de Brodatz albümünde yer alan desen tipi imgeler gösterilmiştir.

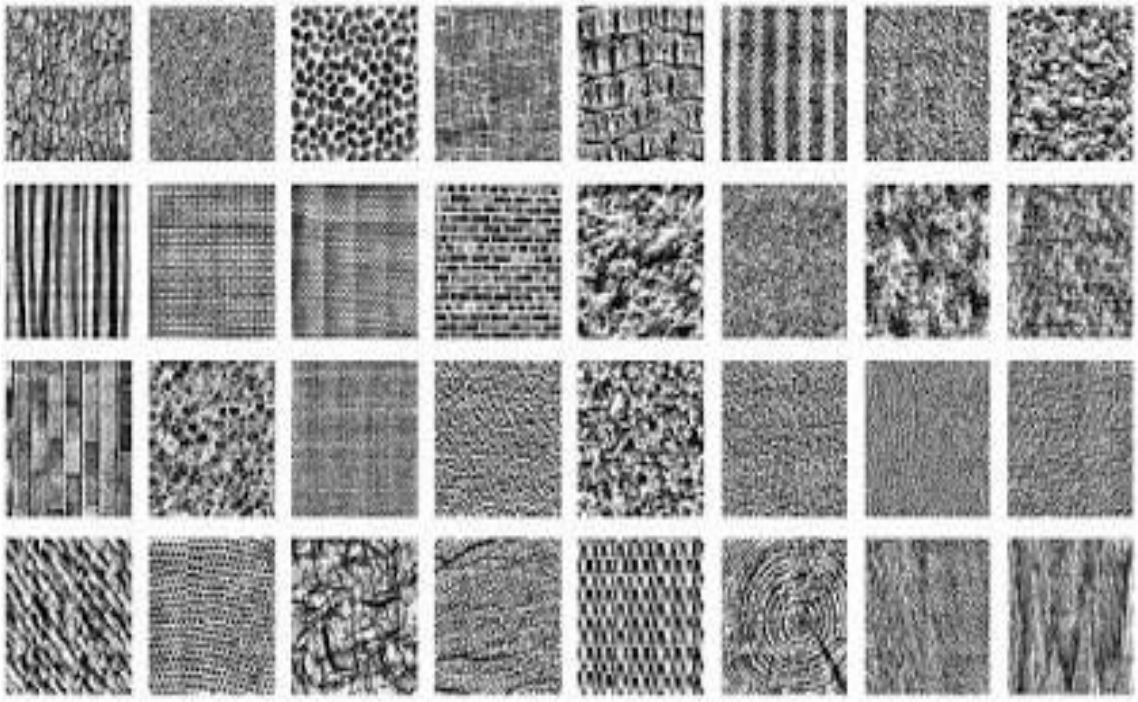

Şekil 2.12: Brodatz albümü içerisindeki farklı sınıflara ait desen tipi görüntüler kümesi.

2.3.2. Desen Analizi

Son zamanlarda desen tipi görüntülerin sınıflandırılması ve analizi konuları bilgisayar görüsü (computer vision), bilgisayar grafikleri (computer graphics), görüntü işleme (image processing) alanlarındaki uygulamalarda önemli bir araştırma konusu haline gelmiştir. Biyomedikal görüntülerden bir hastalık veya bozukluğun teşhis edilmesi, endüstriyel yüzey tanıma uygulamalarında kullanılan endüstriyel ürünlerin sınıflandırılması, hava veya uydu görüntülerinin bölümlendirilmesi (segmentation) ve doküman analizinde desen bölgelerinin bölümlendirilmesi gibi farklı alanlardaki birçok uygulamada kullanılmaktadır.

Desen tipi görüntülerin analizi için kullanılan yöntemler yapısal, istatistiksel, model tabanlı ve dönüşüm tabanlı yaklaşımlar olmak üzere 4 kategoriye ayrılmıştır. Yapısal tabanlı yaklaşımlar, imgeyi oluşturan ögelerin uzaysal düzenlerinin hiyerarşisi ve

imgenin iyi tanımlanmış ögeleri tarafından temsil edilir (Haralick, 1979). Yapısal yaklaşımların avantajı imgenin iyi bir sembolik tanımını sağlamaktır. Ama yapısal yaklaşımlar imge analizi yerine sentezleme çalışmalarında daha çok kullanışlıdır (Unser, 1995). Yapısal yaklaşımlara Laplace Gauss filtre, Gauss filtre fark, uyarlanabilir alan çıkarım yöntemleri örnek verilebilir.

İstatistiksel tabanlı yaklaşımlarda desen, bir imgenin gri seviyeleri arasındaki dağılımları ve ilişkileri yöneten deterministik olmayan (irregular) özellikleri ile dolaylı bir şekilde temsil edilir. İstatistiksel yaklaşımlarda bir imge içerisindeki desenden çıkarılacak özellikler eş-oluşum matrisi, Gauss-Markov Rastgele Alan, Yerel Lineer Dönüşüm, Yerel İkili Desen (LBP), Gabor Filtre, ikinci-dereceden istatistik, ilintileme (correlation) tekniği ((Unser, 1995); (Kashyap, 1986)) gibi çeşitli istatistiksel yöntemler ile elde edilebilir.

Model tabanlı yaklaşımlar deseni sadece tanımlamak için değil aynı zamanda desenin sentezlemesi için de kullanılan imge modelinin yapılandırılması üzerine tanımlanır (Tuceryan, 1993). Model tabanlı yaklaşımlarda model parametreleri tahmin edildikten sonra desen analizi için kullanılır. Bu model parametreleri desenin temel özelliklerini yakalar. Model tabanlı yaklaşımlara 1-boyutlu zaman serisi, otoregresyon modeli, hareketli ortalama yöntemleri örnek verilebilir.

Dönüşüm tabanlı yaklaşımlar bir desenin boyutu veya frekansı gibi özellikleri ile yakından ilişkili olan bir bilgiye sahip olan koordinat sisteminin alanındaki bir imgeyi temsil eder (Tuceryan, 1993). Dönüşüm tabanlı yaklaşımlara Fourier dönüşümü, dalgacık dönüşümü gibi yöntemler örnek verilebilir.

2.3.3. Desen Sınıflandırılması

Birçok bilim dalında karar verme sistemi olan sınıflandırma, bir olayı veya fiziksel bir nesneyi önceden belirlenmiş sınıflardan birine atama işlemidir. Desen sınıflandırılmasındaki amaç, bilinmeyen bir örnek görüntüyü önceden belirlenmiş desen sınıflarından birine atamaktır. Desen sınıflandırılması problemi desen analizi konuları içerisindeki 4 ana konudan biridir. Diğer konular ise desen bölümlendirilmesi (texture segmentation), desen sentezi (texture synthesis) ve desenden şekil belirleme (shape of texture) problemleridir.

Desen sınıflandırılması öğrenme ve tanıma olmak üzere 2 aşamadan oluşur. Öğrenme aşamasındaki amaç, bir desen örneği için genellikle sınıf etiketleri bilinen görüntülerin bulunduğu ve her bir desen sınıfını kapsayan öğrenme verileri içerisinden bir model oluşturmaktır. Eğitim verilerinin desen içeriği her bir görüntü örneği için desensel özellikler kümesini veren seçilmiş bir desen analizi metodu ile yakalanır. Bu desen özellikleri pürüzlük, yönelim, karşıtlık, uzaysal yapı gibi verilen bir görüntünün desensel özelliklerini karakterize eder. Tanıma bölümünde ise ilk önce bilinmeyen bir örneğin desen bilgisi öğrenme aşamasında kullanılan aynı desen analizi metodu ile tanımlanır. Daha sonra örnek girdinin desensel özellikleri bir sınıflandırma algoritması kullanılarak öğrenme görüntüleri ile kıyaslanır ve bu örnek girdi önceden bilinen sınıflardan hangisi ile en iyi şekilde uyuşuyorsa o sınıfa atanır.

Desen sınıflandırılması problemlerinde tanıma aşamasının görsel olarak temsili Şekil 2.13'te verilmiştir (Varma ve diğ., 2005). Burada yaprak, ahşap, çim, levha, kadife ve hasır olmak üzere 6 desen sınıfı bulunmaktadır. Her bir sınıf içerisinde farklı ışık açısı ve yönelimlere sahip 6 desen örneği yer almaktadır. Öğrenme aşamasında 6 desen sınıfı içerisinde yer alan her bir desen örneğinin desen özelliklerine göre bir öğrenme modeli oluşturulur. Tanıma aşamasında ise bilinmeyen bir desen örneği geldiğinde (burada sınıflandırılacak olan desen örneği çim sınıfına aittir) ilk olarak öğrenme aşamasında öğrenilen öğrenme modeline göre sınıflandırılacak görüntünün desen özellikleri elde edilir. Daha sonra seçilmiş bir sınıflandırma algoritması kullanılarak bu desen özelliklerine göre sınıflandırılacak olan görüntü örneğinin en iyi uyuştuğu desen sınıfı olan çim (grass) sınıfına atama işlemi gerçekleştirilir (Şekil 2.13).

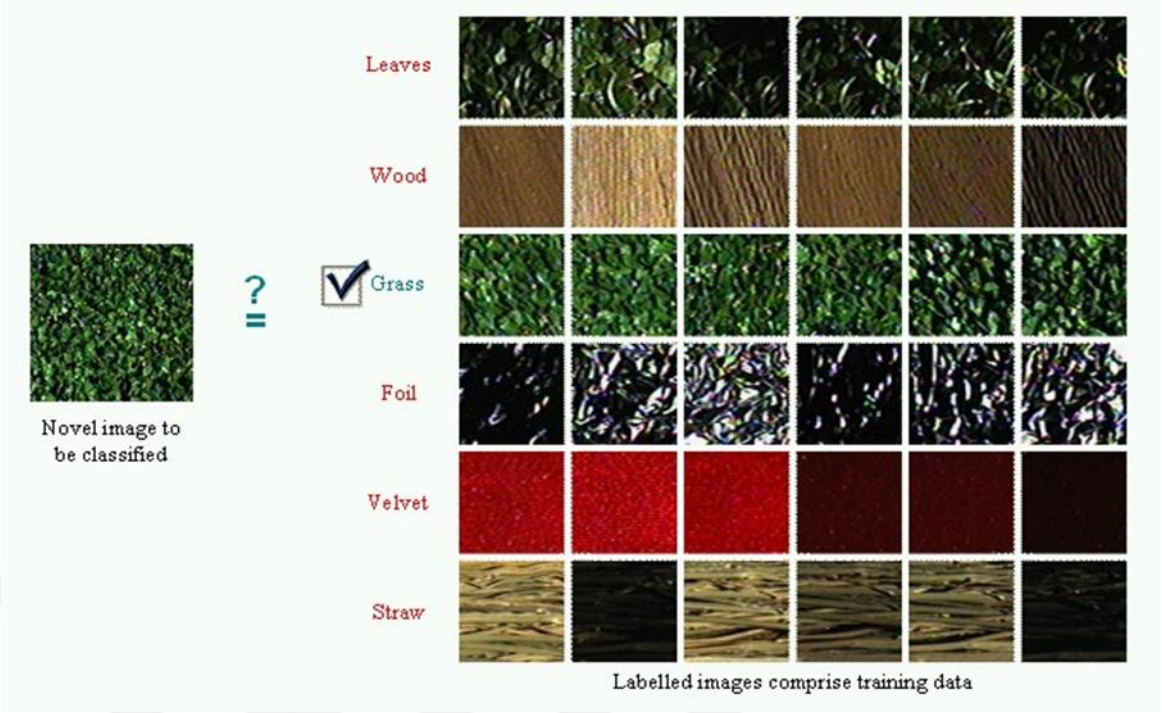

Şekil 2.13: Desen sınıflandırılması probleminin görsel gösterimi (Varma ve diğ., 2005).

Sınıflandırma problemlerinin odak noktası desenlerin renkleri ile değil, desensel görünümleri ile malzemelerin sınıflandırılmasıdır. Bu nedenle tüm görüntüler gri tonlamaya dönüştürülerek ve hiçbir renk bilgisi kullanılmayarak sınıflandırma işlemi yapılmaktadır.

2.3.4. Desen Sınıflandırılmasında Kullanılan Yöntemler ve Uygulama Alanları

Haşiloğlu (2001) desen sınıflandırması çalışmasında birçok desen analizi yöntemleri içerisinden Dalgacık çerçeveler yöntemini önermiştir. Bu çalışmada, Brodatz albümünde yer alan birbirinden farklı ve birbirine benzeyen desen örneklerinden 16 tanesi seçilerek 0^0-360^0 değerleri arasında rastgele döndürülmüş alt-örnekler (pencereler) elde edilmiştir. Her bir desenden elde edilen pencerelerde 16 farklı açı değeri kullanılmıştır. Pencereleme tekniklerinden örtüşen (overlapping), örtüşmeyen (non-overlapping) ve diyagonal (köşeden köşeye) pencereleme yöntemleri ile yeni önerilen piramit pencereleme yöntemi kullanılarak hızlı adaptif geriye yayılımlı yapay sinir ağları algoritması ile performansları değerlendirilmiştir. Yapay sinir ağlarının giriş katmanında 4 adet nöron (öznitelik) kullanılmıştır. Yapay sinir ağlarının eğitiminde, 16 farklı açıya sahip her bir 16 desen örneğinden toplam 256 tane öznitelik kullanılmıştır. Dalgacık dönüşümlerinden Haar dalgacık, Symlets dalgacık ailesi, Daubechies dalgacık

ailesi ve Lemarie dalgacık ailesi kullanılarak skala=2 ve skala=3 için pencereleme yöntemlerinin desen sınıflandırılması için performansları karşılaştırılmıştır. En yüksek sınıflandırma performansı, önerilen piramit pencereleme tekniği kullanılarak skala değerinin 2 (öznitelik sayısı=4) olarak seçildiği Haar dalgacık yöntemi ile eğitim veri seti üzerinde %100 ve test veri seti üzerinde %99.9 başarı elde edilmiştir.

Budak ve Şengür (2015), desen sınıflandırması çalışmasında Ölçekten Bağımsız Öznitelik Dönüşümü (ÖBÖD) ve Kelime Çantası (KÇ) yöntemleri kullanarak özellik tabanlı bir yaklaşım önermiştir. ÖBÖD yöntemi, imgenin boyutundan, kameranın açısından, ortamın ışık koşullarından ve imgenin açısına bağlı olmadan başarılı bir şekilde özellik eşleştirmesi yapabildiğinden dolayı tercih edilmiştir. KÇ modeli, her bir görsel kelimenin oluşum sıklığının hesaplanmasından sonra kümelenerek bir kütüphane oluşturulması esasına dayanmaktadır. Deneysel çalışmalarda 25 sınıfın her birinde 640×480 ölçekli 40 adet desen görüntüsü içeren UIUCTex veri seti ve 11 sınıfın her birinde 200×200 ölçekli 432 adet desen görüntüsü içeren KTH-TIPS2-a veri seti kullanılmıştır. KTH-TIPS2-a veri seti her bir sınıfta aynı desene ait 4 farklı aydınlanma koşulu, 9 farklı ölçek ve 3 farklı açıya sahip 108'er tane örnek olmasından dolayı UIUCTex'e göre zor bir veri setidir. Veri setinin 2/3'ü eğitim setine geri kalanı ise test setine atanarak Destek Vektör Makineleri (DVM) sınıflandırıcısının RBF çekirdek fonksiyonu kullanılarak her bir veri setinin performansları karşılaştırılmıştır. Veri setlerine ait özellikler ÖBÖD yöntemi ile elde edilip k-ortalama algoritması ile eğitim veri seti için görsel kelimeler kümelenmiştir. Görsel kelimelerin histogramları belirlendikten sonra normalize edilmiştir ve eğitim veri setinden elde edilen özellikler ile test veri setinden elde edilen özellik histogramlarına göre DVM ile sınıflandırılmıştır. Elde edilen sonuçlara göre UIUCTex veri seti %91.2 başarı oranı, KTH-TIPS2-a veri seti ise %72.1 başarı oranı göstermiştir.

Yan ve diğ. (2016) desen sınıflandırılması için LBP karmaşık ağları ve fraktal teorisinin birleşiminden oluşan yeni bir yaklaşım olan FLCN yöntemini önermiştir. Bu yöntemde, karmaşık ağlar görüntünün piksel ilişkileri ve LBP özelliklerine göre inşa edildikten sonra karmaşık ağlar üzerindeki uygun parametre ve istatistiksel özelliklerin birleşimini görüntünün desenini oluşturmak için incelemişlerdir. Deneysel çalışmalarda Brodatz ve HEp-2 Cells görüntülerini içeren iki veri seti kullanılarak önerilen FLCN yöntemi ile birinci derece (first-order), LBP+DIFF, GLCM, CLBP ve CN modern yöntemlerinin

sonuçları karşılaştırılmıştır. Elde edilen sonuçlara göre FLCN yöntemi, bölünmüş görüntülerin sınıflandırılmasında %85.31 başarı oranı ve biyomedikal görüntülerin ayırt edilmesinde %81.16 başarı oranı ile diğer kullanılan metotlara göre üstün gelmiştir.

Riaz ve diğ. (2013), desenlerin sınıflandırılması için yönelim ve ölçek değerlerinden bağımsız yeni bir yaklaşım önermiştir. Önerilen yöntem, desenlerin boyut ve yönelimlerine göre filtre temsillerini azaltabilen Gabor filtrelerine dayanmaktadır. Ayrık Fourier dönüşümünün yer değiştirme değişmezlik özelliği kullanılarak yönelim ve ölçekten bağımsız desen özellikleri önerilmiştir. Deneysel çalışmalarda Brodatz veri seti kullanılarak 4 farklı test ortamı oluşturulmuştur: Birinci testte, orijinal 512x512 boyutlu Brodatz görüntülerinden örtüşmeyen pencereleme tekniği ile 128x128 boyutlu makrokolonlar kullanılmıştır. İkinci testte, eğitim kümesinde orijinal görüntüler test kümesinde ise 30^0, 60^0, 90^0, 120^0, 150^0 ve 200^0 derece döndürülmüş görüntüler kullanılmıştır. Üçüncü testte, eğitim kümesinde orijinal görüntüler test kümesinde ise 0.66, 0.8, 1.25 ve 1.5 değerlerinde ölçeklenmiş görüntüler kullanılmıştır. Son testte ise, eğitim kümesinde orijinal görüntüler test kümesinde ise 30^0, 60^0, 90^0, 120^0, 150^0 ve 200^0 derece döndürülmüş ve 0.66, 0.8, 1.25 ve 1.5 değerlerinde ölçeklenmiş görüntüler kullanılmıştır. Her bir test kümesi üzerinde önerilen yöntem ile desen sınıflandırılması çalışmalarında sıklıkla kullanılan LBP özellik çıkarım yöntemi ve homojen desen (HT) temsillerinin performans sonuçları DVM sınıflandırıcının polinom çekirdek fonksiyonu kullanılarak elde edilmiştir. Deney sonuçlarına göre tüm testlerde en iyi performansı önerilmiş yöntem göstermiştir.

Krishnan ve diğ. (2016), desen sınıflandırılması çalışmalarında Shearlet dönüşümünü kullanarak sınıflandırma tekniklerinin performansını araştırmıştır. Deneysel çalışmalarda Brodatz albümü içerisinden farklı sınıflara ait 112 desen örneği kullanılmıştır. Görüntü desenlerinin sınıflandırılmasında minimum mesafe sınıflandırıcısı ve lineer regresyon modeli kullanılmıştır. Elde edilen deneysel sonuçlara göre, Shearlet dönüşümünün desenlerin sınıflandırılmasında farklı yönlerde gerçekleşen değişimlerine karşı oldukça hassas olduğu ve mevcut yöntemlere göre daha başarılı olduğu kanıtlanmıştır. Ayrıca, Shearlet dönüşümü çok yönlü temsillerinin etkin olmasından dolayı desen analizinde gelişmiş bir yöntem olarak kabul edilmiştir. En yüksek sınıflandırma performansı, lineer regresyon için önerilen özellik kümesi ile %98.2 başarı oranıyla elde edilmiştir.

2.4. DOĞAL TİP GÖRÜNTÜLER

2.4.1. Doğal Görüntüler Nedir?

Doğal görüntüler gerçek dünyada kolaylıkla karşılaşabileceğimiz gökyüzündeki bulutlar, ağaç, meyve, çayır, manzara gibi farklı tip görüntülerden oluşmuş imge uzayıdır. Bizler görme sistemimiz yardımıyla doğal dünyada karşılaştığımız görüntülerin doğal mı yoksa bilgisayarlar tarafından rastgele bir şekilde mi oluşturulduğunu kolaylıkla ayırt edebiliriz. Doğal görüntüler belirli bir yapıyı içerdikleri için bilgisayar tarafından oluşturulmuş görüntülerden farklıdır. Bilgisayar üzerinde rastgele bir şekilde oluşturulan görüntüler (bir ağaç görüntüsü olsa bile) gerçekte asla doğal bir sahne içermez. Gerçek dünyadaki oldukça büyük olası tüm görüntü uzayı içerisinde doğal görüntüler oldukça nadirdir (Ruderman, 1994). Biyolojik görme sistemleri evrim ve gelişimle birlikte aldıkları duyusal girdileri işleme almaya adapte olmaktadır. Dolayısıyla doğal görüntüler görme sisteminin uyumu ile benzer istatistiksel yapıya sahip olan veri kümeleridir (Hyvärinen ve diğ., 2009).

Tez kapsamında kullanılan doğal görüntüler kümesi Şekil 2.14'de verilmiştir (Favorov ve Kursun, 2011). Bu tez kapsamında desen tipi görüntülerin sınıflandırılması çalışmasının yanı sıra doğal görüntülerin sınıflandırılması da incelenmiştir. Buradaki amaç; kullanılan doğal görüntülerin insan biyolojik görme sistemine giren verilere benzer olmasından dolayı geleneksel görüntü işleme özellik çıkarım metotları ile biyolojik görme sisteminin veri işleme modeline benzer şekilde geliştirilmiş Favorov'un Katman-3 veri işleme modelinin başarımını karşılaştırmaktır.

Şekil 2.14: Tez kapsamında kullanılan beş farklı doğal görüntü veri kümesi (Favorov ve Kursun, 2011).

Doğal görüntüler uzayda dağılırken bilgisayar ortamında rastgele oluşturulan görüntüler gibi düzgün dağılımlı (uniformly distributed) görüntüler değildir. Gerçek dünyadaki doğal görüntülerin çoğu düzgün olmayan yapıdadır ya da bir diğer ifadeyle çok fazla sayıda artıklık (redundancy) içermektedir (Hyvärinen ve diğ., 2009). Düzgün dağılımlı ve düzgün dağılımlı olmayan imge örnekleri desen tanımının yer aldığı 2.3.1. bölümde yer alan Şekil 2.11'de gösterilmiştir.

2.5. ÖZNİTELİK ÇIKARIMI VE İSTATİSTİKSEL MODELLER

Öznitelik, bir nesneye ait ayırt edici karakteristik özelliklerin fonksiyonu olarak tanımlanır. Öznitelik çıkarımı, görüntü içerisinde yer alan bilgilerden problemin çözümüne ilişkin yeni bilgilerin elde edilmesi işlemidir. Bir sınıflandırma probleminde bir görüntüye ait şekil, renk, desen, yansıma, kenar özellikleri gibi öznitelikler elde edilebilir. Öznitelik vektörlerinin sınıflarda yer alan desen görüntülerini birbirinden ne kadar iyi ayırt edebildiği sınıflandırma problemlerin başarısını doğrudan etkilemektedir. Bu yüzden, sınıf içi değişimi en az sınıflar arası değişimi en fazla olan en az sayıda öznitelik çıkarmak öznitelik çıkarım yöntemlerinin esas amacıdır. Geleneksel görüntü

işleme yöntemleri, özniteliklerin belirlenmesinde sadece nesnelere ait yansıma bilgilerini kullanmaktadır. Desen sınıflandırılması problemlerinde geleneksel görüntü işleme yöntemleri yetersiz kalmaktadır. Bu yüzden, nesneye ait şekil, desen, komşuluk gibi bilgileri kullanan nesne tabanlı görüntü işleme yöntemleri desen sınıflandırılması problemlerinde daha doğru sonuçlar üretmektedir.

Bu tez çalışmasında desen tipi görüntülerin ve doğal tip görüntülerin sınıflandırılması problemlerine ilişkin geliştirilen deneylerde piksel tabanlı sınıflandırma yöntemi ile nesne tabanlı sınıflandırma yöntemlerinden *Gabor Dalgacık Dönüşümü* ve *Yerel İkili Desen (LBP)* öznitelik çıkarım yöntemleri kullanılmıştır.

2.5.1. Piksel Özniteliklerinin Çıkarılması

Piksel tabanlı sınıflandırma, 1970'li yıllarda çok bantlı görüntülerin işlenmesiyle ilk kez geliştirilmeye başlanmıştır. Geleneksel görüntü işleme yöntemlerinde, nesneye ait öznitelikler belirlenirken nesnelerin sadece yansıma bilgileri kullanılır. İstatistiksel olarak sınıflandırılacak görüntü gri-seviyeli piksel değerlerine göre benzer karakteristik özellikleri taşıyan piksel sınıfına atanır (Altunkaya ve diğ., 2011).

2.5.2. Gabor Dalgacık Dönüşümü (GWT) Öznitelik Çıkarım Metodu

İmgelerin etkin bir şekilde analizini gerçekleştiren Gabor dalgacıkları, insan görme sistemindeki konik hücrelerin uzaysal frekans ve yönelim seçici özelliklerinden esinlenerek hazırlanmıştır. Gabor dalgacıkları, desen tipi imgelerin sınıflandırılması (Avcı, 2007), kan damarı hücrelerini bölütleme (Yavuz ve Köse, 2014), parmak izi tanıma (Çalışkan ve Ertuğrul, 2015), MR beyin imgelerinden öznitelik çıkarma (Bağcı ve Bai, 2007) gibi çeşitli görüntü işleme ve bilgisayar görüsü uygulamalarında yaygın bir şekilde kullanılmaktadır.

Karmaşık bir Gabor dalgacığı Gauss biçimli zarf fonksiyonu ile çarpılmış sinüs fonksiyonları olarak tanımlanabilir. 2 boyutlu bir Gabor dalgacık dönüşümü $I(x, y)$ imgesinin katlanmasıyla elde edilir. Gabor dalgacıklarının elde edilmesine dair fonksiyon Eşitlik 2.1'de gösterilmektedir (Petkov ve Kruizinga, 1997). Burada $g(x, y)$ fonksiyonu Gabor filtresini ifade etmektedir.

$$I(x,y) = \iint I(x',y')g\,(x-x',y-y')\,dx'dy' \tag{2.1}$$

$$g(x,y;\lambda,\theta,\varphi,\sigma,\gamma) = e^{\frac{{x_1}^2+y^2{y_1}^2}{2\sigma 2}}\cos(2\pi\frac{x_1}{\lambda}+\varphi) \tag{2.2}$$

$$x_1 = x\cos\varphi + y\sin\varphi \tag{2.3}$$

$$y_1 = -x\sin\varphi + y\cos\varphi \tag{2.4}$$

Yukarıdaki formülde λ kosinüs dalgasının dalga boyunu, θ dalgacığın yönelimini, φ sinüsün fazını, σ Gauss biçiminin yarıçapını ve γ Gauss biçiminin en boy oranını belirtmektedir. Şekil 2.15'te 3 ölçekli ve 8 yönelimli Gabor filtrelerinin büyüklük ve gerçel kısımları gösterilmektedir.

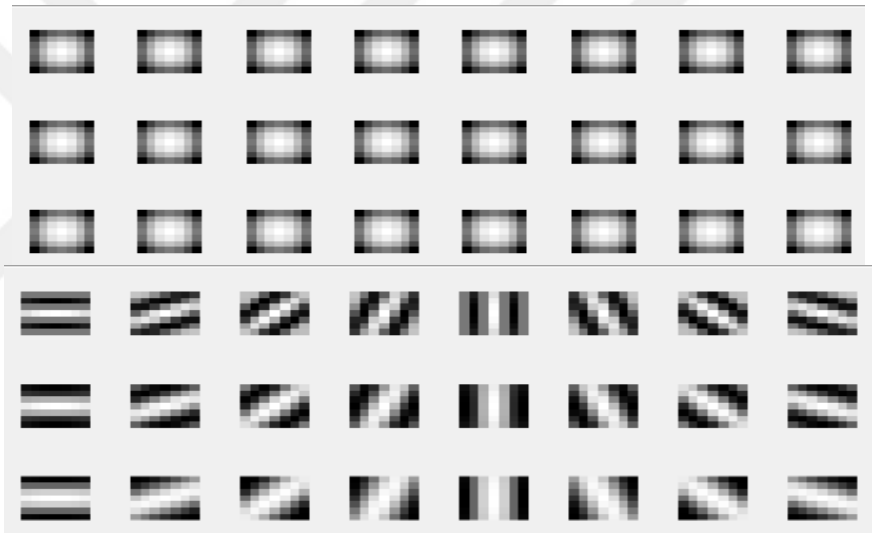

Şekil 2.15: Gabor filtresinin 3 ölçek ve 8 yönelimdeki büyüklük imgelerinin (ilk 3 satır) ve gerçel imgelerinin (son 3 satır) görünümü.

3-ölçek ve 8-yönelimli Gabor filtresi için 32x32 boyutundaki gri-seviyeli bir imge parçası kullanıldığında 3x8x32x32 =24.576 boyutunda bir öznitelik vektörü oluşur. Görüldüğü üzere yüksek boyutlarda imge için Gabor özellik sayısı oldukça fazla olacaktır. Bir imgenin komşu pikselleri yüksek korelasyona sahip olduğundan Gabor filtresinden kaynaklanan özellik imgesinin boyutu indirgenerek bu bilgi fazlalığı azaltılabilir (Haghighat ve diğ., 2015). Bu öznitelikler birim varyans ve sıfır ortalamaya göre normalize edilir. Örneğin; indirgemeyi hem satır hem de sütun için 4 olarak belirlersek 32x32 boyutundaki bir imge parçasının (3x8x32x32)/4*4=1536 tane öznitelik vektörü oluşacaktır.

2.5.3. Yerel İkili Desen (LBP) Öznitelik Çıkarım Metodu

Ojala ve diğ. (1996) tarafından önerilen orijinal LBP operatörü desen tanımlanmasında kullanılan güçlü bir araçtır. Orijinal LBP operatörü, bir görüntünün her bir piksel değerini 3x3 boyutundaki komşu piksel değerleri ile merkez piksel değerini eşleştirir ve sonucu bir ikili sayı olarak düşünerek görüntünün piksel değerlerini etiketler. Etiketlerin histogram değerleri bir desen tanımlayıcısı olarak kullanılabilir. Orijinal LBP operatörü Şekil 2.16'da gösterilmiştir.

Orijinal LBP operatörü daha sonra farklı boyutlara sahip komşu değerlerini kullanabilmek için geliştirilmiştir (Ojala ve diğ., 2002). Burada, komşu piksel değerleri için R yarıçapına sahip bir çember üzerinde P örnekleme sayısını temsil eden $LBP_{P,R}$ gösterimi kullanılır. Örnekleme noktası piksel bölgesinin merkezine denk gelmediği zaman çift doğrusal ara değerleme (bilinear interpolation) yöntemi kullanılmaktadır.

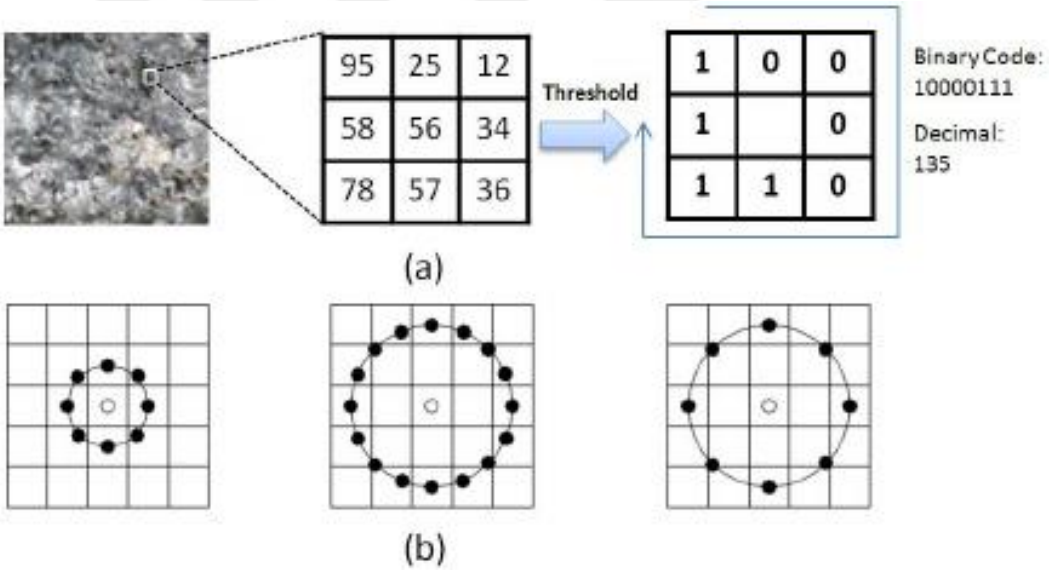

Şekil 2.16: (a) Orijinal LBP operatörü, (b) dairesel (8,1), (16,1) ve (8,2) komşuluklar (Zhao ve diğ., 2011).

Yukarıda gösterilen orijinal LBP operatörünün çalışma örneğinde 3x3 boyutundaki bir pencerede eşik değer merkez pikselin gri seviyesi olan 56 değeridir. Merkez pikselin gri seviye değeri sırasıyla 8 komşu piksel değerleri ile karşılaştırılır. Burada karşılaştırılacak komşu piksel değeri eşik değerden küçük ise 0, büyük veya eşit ise 1 olarak etiketlenir. Her bir pencere alanının 8 piksel ikili sayısı belirlendikten sonra, her bölge saat yönünde veya saat yönünün tersi yönünde 2^i (i =1,2,…,7) sayıda

ağırlıklandırma değeri atanır. 3x3 boyutunda bir alanda 8 bit ikili sayı vardır ve toplam 2^8=256 tane desen elde edilir. Ancak; 256 tane desen tipinin tümü görüntünün desen özelliğini çok iyi tanımlayamaz.

Çok fazla örnek sayısı P ve çok büyük yarıçap değeri R kullanıldığında 3x3'lük bir alanda kullanılan piksel sayısı az olmasına rağmen ($LBP_{P,R}$)'nin ikili desen sayısı ve hesaplama maliyeti çok fazla artacak aynı zamanda kullanışsız ve oldukça seyrek bir histogram elde edilecektir. Bu problemi çözmek için orijinal LBP operatörünün bir başka uzantısı olan düzenli desenlerin tanımı Ojala ve diğ. (2002) tarafından geliştirilmiştir. LBP dizisi çember olarak kabul edildiğinde eğer LBP kod dizisinde 0'dan 1'e veya 1'den 0'a en çok iki bit geçişi görülüyorsa LBP operatörüne düzenli (uniform) denilmiştir. Örneğin; 00000000, 00011100, 01000000 ikili kodlarından en çok iki bit geçişi görüldüğünden düzenli desenlerdir. Düzenli LBP operatörü $LBP_{P,R}^{u2}$ gösterimi Eşitlik (2.5)'te verilmiştir (Tan ve diğ., 2016).

$$LBP_{P,R}^{u2} = \left|s\left(g_{p-1} - g_c\right) - s(g_0 - g_c)\right| + \sum_{i=1}^{p-1} \left|s(g_i - g_c) - s(g_{i-1} - g_c)\right| \quad (2.5)$$

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

Yukarıda gösterilen $LBP_{P,R}^{u2}$ operatörünün formülündeki altsimge (P, R), R yarıçaplı bir dairede P değeri kadar komşu piksel alanında kullanılmasını temsil etmektedir. Üstsimge $u2$ sadece aynı (uniform) desen kullanılmasını ve aynı olmayan (non-uniform) desenlerin ise tek bir etiket ile temsil edilmesini göstermektedir. P örnek sayısı verildiğinde aynı yapıya sahip desen sayısı $P = P^2 - P + 2$ formülü ile temsil edilir. Örneğin; 32x32 boyutundaki bir görüntünün $LBP_{8,1}^{u2}$ operatörü kullanılarak toplam P=8^2-8+2=58 tane aynı dağılımlı desenler ve normal dağılımlı olmayan desenlerin hepsi aynı desen tipi 1 olarak temsil edildiğinden toplam 59 tanedir. Düzenli $LBP_{P,R}^{u2}$ operatörü kullanıldığında öznitelik histogram boyutu büyük ölçüde azalmaktadır. Şekil 2.17'de bir görüntünün orijinal histogramı ile düzenli $LBP_{8,1}^{u2}$ operatörü kullanıldığında elde edilen histogramı gösterilmiştir.

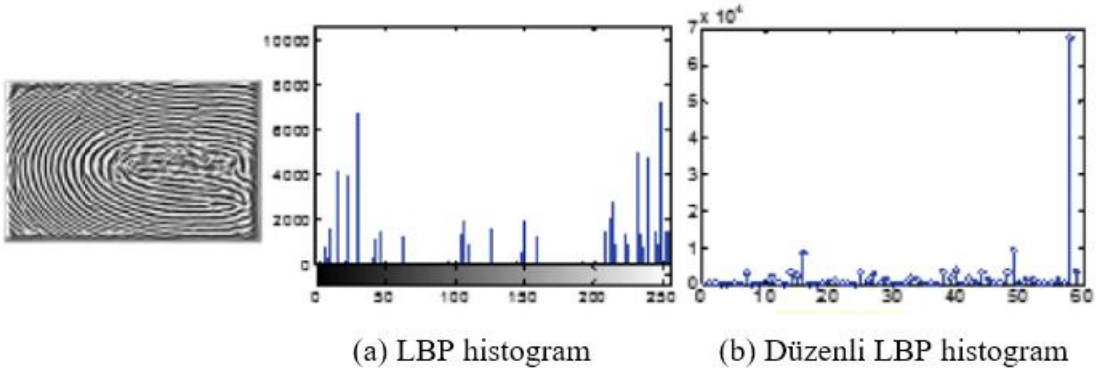

Şekil 2.17: Parmak izi görüntüsünün orijinal LBP ve düzenli LBP histogramı (Tan ve diğ., 2016).

LBP operatörü desen analizi, desen sınıflandırılması, desen bölümlendirilmesi, biyomedikal görüntülerin sınıflandırılması ve yüz tanıma gibi farklı uygulama alanlarında sıklıkla kullanılmaktadır. Doshi ve Schaefer (2012), desen analizi çalışmalarında eş oluşum matrisi, Gabor özellikleri gibi neredeyse tüm geleneksel desen analizi yöntemlerine göre LBP ve LBP'nin farklı eklentilerinin daha başarılı olduklarını yaptıkları çalışmayla ispatlamıştır.

2.5.4. Katman-3 (L3) Veri İşleme Modeli

Yapay öğrenme ve desen tanıma alanlarına ait doğrusal olmayan problemlerin çözümüne yönelik birçok yöntem geliştirilmiştir. Geliştirilen yöntemler içerisinden girdi uzayının daha yüksek bir boyuta sahip yeni bir uzaya taşınması sonucu öznitelik uzayının elde edilmesi yöntemi en etkilisidir (Şekil 2.18). Böylece, doğrusal olmayan bir uzayda temsil edilen problem bu dönüşüm sayesinde doğrusal yöntemler ile çözülebilme imkânı bulabilmektedir.

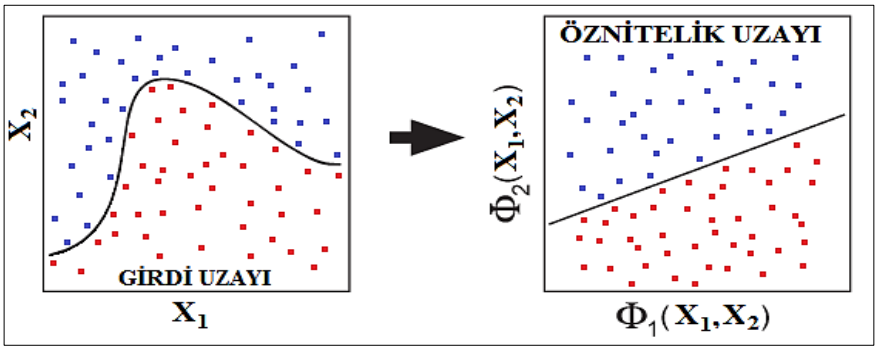

Şekil 2.18: Girdi uzayının "öznitelik" uzayına dönüşümü (Favorov ve Kursun, 2011).

Yukarıda gösterilen sol taraftaki şekil iki sınıfa ait girdi uzayının doğrusal olmayan bir doğru ile ayrılmasını ifade ederken, sağ taraftaki şekil ise doğrusal olmayan bir dönüşüm sonrasında iki sınıfa ait girdi uzayının doğrusallaştırılmasını ifade etmektedir. Bu dönüşüm sayesinde elde edilen öğrenme fonksiyonu yeni gelen bir girdiyi daha kolay öğrenerek sınıflandırabilecektir.

Desenleri algılama, kavrama, sınıflama gibi konularda insan biyolojik görme sistemi yapısı örnek alınarak çeşitli yöntemler geliştirilmektedir. Görme sisteminin en çok bilinen ve en çok çalışılan alanı birincil görme korteksidir (V1). Birincil görme korteksi, alt katmanlar ve talamustan gelen girdileri kullanarak birçok doğrusal olmayan fonksiyonları öğrenebilmektedir. Bu alanda kullanılan girdi uzayının üst katmanlar ile sürekli bir etkileşim halinde olması nedeniyle hücrelerin çıktılarının şekillenmesine etki eder. V1 alanında yer alan 6 katman farklı fonksiyonel görevleri yerine getirmektedir. Bu katmanlar içerisinden görsel bilgilerin alındığı ve LGN tarafından filtrelenmiş bilgilerin ilk işlendiği Katman-4 için geliştirilmiş birçok matematiksel model vardır. Katman-4 aldığı bilgileri doğrusal olmayan Gauss çekirdeğine benzer bir dönüşümden geçirerek problem doğrusallaştırma işlemlerini gerçekleştirir (Tübitak Projesi, 2016). Daha sonra yeni bir forma dönüşen bilgiler daha detaylı bir şekilde işlenmesi için Katman 3'e gönderilir. Katman 3'te işlenen bilgi tekrar L4'e gönderilerek daha üst seviyede aynı işlemin tekrarlanması sağlanır (İsenkul, 2016). Burada L4 katmanının fonksiyonel rolü Favorov'un çalışmasında (Favorov ve Kursun, 2011) elde edilen teorem ile bir kortikal alana giren bilgiler arasındaki doğrusal olmayan etkileşimleri öğrenmeyi kolaylaştırdığı ve bu bilgilerin öğrenilmesi amacıyla elde edilen etkileşimleri doğrusallaştırarak bir üst katmana ilettiği keşfedilmiştir (İsenkul, 2016). L4 katmanının en önemli özniteliği lokal olarak yerleşmiş L4 alıcıların çok yönlü fonksiyon doğrusallaştırma özelliğine sahip radyal tabanlı fonksiyon (RBF) ağlarına çevirdiği Favorov'un çalışmasında gösterilmiştir (Favorov ve Kursun, 2011). Katman-4 veri işleme modelinde kedilerdeki birincil görme kortekse (V1) benzer şekilde yapısal ve fonksiyonel matematiksel ileri beslemeli baskılama L4 modeli doğal görüntüler içerisindeki kendinden düzenli bağlantılar kullanılarak formülize edilmiştir. L4 modelinde kullanılan görsel girdi örüntüleri tez çalışmasındaki YARD veri kümesine ait 5 adet 500x335 boyutlarında gri-seviyeli doğal görüntüleri içermektedir. Somers ve diğ. (1995)'nin modellemiş olduğu retinal/LGN modeli kullanılarak LGN'e benzer nöronlar

modellenmiştir. Bu LGN katmanında 91 adet ON-merkezli ve 91 adet OFF-merkezli olmak üzere toplam 182 adet alıcı alanları bulunmaktadır. Gerçek L4 ile Favorov'un geliştirmiş olduğu L4 matematiksel modelinin problem doğrusallaştırma yeteneklerinin benzer olduğu Favorov'un çalışmasında gösterilmiştir (Favorov ve Kursun, 2011).

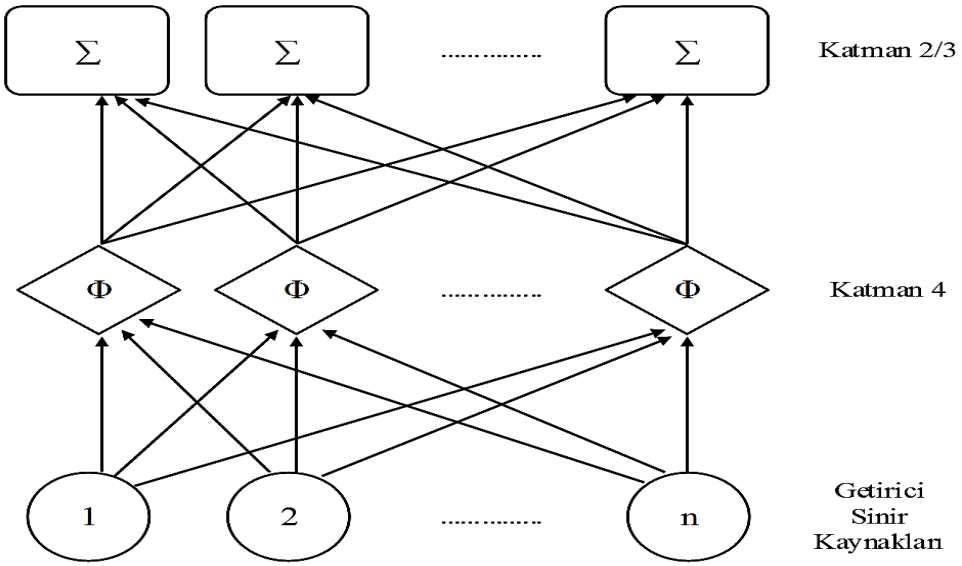

Şekil 2.19: Kortikal sütundaki fonksiyon doğrusallaştırma yöntemi (Favorov ve Kursun, 2011).

Şekil 2.19'da gösterilen Katman-3 veri işleme modelinde L3 hücreleri tarafından alınan girdiler ilk önce L4 katmanı tarafından doğrusal olmayan yöntemle dönüştürüldükten sonra L3 katmanı tarafından işlenir (Favorov ve Kursun, 2011). Bunun nedeni, L3 katmanında bulunan girdilerin Şekil 2.19'da gösterilen fonksiyon doğrusallaştırma yönteminden çok daha karmaşık, ayrıntılı ve L3 ile doğrusal ilintinin çok az olmasından kaynaklanmaktadır. Bu işlem sayesinde L3 ile girdiler arasında doğrusal ilinti artışı yapılarak doğrusal yöntemler ile öğrenme fonksiyonlarının oluşturulması sağlanmıştır (İsenkul, 2016). Katman-3 veri işleme modeli Şekil 2.19'da görüldüğü üzere Katman-4 veri işleme modelindeki her bir RBF çıktılarının ağırlıklı toplamından oluşmaktadır. Bu tez çalışmasında kullanılan Katman-3 veri işleme modeli, lokal Katman-4'lerin doğrusal boyut indirgeme yöntemi ile 5 boyutlu Katman-3 gösteriminin elde edilmesinden oluşturulmuştur (Tübitak Projesi, 2016). Böylece, desenlerin sınıflandırılmasında çok daha fazla sayıda L4 özniteliği kullanmak yerine 5 tane L3 özniteliği kullanılarak hem sınıflandırıcının başarım sonuçlarında hem de zaman maliyeti açısından daha etkili ve kullanışlı bir yöntem olmuştur.

2.6. YAPAY ÖĞRENME VE İSTATİSTİKSEL ANALİZ

2.6.1. Yapay Öğrenme Nedir?

Öğrenmek, belli durumlar ve sorunlar karşısında tepki ve davranış oluşturma ve bu davranışları değiştirerek yenilerini edinebilme yeteneğidir (TDK, 2017). Öğrenme aynı zamanda deneyim, eğitim ve çalışma yoluyla davranışta meydana gelen uzun süreli değişimler olarak da tanımlanabilir.

İnsan zekâsının bilgisayarlara aktarılabilmesi düşüncesi yapay zekâ çalışmalarının temelini oluşturmuştur. Böylece, bilgisayarların çabuk işlem yapabilme, taşınabilirlik, kolay kopyalama gibi özellikleri ile yapay zekânın sunduğu birçok avantajdan faydalanılabilir. Yapay öğrenme, açık bir şekilde öğrenme algoritması olmadan deneysel verilerden elde edilen bilgiler yardımıyla bilgisayarlara öğrenme olanağı sağlayan yapay zekânın bir alt dalıdır. Bir problemi bilgisayarlarda çözebilmek için bir algoritmaya ihtiyaç duyulmaktadır; ancak her problemin çözümü için bir algoritma mevcut değildir. Örneğin; verilen birçok tamsayı değerlerini sıralamak için mevcut algoritmalar vardır; ancak e-posta adreslerine gelen istenmeyen mesajları sınıflandırmak gibi çoğu problemler için bir öğrenme algoritması mevcut değildir (Alpaydın, 2014). Bu gibi problemlerin çözümünde insandaki öğrenme süreçlerinden faydalanılarak geliştirilen yapay öğrenme yöntemlerine ihtiyaç duyulmaktadır.

Yapay öğrenme; parmak izi tanıma, yüz tanıma, istenmeyen e-postaları filtreleme, hava durumu tahmini, konuşma tanıma, desen tanıma, desen sınıflandırma, müşteri segmentasyonu (Schapire, 2008) ve duygu analizi (Nizam ve Akın, 2014) gibi birçok farklı problemler için çözümler bulmamıza yardımcı olmaktadır. Bu tez kapsamında yapay öğrenme yaklaşımları kullanılarak desen sınıflandırması problemleri incelenmiştir.

2.6.2. Öğrenme Yöntemleri

Yapay öğrenmede iki varlık önemlidir: Bunlardan birincisi belirli bir görevi yerine getirmek için gerekli bilgiye sahip olan öğretmen (teacher), ikincisi ise görevi yerine getirmesi için öğrenmesi gereken öğrencidir (learner). Camastra ve Vinciarelli (2008) öğrenme yöntemlerini 4 bölümde sınıflandırmıştır:

- Ezbere dayalı öğrenme (*rote learning*),
- Talimatlardan öğrenme (*learning from instruction*),
- Benzetim yoluyla öğrenme (*learning by analogy*),
- Örneklerden öğrenme (*learning from examples*),
    - Gözetimli öğrenme (*supervised learning*),
    - Gözetimsiz öğrenme (*unsupervised learning*).

2.6.2.1. Ezbere Dayalı Öğrenme

Ezbere dayalı öğrenme, yeni bilgiyi öğrenene doğrudan iletir ve öğrenen tarafından gerçekleştirmesi gereken hiçbir çıkarım söz konusu değildir. Bu öğrenme yöntemine örnek olarak öğrenen tarafından hiçbir çaba gerektirmeyen bilgisayar programları ve yeni gelen bilgiden çıkarımlar olmadan doğrudan öğrenmeye dayanan ilkel veri tabanı sistemleri verilebilir (Camastra ve Vinciarelli, 2008).

2.6.2.2. Talimatlardan Öğrenme

Talimatlardan öğrenme, öğrenenin bir öğretmen ya da ders kitabından edindiği bilgileri girdi dilinden başka bir içsel bir dile dönüştürmesine dayanır. Yeni bilgiler etkin kullanım için öğrenen tarafından bazı çıkarımlar yapılarak önceki bilgiler ile bütünleştirilir. Bu öğrenme yönteminde eğitim yöntemleri taklit edilir (Camastra ve Vinciarelli, 2008).

2.6.2.3. Benzetim Yoluyla Öğrenme

Benzetim yoluyla öğrenme, yeni durumda etkili bir şekilde yararlı olabilecek yeni kavram veya beceriye güçlü benzerlik getiren yeni gerçekler veya beceriler edinmeye dayalıdır. Bu öğrenme yönteminde, öğrenen daha fazla çıkarım yapmalıdır. Örneğin; orijinal olarak tasarlanmamış bir bilgisayar programı yakın ilişkili fonksiyonları gerçekleştiren mevcut bir bilgisayar programına dönüştürmek için benzetim yoluyla öğrenme yöntemi kullanılabilir (Camastra ve Vinciarelli, 2008).

2.6.2.4. Örneklerden Öğrenme

Örneklerden öğrenme, talimatlardan öğrenme ve benzetim yoluyla öğrenme yöntemlerinden daha fazla çıkarımın yapıldığı *basit öğrenme* olarak da bilinen bir yöntemdir. Öğrenen daha önceden verilen örnekleri kullanarak yeni bir kavram veya örnek için genelleme yapmalıdır. Örneklerden öğrenme iki öğrenme yöntemine ayrılmaktadır: Gözetimli öğrenme ve gözetimsiz öğrenme.

- ***Gözetimli öğrenme:*** Gözetimli öğrenme (veya öğretmen tarafından öğrenme) yönteminde veriler girdi-çıktı değerlerinden oluşan örnekleri kapsamaktadır. Bu öğrenme şeklinde veri kümesi iki kümeye ayrılır: Eğitim ve test kümesi. Eğitim kümesinde girdi-çıktı değerleri birlikte yer alır ve her bir örnek etiketlenmiş olarak kabul edilir. Seçilen bir gözetimli öğrenme algoritması ile eğitim kümesi incelenir ve yeni örnekleri eşleştirmek için kullanılabilen bir öğrenme modeli elde edilir. Elde edilen bu model önceden örneklerin bilinmediği test kümesi üzerinde model başarım ölçütlerine göre sınıflandırıcının başarısı ölçülür (Camastra ve Vinciarelli, 2008). Literatürde bu öğrenme yöntemi denetimli öğrenme, danışmanlı öğrenme ve eğiticili/eğitmenli öğrenme olarak da bilinmektedir. Gözetimli öğrenme çıktı türlerine göre sınıflandırma ve regresyon olarak ayrılmaktadır. Sınıflandırma, girdi vektörünü sonlu sayıdaki bir ayrık kategoriye atamayı amaçlayan problemlerdir (Mohri ve diğ., 2012). Örneğin; bir hastalığın teşhisi probleminde, çıkış değerlerinin 'hasta' veya 'hasta değil' gibi bir sınıf çıktısı olduğu problemler sınıflandırma problemlerine örnek verilebilir. Regresyon ise, iki veya daha fazla değişken arasındaki ilişkiyi ölçmeyi sağlayan bir metottur. Çıkış değerlerinin gerçek çıktı değerleri ile temsil edildiği problemler regresyon problemleri olarak bilinir. Örneğin; bir öğrencinin derse gelmediği gün sayısı ile o dersteki başarı oranının ölçülmesi, basınç ile sıcaklık arasındaki ilişkinin ölçülmesi veya bir kişinin gelir düzeyi ile tüketim giderleri arasındaki ilişkinin ölçülmesi regresyon problemlerine örnek verilebilir (Wikipedia, 2017).

- ***Gözetimsiz öğrenme:*** Gözetimsiz öğrenme, sadece girdi değerlerinin olduğu ve çıktı değerlerinin olmadığı bir öğrenme yöntemidir. Gözetimsiz öğrenmede hiç öğretmen yoktur. Bu öğrenme yönteminin amacı, verilerin izlenmesi ile bu örneklerin özellikleri arasındaki benzerliklerin bulunarak sınıfların tanımlanmasıdır (Camastra ve Vinciarelli, 2008). Gözetimsiz öğrenme, görüntü ve metin segmentasyonu, aldığı ürün bakımından müşterilerin sınıflandırılması, bitki ve hayvan gruplarının özelliklerine göre sınıflandırılması, deprem bölgelerinin önem sırasına göre belirlenmesi ve desen gruplarının keşfedilmesi gibi çeşitli uygulamalarda kullanılmaktadır.

2.6.3. Modelleme

Yapay öğrenmenin amacı, eğitim kümesindeki verilerden öğrenme işlemini gerçekleştirip bir model ortaya çıkarmak ve bu modeli daha önce görülmemiş örneklerden oluşan test kümesi üzerinde analiz ederek sonuç elde etmektir. Yapay öğrenme modeli 3 farklı durumda bulunabilir: Ön yargı durumu, normal durum ve varyans durumu (Şekil 2.20) (Mishchenko., 2017).

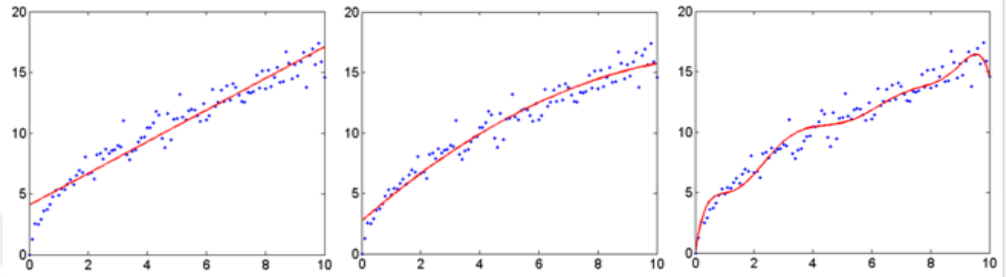

Şekil 2.20: Yapay öğrenme modelleri (Mishchenko, 2017).

Ön yargı durumu, çok basit ve çok fazla ön bilginin yer aldığı bir modeldir. Bu model test kümesi üzerinde verileri iyi temsil edemediğinden dolayı model başarısı düşüktür. Varyans durumu, çok fazla karmaşık ve esnek bir modeldir. Bu yüzden; bu model bütün gürültüleri temsil ettiğinden doğru bir ilişki bulamaz. Bu iki durumda model başarımı için iyi bir model değildir. Normal durum, bu iki modelin ortasında bulunur, ne çok basit ne de çok karmaşık bir modeldir (Mishchenko., 2017).

Yapay öğrenme çalışmalarında model seçimini gerçekleştirirken iki yol izlenebilir. Birinci yolda, aynı öğrenme modelinin farklı parametre değerlerindeki başarıları test kümesi üzerinde karşılaştırılarak en iyisi seçilebilir. İkinci yolda ise, farklı öğrenme modelleri kullanılarak test kümesi üzerindeki başarıları karşılaştırılarak en iyisi seçilebilir.

Bu tez çalışmasında, birinci yol izlenerek Destek Vektör Makineleri (DVM)'nin farklı parametre değerleri ve farklı çekirdek fonksiyonları ile desen sınıflandırması problemi için model başarımları karşılaştırılmıştır.

2.6.3.1. Destek Vektör Makineleri (DVM)

Destek Vektör Makineleri (DVM)'nin teorik temelleri 1960'lı yıllarda V. Vapnik tarafından ortaya atılmış ve 1995 yılında da sınıflandırma için önerilmiştir. DVM, istatistiksel öğrenme teorisine diğer bir deyişle Vapnik-Chervonenkis (VC) teorisine dayalı bir gözetimli öğrenme ve sınıflandırma yöntemidir. DVM'nin amacı, genelde {+1, -1} sınıf etiketlerinden oluşan iki sınıfa ait örneklerin bilindiği bir uzayı ikiye bölen en iyi karar fonksiyonunu tahmin etmek veya karar sınırlarını (hiper düzlemlerini) belirlemektir (Cortes ve Vapnik, 1995). Şekil 2.21'de gösterildiği gibi iki sınıflı verileri birbirinden ayırabilen birçok hiper düzlem bulunabilir.

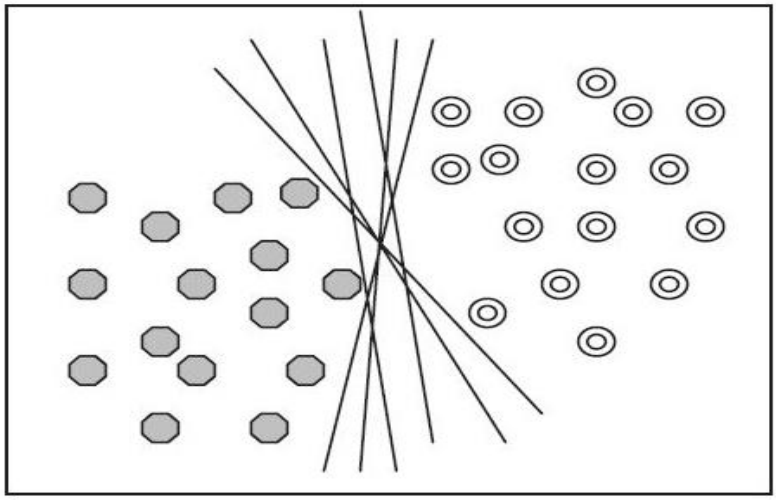

Şekil 2.21: İki sınıflı bir problem için hiper düzlemler (Wikipedia, 2017).

İki sınıf arasındaki sınırı maksimuma çıkararak en uygun ayrımı yapan hiper düzleme optimum hiper düzlem ve sınır genişliğini sınırlandıran noktalara ise destek vektörler denilmektedir (Şekil 2.22). Destek vektörler bulunduğu sınıfın orijine en yakın olan elemanlarıdır. Ayırıcı düzlemin optimum olması için destek vektörlerle ayırıcı düzlem arasındaki mesafenin maksimum olması gerekir (Çomak, 2004).

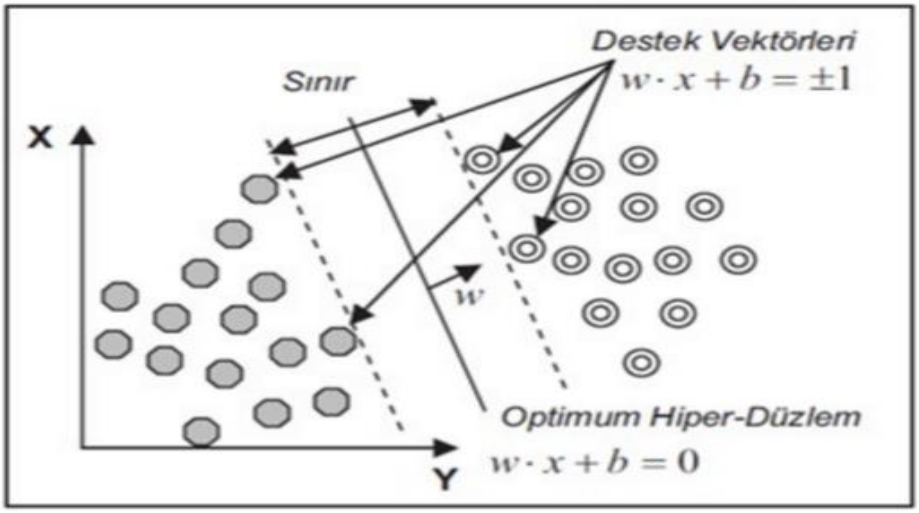

Şekil 2.22: Optimum hiper düzlem ve destek vektörleri (Wikipedia, 2017).

Doğrusal olarak ayrılabilme durumunda $x_i \in R^d$ özellikler vektörü her biri y_i={-1,+1} ile gösterilen sınıflardan birine ait olmak üzere n sayıdaki eğitim verisi$\{x_i,y_i\}$şeklinde ifade edilsin. Bu durumda, ayırıcı aşırı düzlem f(x) fonksiyonu ile ifade edilir:

$$f(x) = w^t.x + b = \sum_{i=1}^{n} w_i\, x_i + b \tag{2.6}$$

Burada w, aşırı düzlemin normalini, b sabiti ise sapma değerini ifade eder. |b|/||w|| aşırı düzlemin orijine olan uzaklığı, x aşırı düzlem üzerindeki herhangi bir nokta olmak üzere $f(x) = w^t.x + b = 0$ koşulunu sağlamaktadır. Ayırıcı düzlem verileri ikili sınıflar için Eşitlik 2.7'deki gibi yazılır.

$$\textit{Sınıf 1: } f(x) > 0 \; için \; y_i = +1 \tag{2.7}$$

$$\textit{Sınıf 2: } f(x) < 0 \; için \; y_i = -1$$

DVM'ler iki sınıflı problemler üzerine kurulu bir sınıflandırıcıdır. Ancak; birçok problemlerde çoklu sınıf etiketlerine sahip verileri sınıflandırma ihtiyacı duyabiliriz. Şekil 2.23'de çoklu sınıflar için DVM yöntemi gösterilmiştir.

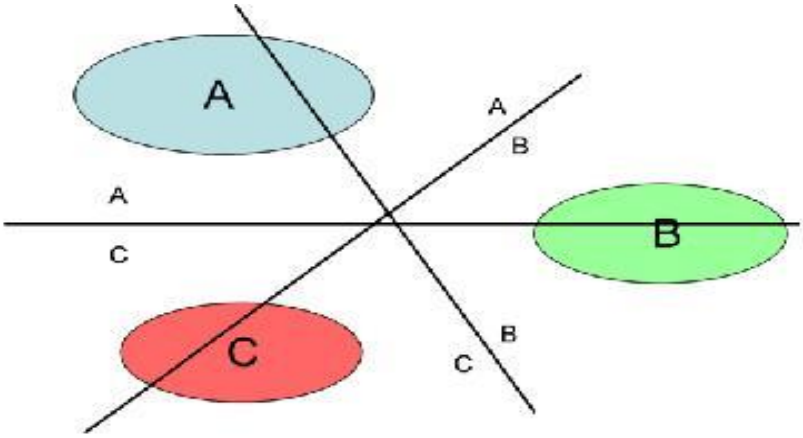

Şekil 2.23: Çoklu sınıf problemleri için hiper düzlemler.

Çoklu sınıf etiketlerine (i=1,2,…,n) sahip verileri DVM ile sınıflandırılabilmek için 2 yöntem bulunmaktadır: 1-v-r (bire karşı kalanlar) ve 1-v-1 (bire karşı bir) yöntemi (Wikipedia, 2017).

- ***1-v-r (bire karşı kalanlar) yöntemi:*** Vapnik tarafından 1998 yılında önerilmiştir. Bu yönteme göre metodun her bir çalıştırılmasında bir sınıfa ait olan veriler diğer tüm sınıf etiketlerine sahip olan verilerden ayrılması stratejisi üzerine kurulmuştur. Bu yöntemin dezavantajı ise eğitim kümesindeki veriler çok sayıda olduğunda eğitim süresinin artmasıdır.

- ***1-v-1 (bire karşı bir) yöntemi:*** Bu yöntemde k sayıda etikete sahip veriler için $k = k * (k - 1)/2$ sayıda destek vektörün eğitilmesi gerekmektedir. Kullanılacak sınıf etiketi sayısına göre destek vektör sayıları değişmektedir. Örneğin; üç sınıfa ait verilerin bulunduğu bir problemde, birinci sınıflandırıcı A ve B etiketine sahip sınıfları birbirinden ayırır. İkinci sınıflandırıcı, A ve C etiketine sahip sınıfları birbirinden ayırır. Üçüncü sınıflandırıcı, B ve C etiketine sahip sınıfları birbirinden ayırır (Şekil 2.23).

2.6.4. Model Seçimi ve Değerlendirme

Bir modelin performansının değerlendirilmesi için literatürde geliştirilmiş birçok model başarım ölçütleri ve yöntemleri bulunmaktadır. Model değerlendirme yöntemleri ve modelin değerlendirilmesi için kullanılan model başarım ölçütleri bu bölümde açıklanmıştır.

2.6.4.1. Model Performans Değerlendirme Yöntemleri

Yapay öğrenme metotları kullanılarak herhangi bir problemin çözümüne uygun olarak bir model elde edilmektedir. Değerlendirme işlemi, uygulanan birçok model içinde hangi modelin daha iyi olduğunu bulmak ve ileride öğrenme modelinin ne ölçüde iyi çalışacağını anlamak için yapılmaktadır. Bir modelin performansı kullanılan yapay öğrenme metodunun haricinde sınıf dağılımı, eğitim ve test kümelerinin belirlenmesine de bağlıdır. Model performansını değerlendirmek için geliştirilmiş yöntemlere aşağıda kısaca yer verilmiştir.

- **Hold-out:** Bu yöntemde veri seti eğitim kümesi ve test kümesi olarak ikiye ayrılmaktadır. Eğitim kümesinde, model seçimi için seçilmiş olan sınıflandırma algoritmasının eğitiminin gerçekleştirilmesi, seçilen model için en iyi parametrelerin belirlenmesi gerçekleştirilir. Test kümesinde ise eğitim aşamasında belirlenen parametreler ile modelin genel performansı bulunur. Bu yöntemin dezavantajları, veri setinin küçük olması durumunda test kümesi için yeteri kadar verinin yer almaması veya eğitim ve test kümesi sadece bir kere oluşturulduğu için bu ayrımdan kaynaklanan hata oranında sorunların olabilmesidir.

- **Tekrarlı Hold-out:** Bu yöntemde veri seti farklı alt kümelere bölünerek hold-out işlemi tekrarlanır. Her eğitim aşamasında veri setinin belli bir oranı eğitim kümesine geri kalanı ise test kümesine atılır. Eğitim kümesinde karar verilen model ve parametreler kullanılarak test kümesi üzerinde genel performans sonuçları elde edilir. Son olarak alınan tüm performans sonuçlarının ortalaması bu yöntemin performansını göstermektedir. Bu yöntemin dezavantajı farklı eğitim aşamalarında test kümelerinin örtüşebilmesidir.

- **Çapraz Geçerleme (Cross Validation):** Çapraz geçerleme, *k-kat çapraz geçerleme (k-fold)* ve *birini dışarıda bırak çapraz geçerleme (leave one out-LOOCV)* olmak üzere iki farklı biçimde uygulanabilmektedir. ***K-kat çapraz geçerleme* yöntemi**, veri seti k eşit parçaya ayrılarak her seferde k parçadan bir tanesi test, $k-1$ tanesi de eğitim için kullanılmaktadır. Sonuçta elde edilen k tane hata oranının ortalaması alınarak modelin tüm tahmin hatası bulunur

(Kartal, 2015). Şekil 2.24'de k=5 değeri için çapraz geçerleme şematize edilmiştir.

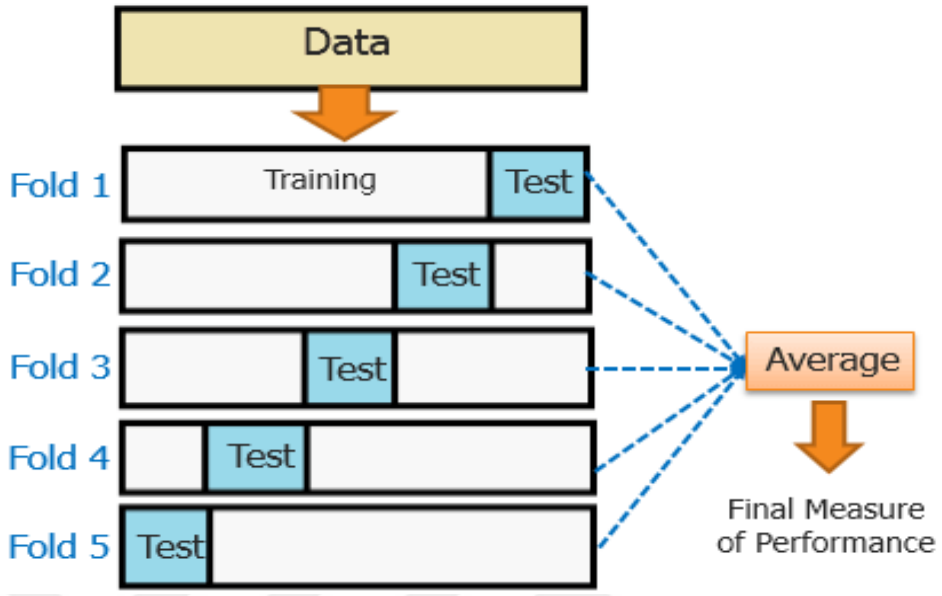

Şekil 2.24: 5-kat çapraz geçerleme (Wikipedia, 2017).

Birini dışarıda bırak yöntemi ise, veri setinde her seferinde sadece 1 örnek test veri seti, geri kalan örnekler ise eğitim veri seti olarak kullanılmaktadır. Bu yöntem özellikle veri setindeki örnek sayısının çok az olduğu durumlarda veya özellik seçimi yapılması durumlarında tercih edilmektedir.

- **Bootstrap örnekleme:** Bootstrap yöntemi, standart sapma, güven aralığı gibi istatistiklerde ve parametrik olmayan tahmin yapma çalışmalarında kullanılan basit ve güvenilir bir yöntemdir. Bu yöntem, mevcut veri setindeki gözlemlerin herhangi bir sayı miktarı kadar rastgele seçilmesi sonucu yeni veri setlerinin oluşturulması mantığına dayanmaktadır. Eğitim veri kümesi oluşturulurken seçilen örnekler veri setinden çıkarılmadığı için aynı örnekler eğitim kümesinde de bulunabilir. Yönteme ait şematik gösterim Şekil 2.25'te yer almaktadır (Takma ve Atıl, 2003). Test kümesi oluşturulurken ise, eğitim veri kümesi içerisinde yer alan veriler hariç gerçek veri setindeki verilerden oluşturulur. Böylece, test veri kümesinde her örnek sadece bir defa tekrar etmektedir.

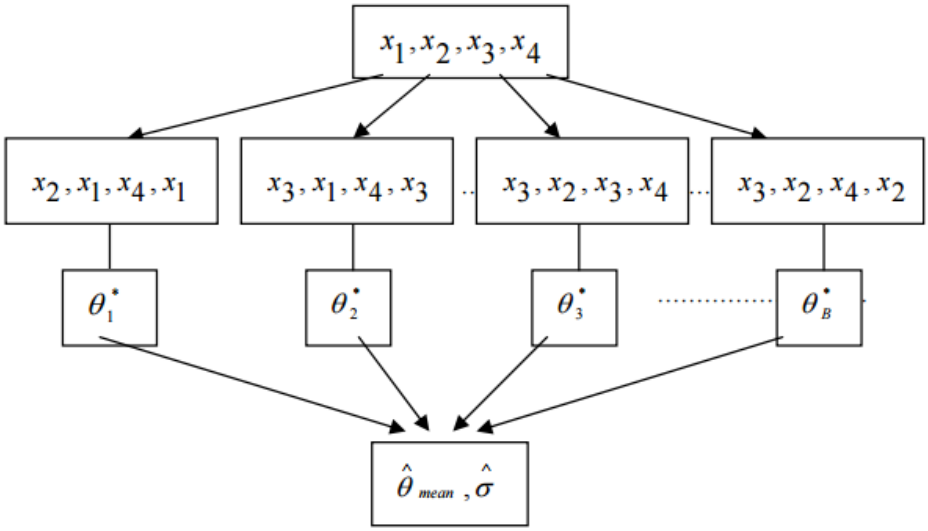

Şekil 2.25: Bootstrap metodunun şematik gösterimi (Takma ve Atıl, 2003).

2.6.4.2. Model Performans Değerlendirme Ölçütleri

Gözetimli öğrenmeli yapay öğrenme çalışmalarında öğrenme algoritmalarının başarılarını değerlendirmek için çeşitli yöntemler geliştirilmiştir. Bu yöntemler bir problemin çözümü için uygulanmış çeşitli sınıflandırıcılar içerisinden en iyisini seçebilmemiz için bizlere yardımcı olmaktadır. Sınıflandırıcının kalitesinin ölçüsü her bir sınıf için doğru sınıflandırılmış ve yanlış sınıflandırılmış örneklerin gösterildiği karışıklık matrisi (confusion matrix) tarafından belirlenir. Tablo 2.1'de ikili bir sınıflandırma problemi için karışıklık matrisi gösterilmiştir. Bu tabloya göre ikili sınıflandırma sonuçlarının değerlendirilmesinde kullanılan doğruluk (accuracy), hata oranı (error rate), duyarlılık (sensitivity ya da recall), kesinlik (precision) ve f-ölçütü (f-measure) açıklanmıştır.

Tablo 2.1: Karışıklık matrisi (Wikipedia, 2017).

		Öngörülen sınıf (Predicted Class)		
Gerçek Sınıf (Actual Class)		C_1 (Positive)	C_2 (Negative)	
	C_1 (Positive)	True positive TP	False negative FN	ΣPositive
	C_2 (Negative)	False positive FP	True negative TN	ΣNegative

Doğruluk - Hata Oranı: Doğru sınıflandırılmış örnek sayısının (TP + TN), toplam örnek sayısına $(TP + TN + FP + FN)$ oranıdır (Eşitlik 2.8). Hata oranı ise bu değerin 1'e tamlayanıdır (Eşitlik 2.9). Diğer bir ifadeyle yanlış sınıflandırılmış örnek sayısının $(FP + FN)$ toplam örnek sayısına $(TP + TN + FP + FN)$ oranıdır.

$$Doğruluk\ oranı = \frac{TP + TN}{TP + TN + FP + FN} \tag{2.8}$$

$$Hata\ oranı = \frac{FP + FN}{TP + TN + FP + FN} \tag{2.9}$$

Duyarlılık (sensitivity): Sınıflandırıcının pozitif sınıf etiketlerini tahmin etmesindeki etkililiğini gösterir. Doğru sınıflandırılmış pozitif örnek TP sayısının, toplam pozitif örnek sayısına (TP + FN) oranıdır (Eşitlik 2.10).

$$Duyarlılık = \frac{TP}{TP + FN} \tag{2.10}$$

Kesinlik (Precision): Kesinlik, sınıfı 1 olarak tahmin edilmiş True Pozitif TP örnek sayısının, sınıfı 1 olarak tahmin edilmiş tüm örnek sayısına (TP + FP) oranıdır (Eşitlik 2.11).

$$Kesinlik = \frac{TP}{TP + FP} \tag{2.11}$$

F-ölçütü (F-measure): Kesinlik ve duyarlılık ölçütleri tek başına anlamlı bir karşılaştırma sonucu çıkarmamıza yeterli değildir. Her iki ölçütü beraber değerlendirmek daha doğru sonuçlar verir. F-ölçütü, kesinlik (K) ve duyarlılığın (D) harmonik ortalamasıdır (Eşitlik 2.12).

$$F - ölçütü = \frac{2 * D * K}{D + K} \tag{2.12}$$

3. MALZEME VE YÖNTEM

3.1. GEOMETRİK GÖRÜNTÜ DÖNÜŞÜMLERİ

Bir görüntü üzerinde büyültme, küçültme, döndürme veya eğme işlemlerini gerçekleştiren fonksiyonlara geometrik fonksiyonlar denir. Geometrik görüntü dönüşümleri çeşitli uygulamalar için kullanılabilir. Örneğin; görüntü tanıma uygulamalarında kullanılacak eğitim kümeleri geometrik dönüşüm fonksiyonları yardımıyla yapay olarak oluşturulabilir. Geometrik görüntü dönüşüm yöntemleri afin (affine) dönüşümler ve perspektif dönüşümler olmak üzere iki çeşittir (Şekil 3.1). Bu tez çalışmasında desen sınıflandırması testlerinde kullanılacak görüntü kümelerini oluşturmak için afin dönüşümler kullanılmıştır.

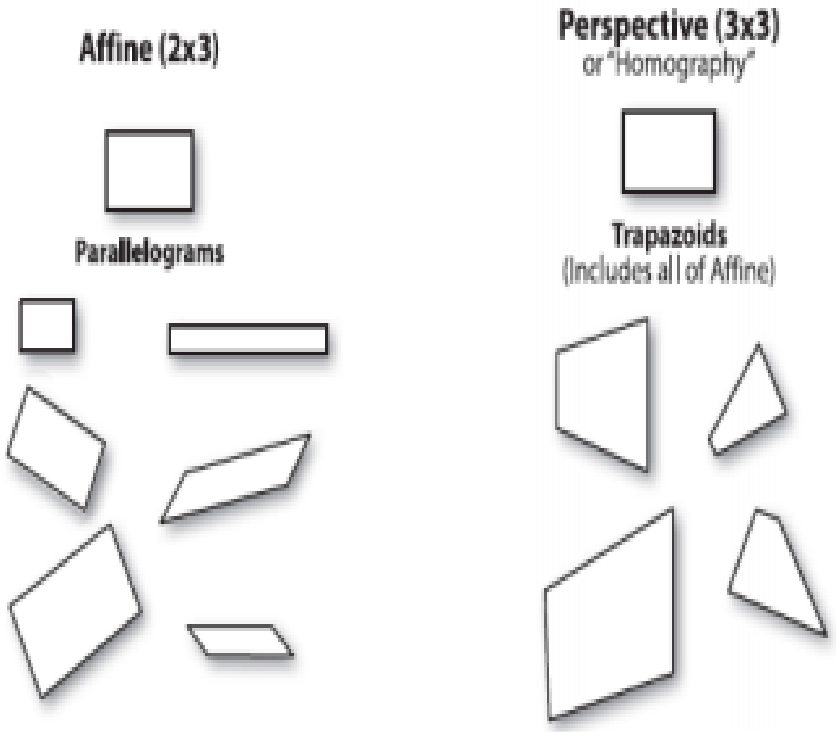

a)Afin Dönüşüm b)Perspektif Dönüşüm

Şekil 3.1: Afin dönüşüm ve perpektif dönüşüm (Bradski ve Kaehler, 2008).

3.1.1. Afin (Affine) Dönüşümler

Afin dönüşümde, 2x3 boyutunda bir haritalama matrisi temel alınarak bir dikdörtgen bir paralelkenara dönüştürülür. Afin dönüşümde x ve y koordinat sisteminde parametre olarak eğme ve döndürme matrisleri kullanılmaktadır. Burada kullanılan parametrelerin çözümü için koordinatları bilinen 3 ortak noktaya ihtiyaç vardır. Örneğin; bir ABCD paralelkenarı afin dönüşüm sonucu bir A'B'C'D' paralelkenarına dönüştürülebilir. Afin dönüşümler sonucu oluşan görüntülerin şeklinin değiştiği fakat kenarlarının paralel kaldığı görülmektedir (Şekil 3.1.a). Afin dönüşümler ile öteleme, döndürme, ölçekleme ve kesme işlemleri gerçekleştirilebilir.

3.1.1.1. Öteleme işlemi

Öteleme işlemi, x ve y koordinat sisteminde yer alan bir görüntünün istenilen piksel miktarı kadar yatay veya düşey eksende kaydırılması işlemidir (Şekil 3.2). Öteleme işleminde şeklin biçimi, yönü ve boyutu değişmezken sadece konumu değişir. Öteleme işlemi sonucunda yatay veya düşey eksende taşmalar meydana gelebilir. Bu gibi durumları önlemek amacıyla çeşitli yöntemler önerilmiştir. Örneğin; taşan pikseller işleme alınmayabilir, görüntünün boyutu öteleme işlemiyle orantılı olarak artırılabilir veya taşan her piksel (0,0) koordinat noktasından taşma miktarı kadar ileri veya geri bir konuma yerleştirilebilir. Bu yöntemlerden en kullanışlı olanı son yöntemdir. Bu tez kapsamında x ve y koordinatlarından istenilen piksel miktarına göre gerçekleştirilen öteleme problemi testlerinde taşma sorununa karşın bir matematiksel formül uygulanmıştır. Böylece öteleme işlemi belirli bir alanda gerçekleştirilmiştir.

Şekil 3.2: Öteleme işlemi (Wikipedia, 2017).

3.1.1.2. Döndürme işlemi

Döndürme işlemi, x ve y koordinat sisteminde yer alan bir görüntünün istenilen koordinat ekseninde döndürülmesidir (Şekil 3.3). Döndürme işlemi, saat yönünün tersi yönünde bir açıyla x ve y ekseni yönünde yapılabileceği gibi orijin etrafında da gerçekleştirilebilir.

Şekil 3.3: 1 Döndürme işlemi (Wikipedia, 2017).

3.1.1.3. Ölçekleme işlemi

Ölçekleme işlemi, x ve y koordinat sisteminde yer alan bir görüntünün boyutunun istenilen derecede değiştirilmesidir. Her iki koordinat ekseninde aynı veya farklı derecede ölçekleme işlemi yapılabilir. Şekil 3.4'te orijinal boyutu 385x385 olan bir görüntünün 100x150 boyutuna ölçekleme işlemi sonrasındaki hali gösterilmiştir.

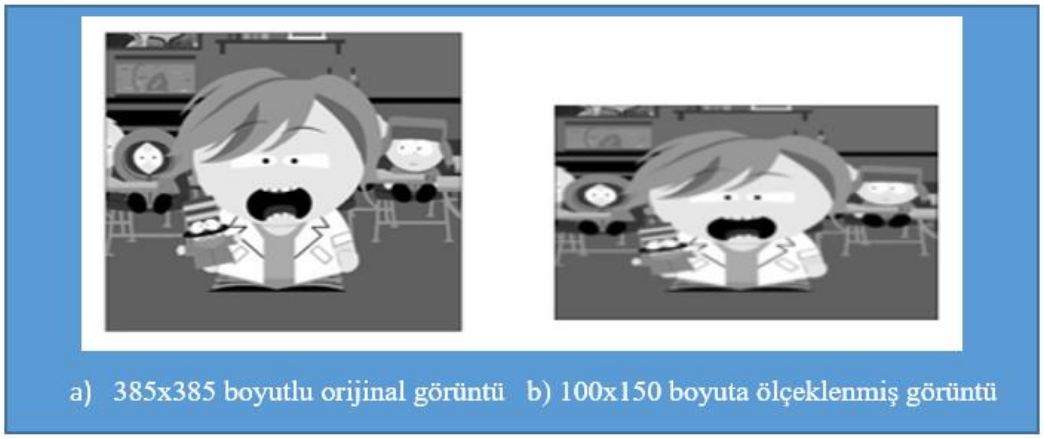

Şekil 3.4: Ölçekleme işlemi (Wikipedia, 2017).

3.1.1.4. Kesme işlemi

Kesme işlemi, x ve y koordinat sisteminde yer alan bir görüntünün yatay ve düşey eksenden istenilen piksel miktarına ve pencere boyutuna denk gelen bölgenin kırpılmasıdır. Şekil 3.5'te orijinal görüntünün istenilen koordinat değerlerine ve istenilen pencere boyutuna göre kesme işlemi gösterilmiştir.

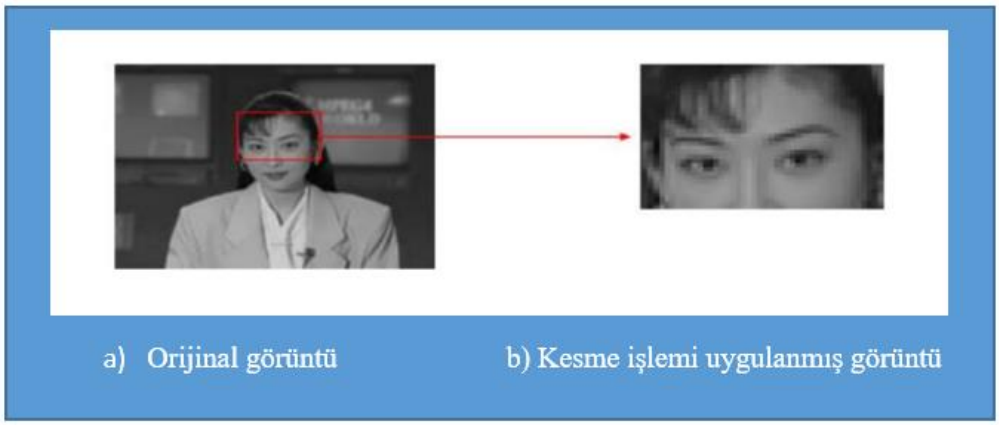

Şekil 3.5: Kesme işlemi (Wikipedia, 2017).

3.1.2. Perspektif Dönüşümler

Perspektif dönüşümde, 3x3 boyutunda bir haritalama matrisi temel alınarak bir dikdörtgen eşkenar dörtgene ya da yamuğa dönüştürülebilir (Şekil 3.1.b). Bu dönüşümde x ve y koordinat sisteminde parametre olarak sadece eğme matrisi kullanılır. Döndürme matrisi kullanılmadığından dolayı elde edilen görüntü bir döndürülmüş görüntü değil eşkenar dörtgene çevrilmiş görüntüdür. Afin dönüşümden farklı olarak kullanılan parametrelerin çözümü için 3 ortak nokta yerine 4 ortak noktaya ihtiyaç duyulur.

3.2. HİSTOGRAM EŞİTLEME

Histogram, bir görüntünün içerdiği piksel değerlerinin ağırlığını temsil eden grafiksel bir gösterimdir. Bir görüntünün histogram grafiği temsil ettiği görüntünün parlaklık değerleri veya renk tonları hakkında bilgi verir. 8-bit parlaklık değerlerine sahip bir görüntünün histogram grafiği 0-255 arası gri-seviye piksel değerleri ile temsil edilir. Koordinat sisteminde x ekseni görüntünün parlaklık değer aralığını, y ekseni ise görüntünün içerdiği piksel değerlerinin ağırlığını temsil eder.

Histogram eşitleme yöntemi, herhangi bir görüntüdeki renk değerlerinin belirli bir alanda kümelenmesinden kaynaklanan renk bozukluklarını gidermek amacıyla kullanılır. Histogram eşitleme sonrasında 8-bit parlaklığa sahip gri-seviyeli bir görüntünün histogram grafiği 0-255 renk tonları arasında homojen olarak dağılır. Şekil 3.6'da 8-bit parlaklık değerleri ile temsil edilen gri-seviyeli bir görüntünün orijinal histogram grafiği ve histogram eşitleme sonrası oluşturulan histogram grafiği gösterilmektedir.

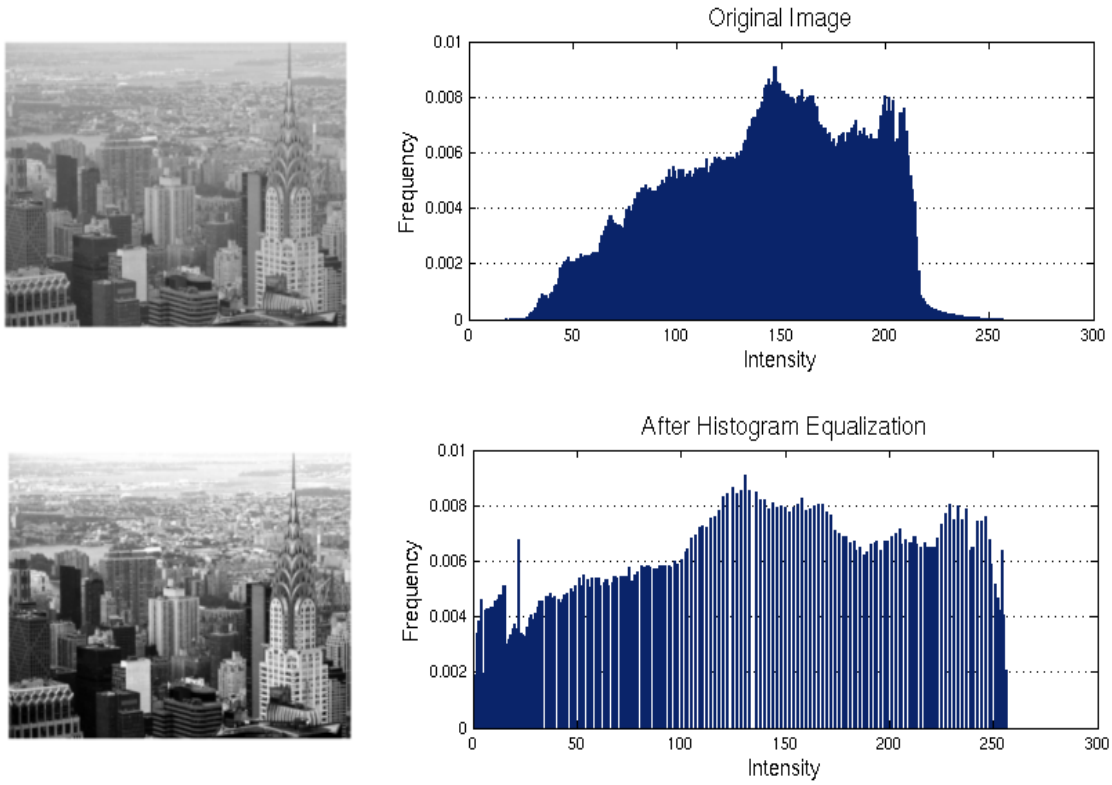

Şekil 3.6: Histogram eşitleme (Wikipedia, 2017).

3.3. TALAMİK KATMAN FİLTRESİ (DIFFERENCE OF GAUSSIANS: MEXICAN HAT)

Talamik katman filtresi (gaussların farkı ya da Meksikalı şapka), orijinal görüntünün daha az bulanık olan bir versiyonundan orijinal gri-tonlamalı görüntünün bulanık halinin çıkartılmasını içeren bir gri-tonlamalı görüntü geliştirme algoritmasıdır. Bulanık görüntüler, orijinal gri tonlamalı görüntünün farklı standart sapmalara sahip Gauss çekirdeği ile konvolüsyon işlemi sonucunda elde edilir. Gauss çekirdeği kullanılarak bir görüntü bulanıklaştırıldığında sadece yüksek frekanslı bilgiler bastırılır. Orijinal

görüntünün daha az bulanık olan bir versiyonundan orijinal gri-tonlamalı görüntünün bulanık halinin çıkartılması sonucunda iki görüntü arasında korunan frekans aralığındaki uzamsal bilgi korunur. Gözün retinasında bulunan sinirsel işlem gelen bilgileri beyne iletmek için aktarılan görüntülerden detayları nasıl çıkartıyorsa Gaussların farkı algoritması da aynı mantıkta tasarlanmıştır. Şekil 3.7'de farklı standart sapmalara sahip iki Gauss eğrisinin çizimi ve bu eğrilerin Gauss farkı gösterilmiştir (Wikipedia, 2017).

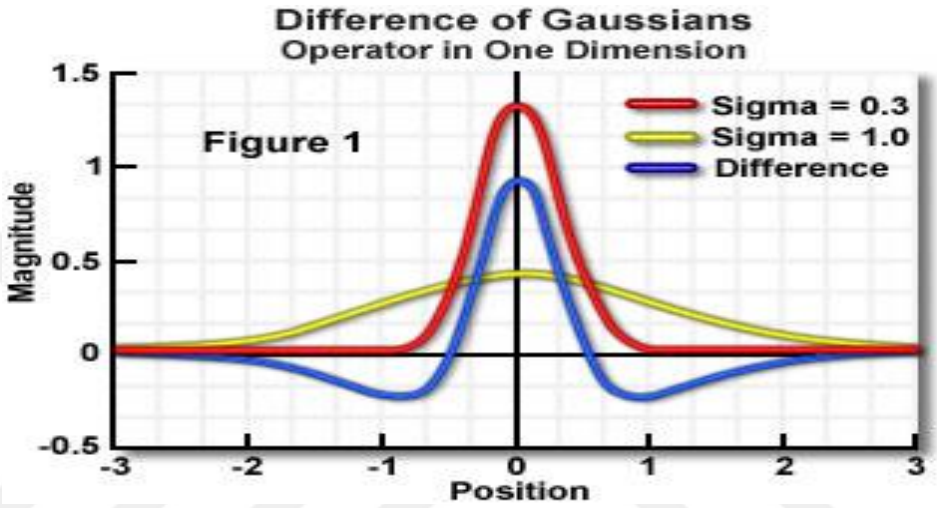

Şekil 3.7: Gaussların farkı: Meksikalı şapka dalgacık.

Gaussların farkı algoritması ikili bir görüntüde bulunan kenarları belirginleştirmede veya görüntüye ait diğer ayrıntıların ön plana çıkartılmasında kullanılabilir. Talamik katman filtresi adıyla da bilinen bu filtrenin çıktısı Şekil 3.8'de gösterilmiştir.

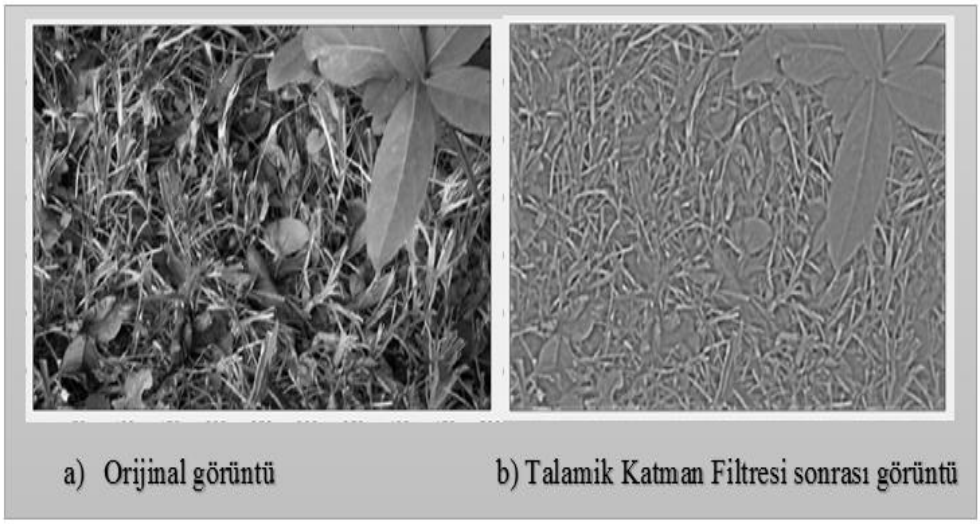

Şekil 3.8: Orijinal görüntü (a), talamik katman çıktısı (b).

Talamik katman filtresi bir görüntüde belirli bir alana bakarak o alanın aydınlık-karanlık yoğunluğuna göre bir çıktısını üretir. Yani, görüntü içerisinde karşıtlık farkı oluşan bölgeler tespit edildikten sonra yüksek geçirgenli bir filtreden geçirilir. Görüntü hakkında bilgi içermeyen bölgeler bu filtre yardımıyla göz ardı edilir. Talamik katman filtresi çıktısına bakarak görüntü hakkında siyahtan-beyaza veya beyazdan-siyaha renk geçişlerini de tespit etmek mümkündür.

4. BULGULAR

4.1. ÖTELEME SINIFLANDIRMA PROBLEMİ TESTİ

Tez kapsamında analizi yapılan ilk performans testi, YARD veri kümesinde bulunan 5 imgenin belli bir boyut ve farklı pozisyonlardaki desenlerinin sınıflandırma başarısını ölçmek amacıyla yapılmıştır. Bu test, ikili sınıflandırma problemi olarak tasarlanmıştır. Ayrıca bu test sayesinde verilen bir imge parçasının x-y koordinat sisteminde hangi yöne ötelendiğinin sınıflandırılabilir olup olmadığı da gözlemlenebilmektedir. Veri kümesinde bulunan her bir imge sınıfından orijinal *p1* pozisyonundan 15x15 boyutlarında toplam 4000 makrokolon pencere seçilmiştir (Şekil 4.1).

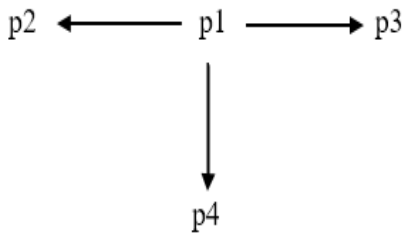

Şekil 4.1: İmge pencerelerinin öteleme sınıflandırma testi için yerleşimleri.

Seçilen makrokolon pencereler, belirlenen 1-15 piksel değer aralıklarında *p2* ve *p3* yönünde x ekseni boyunca ötelenenler 1, *p4* yönünde 15 piksel y ekseni boyunca ötelenenler -1 olarak etiketlenmiştir. Eğitim ve test kümesinde eşit sayıda 1 ve -1 etiketine sahip 2000'er örnek bulunmaktadır. Sınıflandırma performansları, orijinal piksel, Gabor dalgacık dönüşümü (GWT) ve Yerel ikili desen özniteliklerinin DVM sınıflandırıcısındaki rbf ve lineer çekirdek fonksiyonunun başarısına göre değerlendirilmiştir (Şekil 4.2 ve Şekil 4.3). GWT yönteminde; 3-ölçekli 4-yönelimli Gabor filtresi kullanılarak toplam (3x4x15x15)/4x4=168 tane öznitelik, LBP yönteminde; 8 komşu ve 1 yarıçap değeri kullanılarak toplam 59 öznitelik ve piksel yönteminde; toplam 225 öznitelik kullanılmıştır.

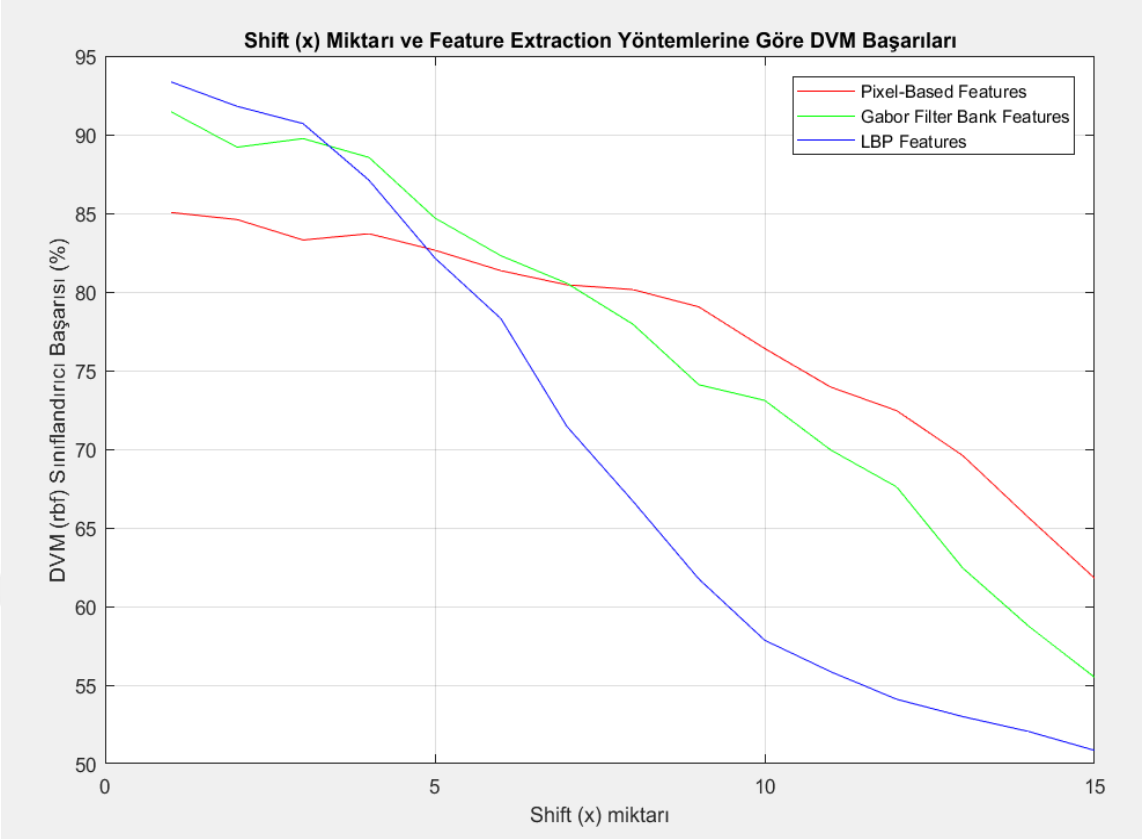

Şekil 4.2: Öteleme sınıflandırma problemi testi DVM (rbf) performansları.

Yukarıda verilen DVM sınıflandırıcının rbf çekirdek fonksiyonundaki başarı sonuçları değerlendirildiğinde x ekseninde piksel öteleme miktarı 3 pikseli geçtiğinde kullanılan 3 özellik yönteminde de başarılar giderek düşmektedir. DVM sınıflandırıcı en yüksek başarısını x ekseni yönünde piksel öteleme miktarı 1 olduğunda vermektedir (Şekil 4.2). Öznitelik çıkarım yöntemlerinden LBP yaklaşık %94, Gabor dalgacık dönüşümü yaklaşık %92 ve orijinal pikseller %85 başarı göstermektedir.

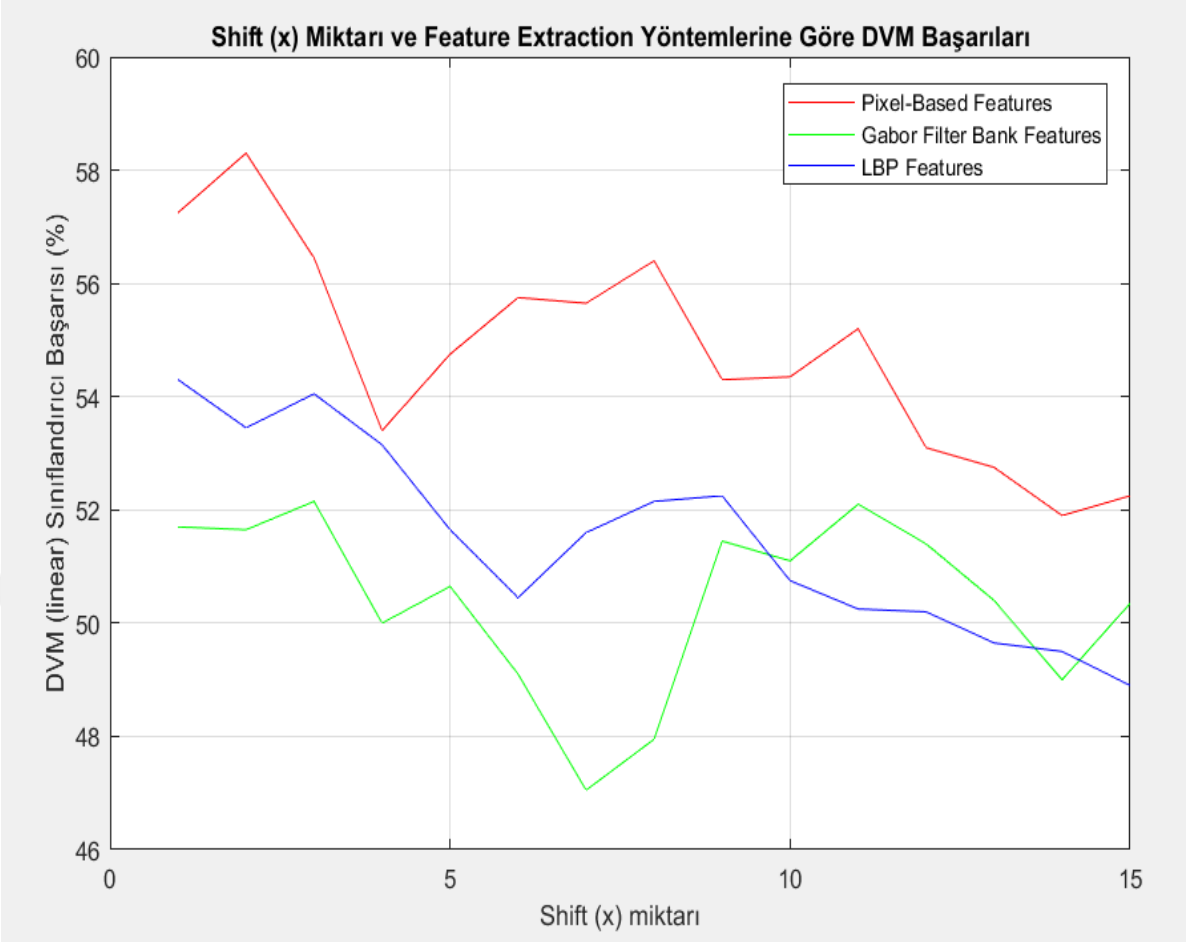

Şekil 4.3: Öteleme sınıflandırma problemi testi DVM (lineer) performansları.

Yukarıda verilen DVM sınıflandırıcının lineer çekirdek fonksiyonundaki başarı sonuçları x eksenine göre piksel öteleme miktarı 1-15 arasında düzgün dağılıma sahip olmayan bir grafik çizmektedir (Şekil 4.3). Öteleme miktarı 1-3 piksel arasında DVM sınıflandırıcının en yüksek başarısı görülmektedir. Özellik çıkarım yöntemlerinden LBP yaklaşık %55, Gabor dalgacık dönüşümü yaklaşık %53 ve orijinal pikseller %59 başarı göstermektedir. Elde edilen sonuçlara göre öteleme miktarının sınıflandırmaya yönelik etkisini incelediğimizde 1 piksel ötelenme miktarı *p1* ve *p2* yönündeki pencerelerin genelde aynı sınıf olarak düşünebildiğine, ama piksel miktarının değişmesine bağlı olarak bu pencerelerin arasındaki benzerliklerinin kalkmasıyla birlikte DVM sınıflandırıcısının rbf ve lineer çekirdek fonksiyonlarında sınıflandırma başarısının giderek düştüğü görülmektedir (Şekil 4.2 ve Şekil 4.3).

4.2. EĞİTİM ÖRNEK SAYISININ SINIFLANDIRMA PROBLEMİ ÜZERİNDEKİ ETKİSİNİN ÖLÇÜMÜ TESTİ

DVM sınıflandırıcısının eğitiminde kullanılacak örnek sayısının ve özellik çıkarım metotlarından LBP, Katman-3 ve her iki yöntemin birleşimi sonucunda elde edilen özniteliklerin sınıflandırma başarısına etkisi incelenmiştir. Tez kapsamında geliştirilen problemlerde YARD veri kümesine ait 5 imgeden rastgele 64x64 boyutunda makrokolon pencereler seçilerek farklı sayıda eğitim ve test kümesi oluşturulmuştur (Tablo 4.1).

Eğitim ve test kümeleri oluşturulduktan sonra LBP ile Katman-3 özniteliklerinin farklı sayıda örneği içeren veri kümeleri üzerindeki başarıları karşılaştırılmıştır. Her bir makrokolon pencere Talamik katman filtresinden geçirildikten sonra Katman-3 öznitelikleri oluşturulduğundan dolayı, LBP özellik çıkarım metodundan önce de her bir makrokolon pencere Talamik katman filtresinden geçirilmiştir. LBP yönteminde; 8 komşu ve 1 yarıçap değeri kullanılarak toplam 59 öznitelik, Katman-3 yönteminde; 64x64x5=20.480 öznitelik ve Katman-3+LBP yönteminde; 59x5=295 öznitelik kullanılmıştır. Her bir test için DVM sınıflandırıcısının rbf ve lineer çekirdek fonksiyonlarının başarım oranları 100 kez tekrarlanarak ortalama bir değere eşitlenmiştir. Burada test sonuçlarını değerlendirirken DVM sınıflandırıcının ortalama doğruluk başarı oranları dikkate alınmıştır.

Tablo 4.1: Farklı sayıda eğitim ve test kümelerinin oluşturulması.

Test No	Eğitim veri kümesinde bulunan örnek sayısı	Test veri kümesinde bulunan örnek sayısı
Test 1	25	500
Test 2	100	500
Test 3	150	500
Test 4	300	500
Test 5	500	500

Yukarıdaki beş durumun her bir özellik çıkarım metoduna göre elde edilen başarım sonuçları aşağıda verilmiştir.

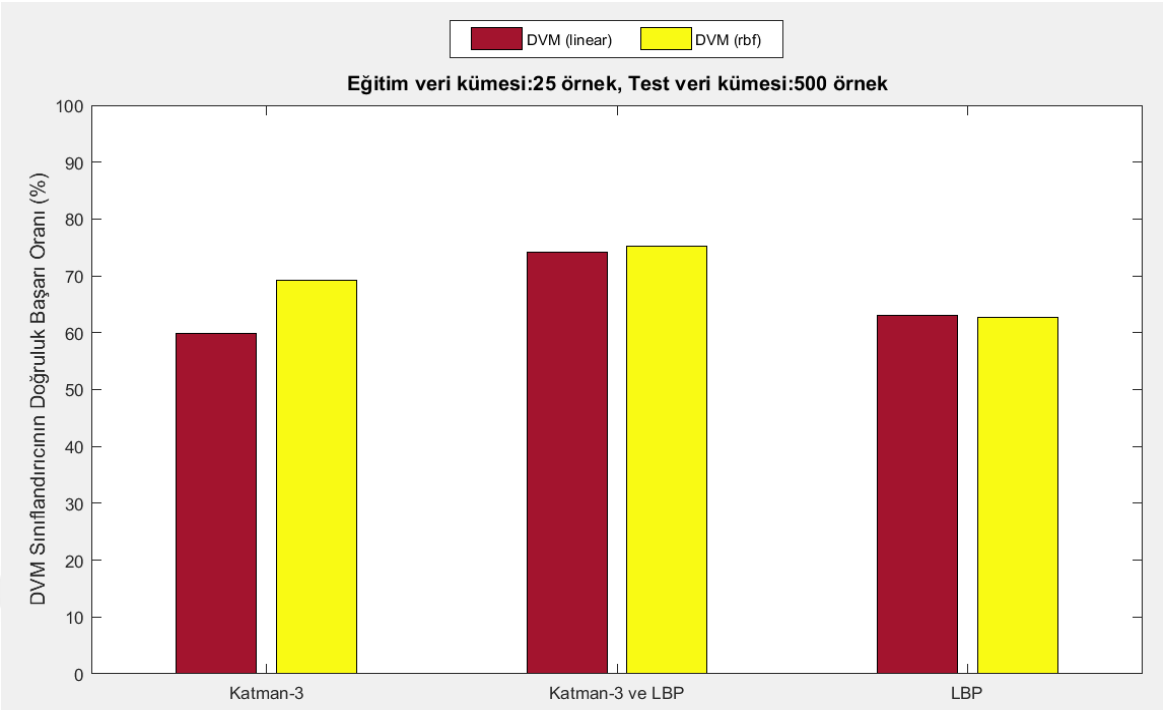

Şekil 4.4: Test 1 sınıflandırma problemi testi DVM performansları.

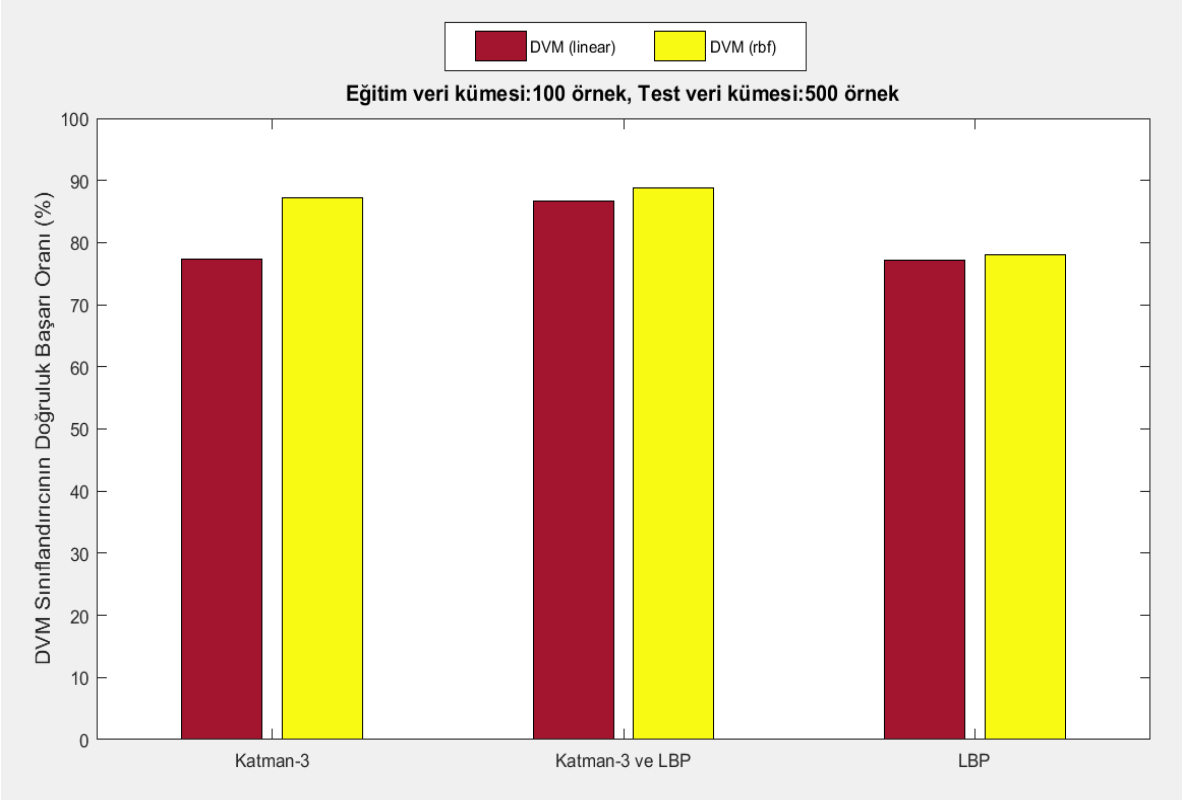

Şekil 4.5: Test 2 sınıflandırma problemi testi DVM performansları.

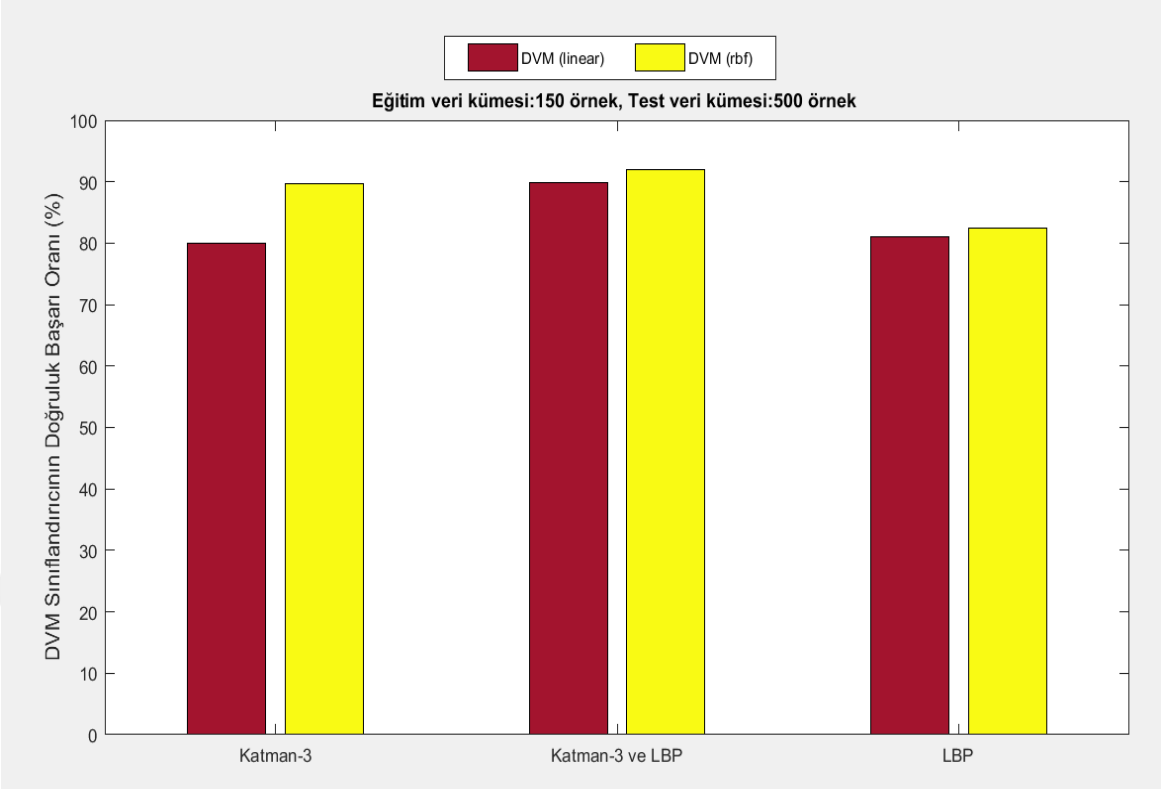

Şekil 4.6: Test 3 sınıflandırma problemi testi DVM performansları.

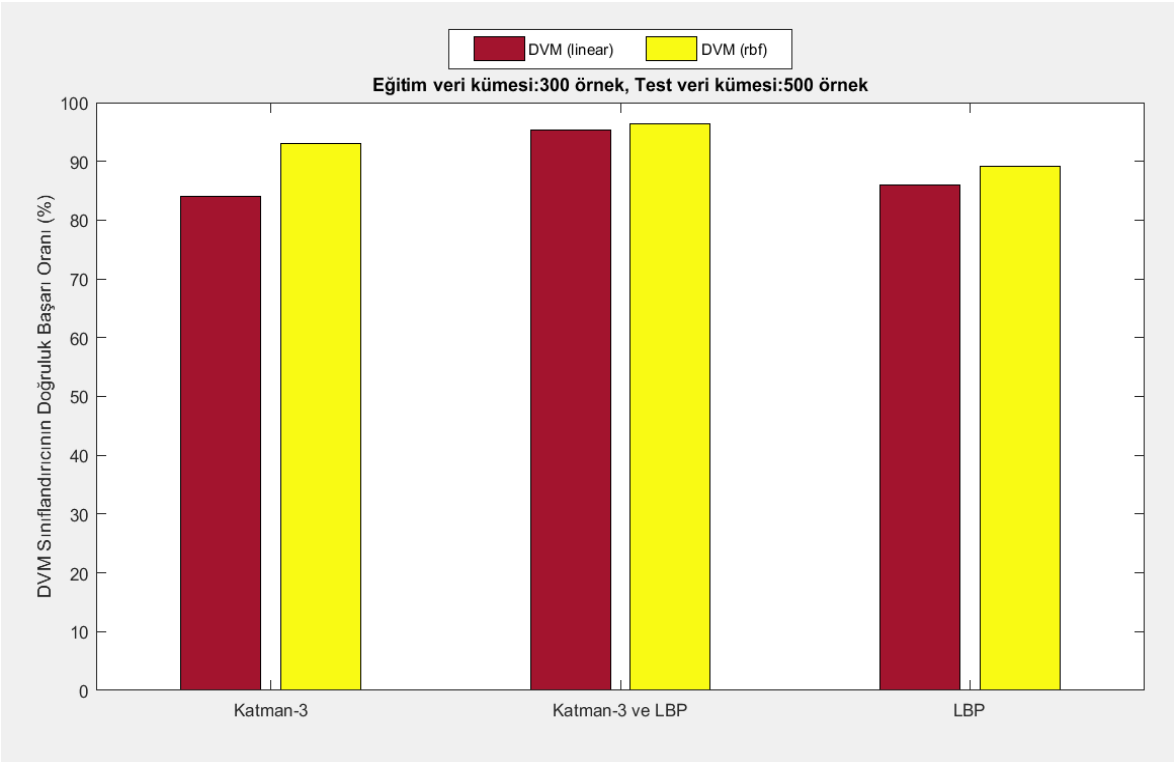

Şekil 4.7: Test 4 sınıflandırma problemi testi DVM performansları.

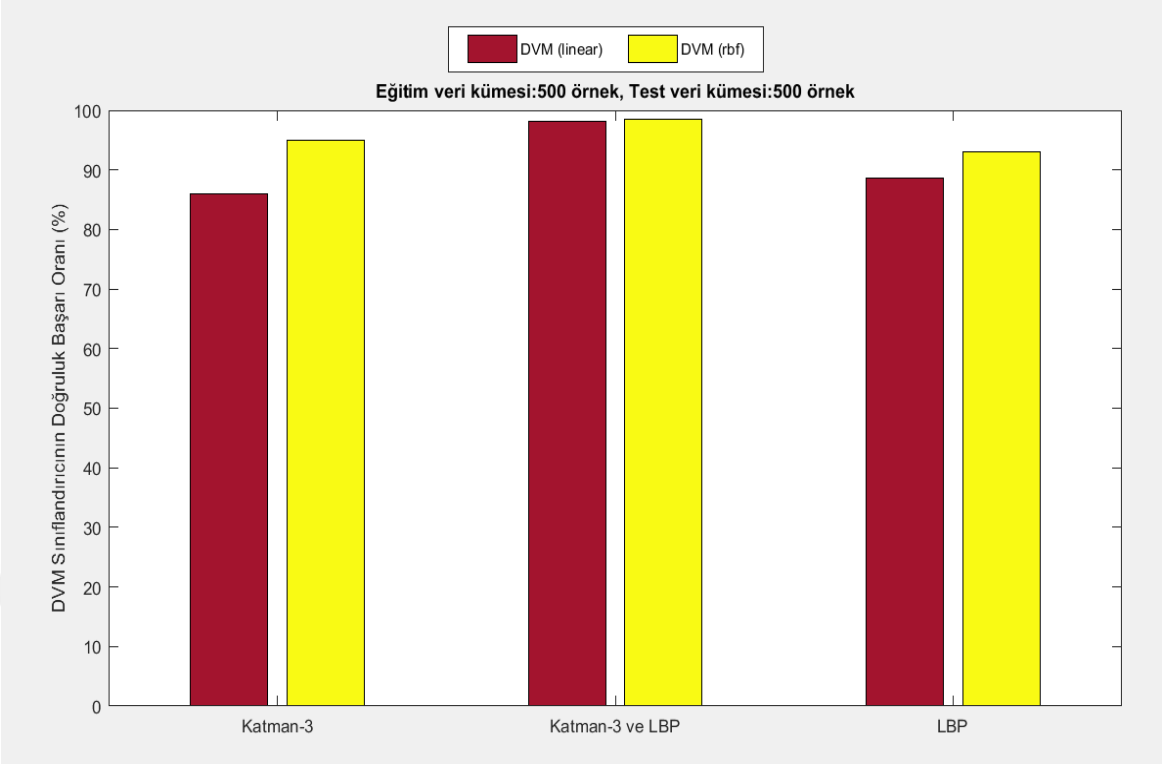

Şekil 4.8: Test 5 sınıflandırma problemi testi DVM performansları.

Yukarıda elde edilen sonuçlar incelendiğinde, test genelinde başarım oranlarının eğitim örneği sayısı ile ilişkili olduğu tespit edilmiştir. Eğitim örnek sayısı artıkça Katman-3, LBP ve Katman-3+LBP öznitelikleri sonucunda DVM sınıflandırıcının rbf ve lineer çekirdek fonksiyonlarındaki başarım oranlarında artış olmuştur. YARD veri kümesindeki her bir imgeden 100'er makrokolon pencere seçilerek eğitim ve test kümesinde toplam 500 örnek kullanıldığında (Şekil 4.8) DVM sınıflandırıcısının lineer çekirdek fonksiyonunda ortalama başarım oranları Katman-3 için **%86.03**, LBP için **%88.60** ve Katman-3+LBP için **%98.06** olmaktadır. DVM sınıflandırıcısının rbf çekirdek fonksiyonunda ortalama başarım oranlarında ise Katman-3 için **%94.92**, LBP için **%93.06** ve Katman-3+LBP için **%98.49** olmaktadır. Diğer eğitim örnek sayılarının sınıflandırma başarımları üzerindeki etkisine göre sınıflandırıcı ortalama başarım oranları Tablo 4.2'de verilmiştir.

Tablo 4.2: Eğitim örnek sayısının sınıflandırma problemi üzerindeki etkisinin ölçümü testi DVM sınıflandırıcı ortalama başarım oranları.

Sınıflandırıcı	DVM (lineer) Ortalama Başarımları (%)			DVM (rbf) Ortalama Başarımları (%)		
Özellik / Test No	LBP	Katman-3	Katman-3 +LBP	LBP	Katman-3	Katman-3 +LBP
Test 1	*63.10*	*59.82*	*74.11*	*62.70*	*69.26*	*75.21*
Test 2	*77.21*	*77.28*	*86.70*	*78.03*	*87.18*	*88.86*
Test 3	*81.09*	*80.01*	*89.80*	*82.49*	*89.72*	*92.03*
Test 4	*86.00*	*84.06*	*95.37*	*89.12*	*93.00*	*96.40*
Test 5	*88.60*	*86.03*	*98.06*	*93.06*	*94.92*	*98.49*

Genel başarım dağılımları incelendiğinde, Katman-3 öznitelikleri ile LBP öznitelikleri beraber kullanıldığında DVM sınıflandırıcının daha iyi performans gösterdiği belirlenmiştir. Katman-3 özniteliklerinin DVM sınıflandırıcısının rbf çekirdek fonksiyondaki başarım oranı, lineer çekirdek fonksiyonundaki başarım oranına göre yaklaşık %8-10 daha iyi performans göstermektedir. DVM sınıflandırıcısının farklı çekirdek fonksiyonlarında görülen bu başarım farkının, Katman-3 ve LBP özelliklerinin beraber kullanılmasıyla birlikte ortadan kalktığı görülmektedir. Katman-3 yöntemi ile LBP yöntemi kıyaslandığında, eğitim örnek sayısının test örnek sayısına göre çok daha az olduğu durumda (Test 1) bile DVM sınıflandırıcısının rbf çekirdek fonksiyonunda Katman-3'ün çok daha iyi performans gösterdiği tespit edilmiştir. Böylece, az sayıda eğitim örneği kullanıldığı durumlarda Katman-3'ün LBP yöntemine göre daha avantajlı olduğu görülmektedir. Eğitim örnek sayısı artıkça her bir özellik çıkarım metodunun DVM sınıflandırıcındaki başarım oranında artış görülmektedir. Eğitim ve test kümelerinde eşit sayıda örnek makrokolon pencereler kullanıldığında Katman-3+LBP özniteliklerinin DVM'nin rbf çekirdek fonksiyonundaki başarım oranı yaklaşık **%98.5** seviyelerine çıkmaktadır.

4.3. ÖZELLİK ÇIKARIM YÖNTEMLERİNİN PERFORMANSLARININ KARŞILAŞTIRILMASI TESTİ

Özellik çıkarım yöntemlerinin performanslarının karşılaştırılması testinde, desen sınıflandırılması problemlerinde literatürde sıklıkla kullanılan Gabor dalgacık dönüşümü (GWT), Yerel ikili desen (LBP) ve piksel öznitelikleri ile tez kapsamında geliştirilen Katman-3 öznitelikleri karşılaştırılmıştır. Bu test ile, daha önce doğal görüntüler (YARD veri kümesi) üzerinde eğitilmiş olan Katman-3'ün, Brodatz desen veri kümesi üzerindeki performansının araştırılması amaçlanmıştır. Tez kapsamında geliştirilen problemlerde Brodatz desen veri kümesinde yer alan 13 farklı sınıfın her birinden 100'er adet rastgele 32x32 boyutundaki makrokolon pencereler seçilerek 1300'er imge parçasından oluşan eğitim ve test kümeleri oluşturulmuştur.

Eğitim ve test kümeleri oluşturulduktan sonra, ilk inceleme olarak her bir makrokolon pencerenin orijinal ve histogram eşitlendikten sonraki halinden elde edilen Gabor, LBP ve piksel özniteliklerinin DVM sınıflandırıcısındaki lineer ve rbf çekirdek fonksiyonları için performansları karşılaştırılmıştır. İkinci incelemede ise, her bir makrokolon pencere Talamik katman filtresinden geçirildikten sonra, ilk incelemede en iyi performansı gösteren öznitelik çıkarım yöntemi ile Katman-3 yöntemi özniteliklerinin DVM sınıflandırıcısındaki lineer ve rbf çekirdek fonksiyonları için performansları karşılaştırılmıştır. GWT yönteminde; 5-ölçekli 8-yönelimli Gabor filtresi kullanılarak toplam (5x8x32x32)/4x4=2560 tane öznitelik, LBP yönteminde; 8 komşu ve 1 yarıçap değeri kullanılarak toplam 59 öznitelik, piksel yönteminde; toplam 1024 öznitelik, Katman-3 yönteminde; 32x32x5=5120 öznitelik ve Katman-3+LBP yönteminde ise 59x5=295 öznitelik kullanılmıştır. Her bir incelemede DVM sınıflandırıcısının başarım oranları 10 kez tekrarlanarak ortalama bir değere eşitlenmiştir ve test sonuçları değerlendirirken DVM sınıflandırıcının ortalama doğruluk başarı oranı dikkate alınmıştır.

Yukarıda bahsedilen incelemelerin her bir özellik çıkarım metoduna göre elde edilen başarım grafikleri aşağıda verilmiştir.

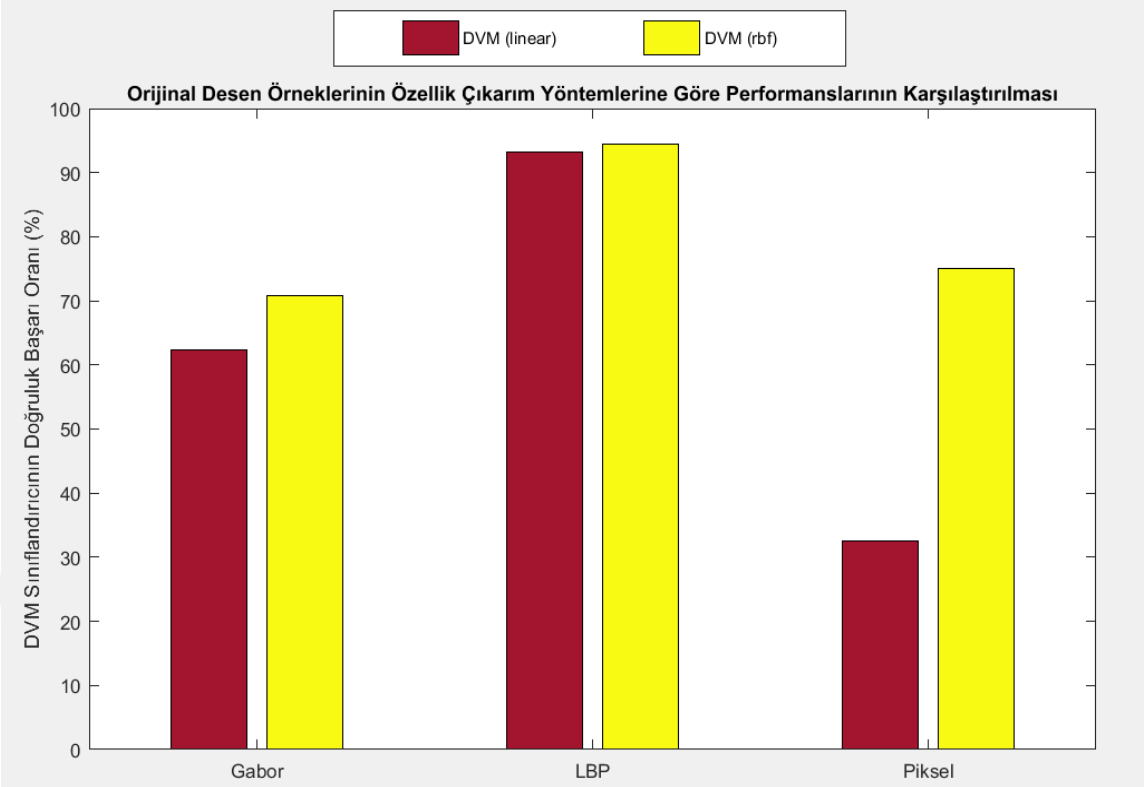

Şekil 4.9: Orijinal desen imgelerinde özellik çıkarım yöntemlerinin performanslarının karşılaştırılması.

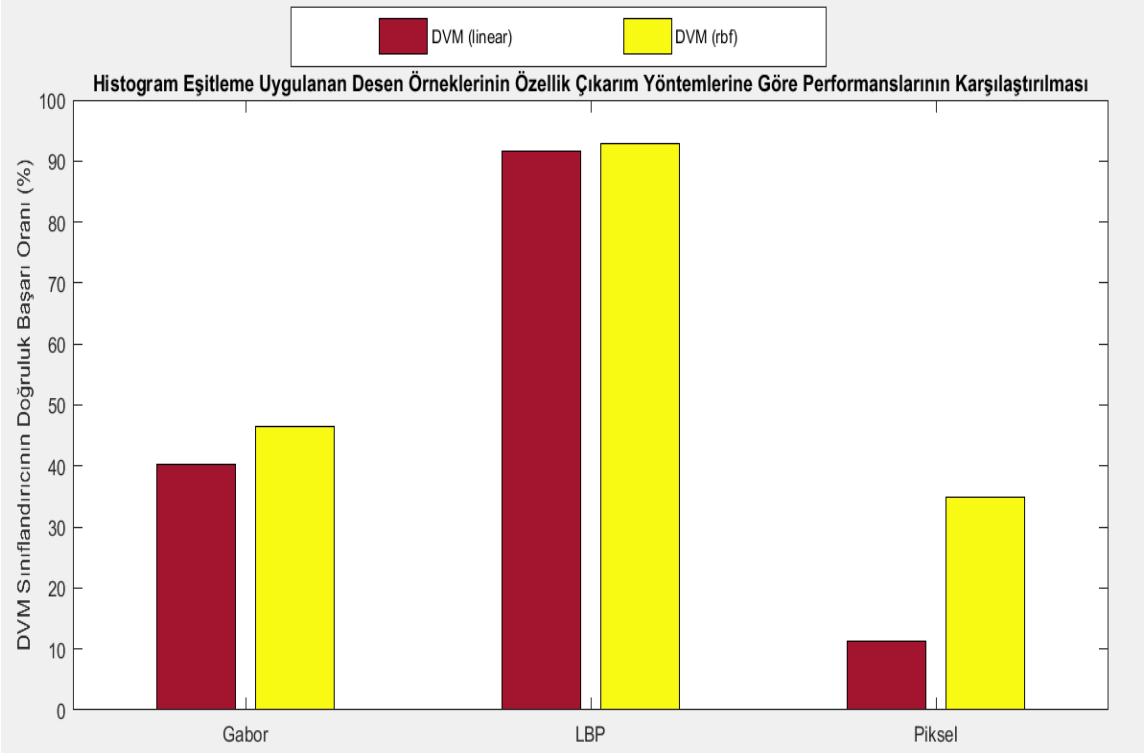

Şekil 4.10: Histogram eşitleme uygulanan desen imgelerinde özellik çıkarım yöntemlerinin performanslarının karşılaştırılması.

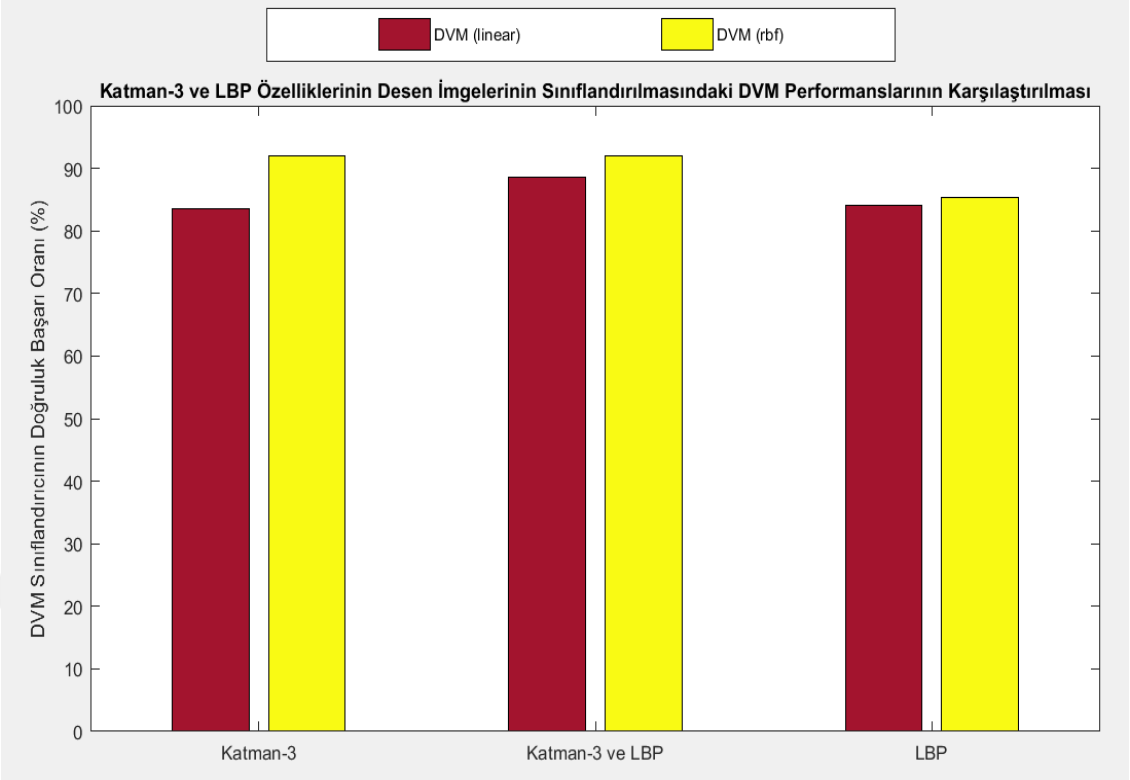

Şekil 4.11: Talamik katman filtresi uygulanan desen imgelerinde Katman-3 ve LBP yöntemlerinin performanslarının karşılaştırılması.

Yukarıda elde edilen sonuçlar incelendiğinde desenlerin sınıflandırılması çalışmasında makrokolon pencere piksellerinin doğrudan öznitelik olarak kullanılmasının aksine özellik çıkarım yöntemleri sonucunda elde edilen yeni özelliklerin öznitelik olarak kullanılmasının DVM performansı açısından daha avantajlı olduğu sonucu tespit edilmiştir. Her 3 inceleme için elde edilen DVM sınıflandırıcısının rbf ve lineer çekirdek fonksiyonlarındaki ortalama başarım oranları Tablo 4.3'de ayrıntılı olarak verilmiştir.

Tablo 4.3: Özellik çıkarım yöntemlerinin performanslarının karşılaştırılması testi DVM sınıflandırıcı ortalama başarım oranları.

Filtre	Yok			Histogram Eşitleme			Talamik katman filtresi		
Özellik / Sınıflandırıcı	Piksel	Gabor	LBP	Piksel	Gabor	LBP	Katman-3	LBP	Katman-3 +LBP
DVM (linear) Ortalama Başarımları (%)	*32.47*	*62.26*	*93.26*	*11.23*	*40.24*	*91.71*	*83.55*	*84.03*	*88.50*
DVM (rbf) Ortalama Başarımları (%)	*75.10*	*70.86*	*94.48*	*34.87*	*46.57*	*92.95*	*91.91*	*85.32*	*89.95*

Genel başarım sonuçlarına bakıldığında, ilk incelemede DVM'nin lineer çekirdek fonksiyonundaki başarımlar piksellerde ***%32.47***, Gabor dalgacık dönüşümünde ***%62.26*** ve LBP operatöründe ***%93.26*** iken, rbf çekirdek fonksiyonundaki başarımlar sırasıyla ***%75.10***, ***%70.86*** ve ***%94.48***'dır. Özellik çıkarım yöntemlerinden Gabor dalgacık dönüşümü doğrusal bir dönüşüm olduğundan dolayı piksel özniteliklerinin DVM performans sonuçları ile arasında çok bir fark görülmemektedir. Histogram eşitleme sonrası DVM'nin lineer çekirdek fonksiyonundaki performans sonuçlarına baktığımızda, piksellerde ***%11.23***, Gabor dalgacık dönüşümünde ***%40.24*** ve LBP operatöründe ***%91.71*** iken, rbf çekirdek fonksiyonundaki başarımlar sırasıyla ***%34.87***, ***%46.57*** ve ***%92.95***'dir. Brodatz desen veri kümesi içerisinden seçilen makrokolon pencerelere histogram eşitleme uygulandıktan sonra piksel ve Gabor yönteminin başarım sonuçlarında düşme görülürken, LBP yönteminin başarım sonucunda ise çok bir değişim görülmemektedir. Çünkü; LBP'nin hesaplanmasında yer alan g_c ve g_p ortalama piksel yoğunluk bilgisi *Denklem 2.5*'te verilen fonksiyon kullanılarak atıldığından LBP operatörü histogram eşitlemeye duyarlı değildir (Liao ve diğ., 2009).

İkinci incelemede ise, Brodatz desen veri kümesindeki her bir makrokolon pencere Talamik katman filtresinden geçirildikten sonra tez kapsamında geliştirilen Katman-3 yöntemi ile LBP operatörü performans sonuçları incelenmiştir. DVM'nin lineer çekirdek fonksiyonundaki başarımlara baktığımızda, LBP'de ***%84.03***, Katman-3'de ***%83.55*** ve Katman-3+LBP'de ***%88.50*** iken, rbf çekirdek fonksiyonundaki başarımlar sırasıyla ***%85.32***, ***%91.91*** ve ***%89.95***'dir. Buradaki bilgiler ışığında, Katman-3 ve LBP operatörünün birlikte kullanılmasıyla DVM performanslarının daha iyi olduğu ve lineer ile rbf çekirdek fonksiyonları arasındaki başarım farkının oradan kalktığı görülmektedir.

4.4. ÇOKLU – ÖLÇEKLİ İMGELERİN SINIFLANDIRMA PROBLEMİ TESTİ

Çoklu-ölçekli imgelerin sınıflandırma problemi testinde, bir pencereye düşen makrokolonun farklı boyutlarda ölçeklendirilmesiyle elde edilen LBP özniteliklerinin DVM sınıflandırıcı performansına ne derece etki edeceğinin tespiti amaçlanmıştır. Bu kapsamda Brodatz veri kümesindeki imgelerden 17x15 boyutunda rastgele seçilen 2600 adet makrokolon pencerelerin yarısı eğitim kümesine kalanı ise test kümesine atanmıştır. LBP yöntemi için 8 komşu ve 1 yarıçap değeri kullanılarak toplam 59 öznitelik elde edilmiştir. Orijinal, ölçeklenmiş ve çoklu-ölçekli imgelerden çıkarılan öznitelikler DVM sınıflandırıcısının lineer ve rbf çekirdek fonksiyonlarına eğitim girdisi olarak verildikten sonra elde edilen öğrenme fonksiyonu ile test veri kümesi üzerinde performansları araştırılmıştır. Tez kapsamında kullanılan imgelerden çoklu-ölçekli LBP özniteliklerin nasıl çıkarıldığı Şekil 4.12'de şematize edilmeye çalışılmıştır.

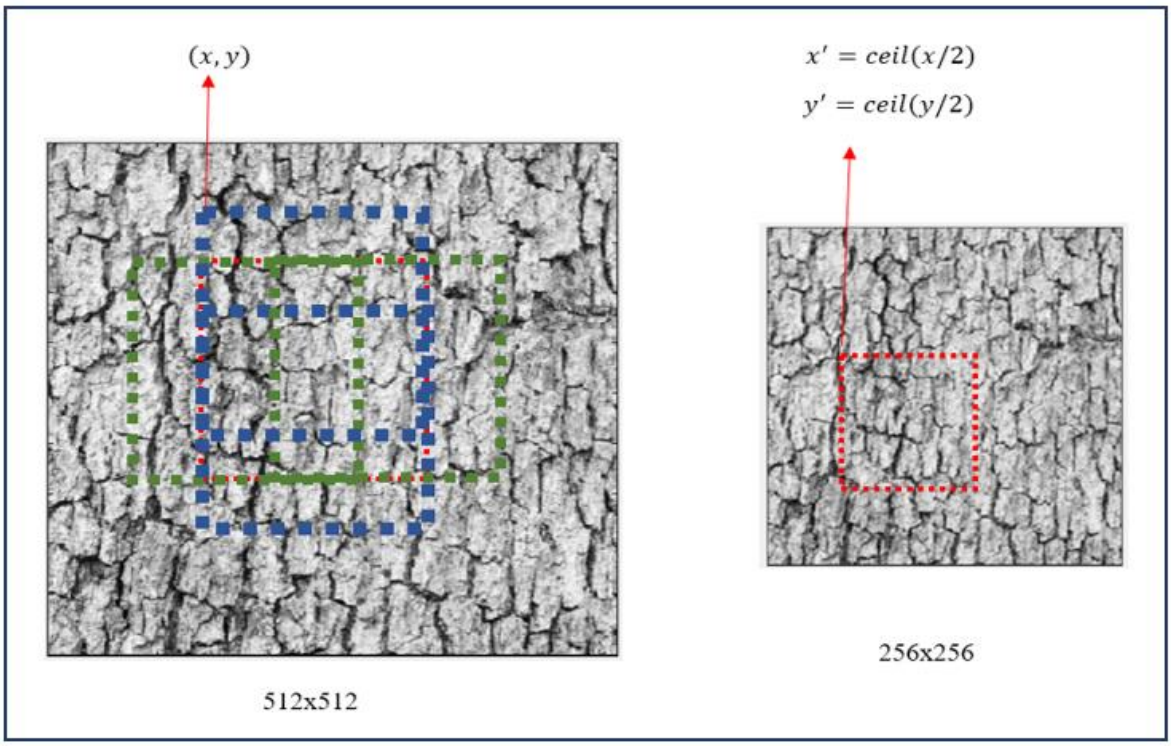

Şekil 4.12: Çoklu-ölçekli imgelerden LBP özniteliklerinin çıkarılması yöntemi.

Yukarıda gösterilen yöntemde, 512x512 boyutundaki orijinal imgede (x, y) noktasına denk gelen 17x15 boyutundaki imge parçası x ve y koordinat düzleminde 1'er kez x boyunca sağa ve sola 8 piksel, y boyunca aşağıya ve yukarıya 7 piksel ötelenerek 4x59=236 adet LBP öznitelikleri elde edilmiştir. Daha sonra aynı imge 256x256 boyutunda ölçeklenerek $(x/2, y/2)$ noktasına denk gelen imge parçasından 59 adet LBP öznitelikleri elde edilmiştir. Böylece, çoklu-ölçekli imgelerin x ve y koordinat sisteminde 1'er kez ötelenmesi sonucunda elde edilen toplam 5x59=295 adet LBP öznitelikleri DVM sınıflandırıcı performanslarının değerlendirilmesinde kullanılmıştır.

2600 adet rastgele seçilmiş desen örneğin normal, ötelenmiş ve çoklu-ölçeklenmesi sonucu elde edilen LBP özniteliklerinin DVM sınıflandırıcısının rbf ve lineer çekirdek fonksiyonlarındaki sınıflandırma başarımları grafiksel olarak aşağıda sırasıyla verilmektedir (Şekil 4.13 ve Şekil 4.14). Ortalama başarı oranı 10 tekrar sonrasında çıkartılmış olup kırmızı eğri orijinal imge parçasının belli bir kaydırma miktarı sonucunda elde edilmiş LBP özniteliklerinin başarımlarını gösterirken, yeşil eğri ise çoklu-ölçekli imge parçasına ait LBP özniteliklerinin başarımlarını göstermektedir.

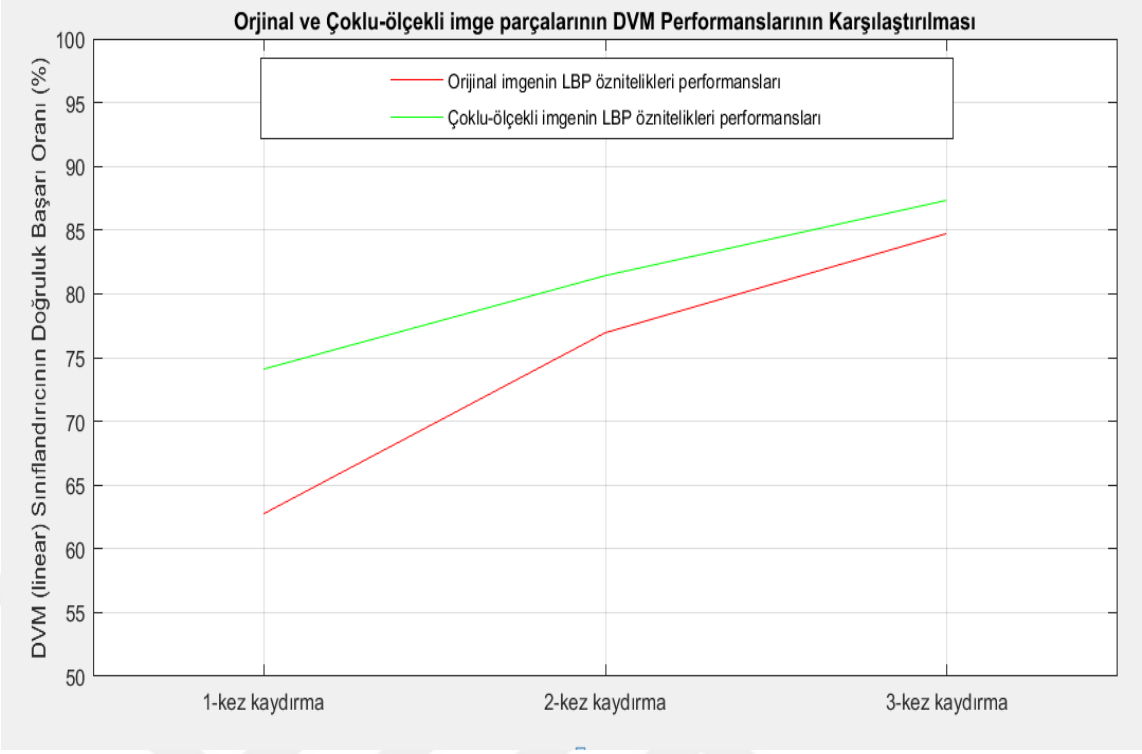

Şekil 4.13: Orijinal ve çoklu-ölçekli imgelerin LBP öznitelikleri DVM (lineer) performansı.

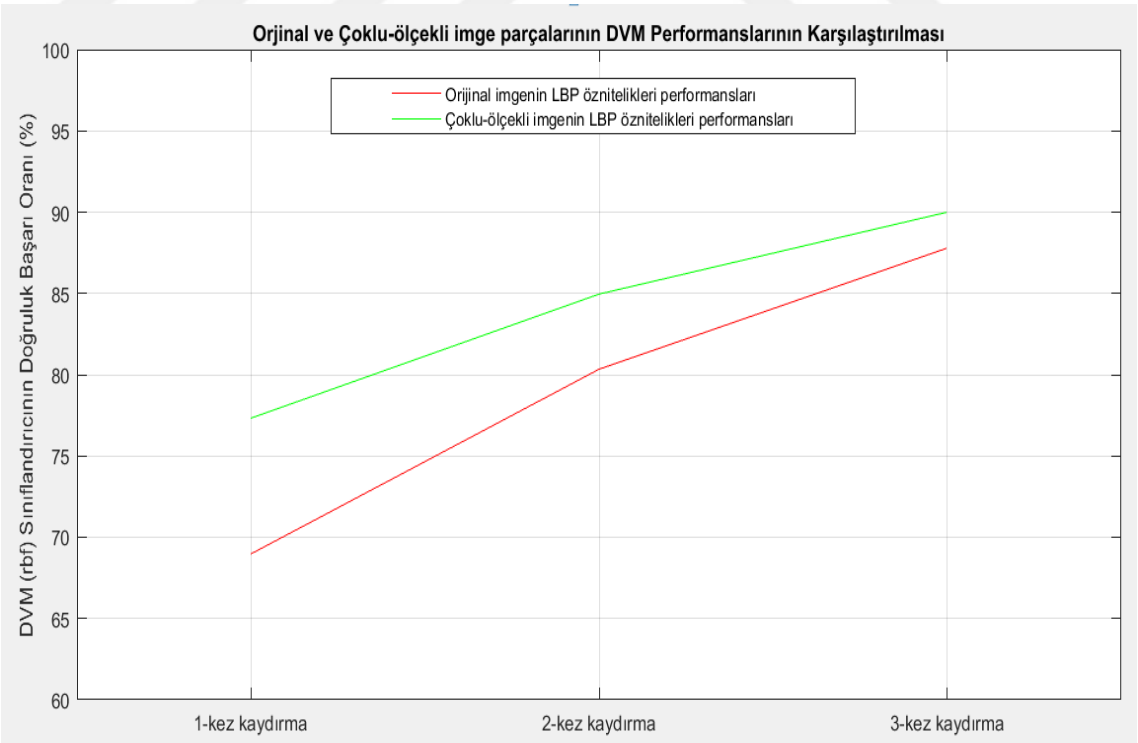

Şekil 4.14: Orijinal ve çoklu-ölçekli imgelerin LBP öznitelikleri DVM (rbf) performansı.

Yukarıda verilen başarım grafikleri incelendiğinde, sınıflandırma testi genelinde elde edilen DVM performanslarının x ve y koordinat sisteminde kaydırma miktarı ile doğru orantılı olarak çoklu-ölçekli imge parçalarından çıkarılan LBP özniteliklerinin kullanılmasıyla artış gösterdiği tespit edilmiştir. İmge parçalarının x ve y koordinat sistemi boyunca 3 kez kaydırma sonucu elde edilen DVM sınıflandırıcısının lineer çekirdek fonksiyonlarındaki ortalama başarım oranları orijinal imgeler için ***%84.73*** iken, çoklu-ölçekli imgeler için ***%87.34***, rbf çekirdek fonksiyonlarındaki ortalama başarım oranları ise sırasıyla ***%87.79*** ve ***%90***'dır**.** Diğer örnek kaydırma değerlerine ait çoklu-ölçekli imgelerin sınıflandırma problemi testi sınıflandırıcı ortalama başarım oranları Tablo 4.4'de verilmiştir.

Tablo 4.4: Çoklu-ölçekli imgelerin sınıflandırma problemi testi DVM sınıflandırıcı ortalama başarım oranları.

İmge Boyutu	**256x256**	**512x512**	**512x512**	**512x512 ve 256x256 Çoklu-ölçekli**	**512x512**	**512x512 ve 256x256 Çoklu-ölçekli**	**512x512**	**512x512 ve 256x256 Çoklu-ölçekli**
Öteleme Miktarı (Piksel)			*x= 8 y=7*	*x= 8 y=7*	*x= 8 y=7*	*x= 8 y=7*	*x= 8 y=7*	*x= 8 y=7*
Kaydırma Sayısı	*0*	*0*	*1*	*1*	*2*	*2*	*3*	*3*
Pencere Boyutu	*17x15*	*17x15*	*17x15*	*17x15*	*17x15*	*17x15*	*17x15*	*17x15*
LBP (Neighbors, Radii)	*(8,1)*	*(8,1)*	*(8,1)*	*(8,1)*	*(8,1)*	*(8,1)*	*(8,1)*	*(8,1)*
Öznitelik Sayısı	*59*	*59*	*236*	*295*	*531*	*590*	*944*	*1003*
DVM (lineer) Başarısı (%)	*61.59*	*48.58*	*62.76*	*74.10*	*76.95*	*81.43*	*84.73*	*87.34*
DVM (rbf) Başarısı (%)	*67.23*	*53.37*	*68.98*	*77.33*	*80.34*	*84.96*	*87.79*	*90.00*

Genel başarım dağılımları incelendiğinde, orijinal imge ve aynı desen özelliklerine sahip farklı boyutta ölçeklenmiş imgeden çıkarılan LBP özniteliklerinin beraber kullanılması sonucu DVM sınıflandırıcının daha iyi performans gösterdiği belirlenmiştir. Orijinal boyutlu imgelerden çıkarılan özniteliklerin sınıflandırma başarısı, ölçeklenmiş imgelerden çıkarılan özniteliklerin ortalama başarım

performansından daha düşüktür. Sınıflandırma performansının artışında, orijinal 512x512 boyutundaki imgenin 256x256 boyuta ölçeklenmesi sonucu boyutu azaltılarak fazla ve gereksiz olabilecek piksel bilgilerinin daha kullanışlı hale getirilmesi etkili olmuştur. Öznitelik vektör değerleri imge boyutundan bağımsız olduğundan her ikisinde de 59 adet LBP öznitelik kullanılmıştır. Orijinal imgeden elde edilen imge parçalarının öteleme kaydırma sayısı artıkça LBP öznitelikleri de arttığından DVM'nin daha iyi performans gösterdiği tespit edilmiştir. 3 kaydırma ile beraber çoklu-ölçekli imgelerden elde edilen özniteliklerin kullanılması sonucu DVM lineer çekirdek fonksiyonunda ***%87.34*** ve rbf çekirdek fonksiyonunda ise ***%90*** seviyelerinde maksimum başarım performansı yakalanmıştır.

5. TARTIŞMA VE SONUÇ

Desen sınıflandırılması görüntü işleme, bilgisayar görüsü gibi çeşitli uygulama alanlarının temel konusunu oluşturmaktadır. Desenler bir görüntü hakkında renk, parlaklık, şekil gibi bilgileri taşıyan önemli bir karakterdir. Bir deseni kavramanın insan görme sisteminde tanıma ve yorumlama için önemli bir rol oynadığına inanılmaktadır. Bu konuda literatürde desen sınıflandırılması, analizi ve tanıma konularında insan beyninin çalışma sistemi temel alınarak yapay öğrenme yöntemleri geliştirilmektedir.

Tez kapsamında, beynin serebral korteks içinde yer alan birincil görme korteksinde (V1) yapılan görsel veri işlemenin ilk adımı olan Katman-4 için Favorov tarafından geliştirilen hesaplamalı modelin (Favorov ve Kursun, 2011) doğrusal boyut indirgeme sonucu 5 boyutlu Katman-3 gösterimi ile çeşitli öznitelik çıkarım yöntemleri kullanılmıştır (Tübitak Projesi, 2016). Bu tez çalışmasında, Katman-3 gösteriminin kapasitesini ölçmek amacıyla yapay öğrenme ve geleneksel görüntü işleme yöntemleri kullanılarak çeşitli sınıflandırma problemi testleri geliştirilmiştir. Katman-3 gösterim yönteminin desenlerin sınıflandırılmasındaki performansı ile literatürde sıklıkla kullanılan piksel, LBP ve GWT öznitelik çıkarım yöntemlerinin DVM sınıflandırıcısındaki performansları karşılaştırılmıştır.

Bu tez çalışması ile, desen tipi imgelerde desen sınıflandırılması problemlerinin daha iyi anlaşılması ve ileride geliştirilebilecek yöntemlere katkı sağlanması amaçlanmıştır. Ayrıca, bu çalışmayla birlikte doğal tip imgelerde desen sınıflandırılması konusunda da literatüre katkı sağlanacağı düşünülmektedir.

İlk tasarlanan test, doğal imgelerin belli bir boyut ve farklı pozisyonlardaki desenlerinin sınıflandırma başarısını ve bu imge parçasının x-y koordinat sisteminde hangi yöne ötelendiğinin sınıflandırılabilir olup olmadığını ölçmek amacıyla geliştirilen afin dönüşüm tabanlı öteleme sınıflandırma problemi testidir. Test analizlerine göre, x yönünde öteleme miktarı artıkça x eksenindeki makrokolon pencerelerin arasındaki benzerliklerin kalmasıyla birlikte DVM sınıflandırıcısının rbf ve lineer çekirdek fonksiyonlarında başarım oranlarının hızlıca düştüğü tespit edilmiştir.

İkinci test, DVM sınıflandırıcısının eğitiminde kullanılacak imge desenleri sayısının sınıflandırma başarım oranına ne ölçüde etki edeceğini belirlemek amacıyla geliştirilen eğitim örnek sayısının sınıflandırma problemi üzerindeki etkisinin ölçümü testidir. Test analizlerine göre, eğitim örnek sayısı ile DVM sınıflandırıcının başarım oranlarının ilintili olduğu tespit edilmiştir. Desenlerin sınıflandırılmasında sadece Katman-3 özniteliklerinin kullanılması eğitim örnek sayısının test örnek sayısına göre çok az olduğu durumda bile diğer yöntemlere göre daha başarılı olduğu fakat DVM'nin farklı çekirdek fonksiyonları arasında başarım farkının %8-10 olduğu gözlemlenmiştir. Bu başarım farkı, Katman-3 öznitelikleri ile LBP özniteliklerinin beraber kullanılması ile birlikte ortadan kalkmasıyla DVM sınıflandırıcısının daha başarılı sonuçlar verdiği gözlemlenmiştir.

Üçüncü test, özellik çıkarım yöntemleri ve Katman-3 özniteliklerin DVM sınıflandırma başarımlarını karşılaştırabilmek amacıyla geliştirilen özellik çıkarım yöntemlerinin performanslarının karşılaştırılması testidir. Bu test, Brodatz desen veri kümesi üzerinde uygulanmıştır. Test analizlerine göre, makrokolon pencerelerin hem orijinal hem de histogram eşitleme sonrasında desenlerin sınıflandırılmasında LBP öznitelik çıkarım yönteminin diğer geleneksel yöntemlere göre üstün performans gösterdiği tespit edilmiştir. Desenlerin sınıflandırılmasında oldukça popüler ve başarılı olan LBP yöntemi özniteliklerinin Katman-3 öznitelikleri ile kıyaslanabilmesi için makrokolon pencereler Talamik katman filtresinden geçirildikten sonra DVM sınıflandırıcındaki performans sonuçları alınmıştır. Elde edilen sonuçlara göre Katman-3 ve LBP özniteliklerinin beraber kullanılmasının desenlerin sınıflandırılmasında daha başarılı sonuçlar verdiği gözlemlenmiştir.

Son test olarak, bir imgenin farklı boyutlarda ölçeklenmesi sonucu elde edilen LBP özniteliklerinin desenlerin sınıflandırılması üzerinde etkisini ölçmek amacıyla çoklu-ölçekli sınıflandırma problemi testi geliştirilmiştir. Bu testteki amaç, Katman-3 veri işleme modeline benzer şekilde LBP özniteliklerinin elde edilmesinin sınıflandırmaya yapacağı katkıyı gözlemlemektir. Test analizlerine göre, orijinal imgenin ötelenmiş ve %50 ölçeklenmiş halinden elde edilen LBP özniteliklerinin beraber kullanılmasının desenlerin sınıflandırılmasında daha başarılı olduğu tespit edilmiştir.

Tez çalışmasında elde edilen test sonuçlarına göre Favorov'un Katman-3 veri işleme modeli desenlerin sınıflandırılmasında sıklıkla kullanılan öznitelik çıkarım yöntemlerine göre daha başarılı olduğu gözlemlenmiştir. Özellikle yapay öğrenme ve örüntü tanıma alanlarında "problemin doğrusallaştırılması" yönteminin etkisi literatürde yapılan çalışmalar ile ispatlanmıştır. Bu yöntemi temel alarak geliştirilen Katman-3 modelinin nöronlarla efektif çalışmasından ötürü desenlerin sınıflandırılmasında güçlü bir gösterim olduğu elde edilen sonuçlarımız arasındadır. Desen sınıflandırılmasında güçlü bir operatör olduğu literatürde yapılan çalışmalarda ispatlanan LBP yöntemi ile bu tez çalışmasında geliştirilen Katman-3 gösteriminin birlikte kullanılmasının sınıflandırma başarım oranlarını oldukça iyileştirdiği elde edilen test sonuçlarımızda görülmüştür.

İleriki çalışmalarda, Katman-3 veri işleme modelinin Brodatz desen veri kümesindeki imgeler ile eğitilmesi sonucu Katman-3 özniteliklerinin elde edilmesi amaçlanmaktadır. Böylece, Katman-3 gösteriminin desen veri kümesi üzerindeki DVM performanslarının artacağı tahmin edilmektedir. Ayrıca, Katman-3 gösteriminin biyomedikal, endüstriyel, meteoroloji gibi farklı alanlara ait veri kümeleri üzerinde gerçekleştirilecek sınıflandırma problemlerinde de başarılı olacağı öngörümüz arasındadır.

KAYNAKLAR

Alpaydin, E., 2014, *Introduction to machine learning*, MIT press.

Altunkaya, Z. ve Yastıklı N., 2011, Ortogörüntüler yardımıyla nesne tabanlı sınıflandırma yöntemi kullanılarak öznitelik çıkarımı, *TBMOB Coğrafi Bilgi Sistemleri Kongresi*.

Ataş, M., Kaya, Y., & Uyar, M., 2013, An efficient rotation invariant feature extraction method based on ring projection technique. In Signal Processing and Communications Applications Conference (SIU), 2013 21st (pp. 1-4). IEEE.

Avci, E., 2007, Doku tipi imgelerin sınıflandırılması için bir uyarlamalı entropi tabanlı dalgacık-yapay sinir ağı sistemi, Journal of the Faculty of Engineering & Architecture of Gazi University 22.1.

Bagci, U., & Bai, L., 2007, Detecting alzheimer disease in magnetic resonance brain images using gabor wavelets. In Signal Processing and Communications Applications, 2007. SIU 2007. IEEE 15th (pp. 1-4). IEEE.

Bohren, C. F., & Clothiaux, E. E., 2006, Fundamentals of atmospheric radiation: an introduction with 400 problems. John Wiley & Sons.

Bradski, G., & Kaehler, A., 2008, *Learning OpenCV: Computer vision with the OpenCV library*, O'Reilly Media, Inc.

Budak Ü., & Şengür A., 2015, Texture classification using scale invariant feature transform and Bag-of-Words, Signal Processing and Communications Applications Conference (SIU), 2015 23th. IEEE.

Camastra, F. ve Vinciarelli, A., 2008, Machine Learning for Audio, Image and Video Analysis: Theory and Applications, Springer, ISBN: 1-84800-007-3.

Cortes, C., & Vapnik, V., 1995, Support-vector networks. Machine learning, 20(3), 273-297.

Çalışkan, A., & Ertuğrul, Ö. F., 2015, Wavelet transform based fingerprint recognition. In Signal Processing and Communications Applications Conference (SIU), 2015 23th (pp. 1481-1484). IEEE.

Çomak, E., 2004, Destek vektör makineleri çoklu sınıf problemleri için çözüm önerileri, Tez (PhD), Selçuk Üniversitesi.

Favorov, O. V. ve Kursun, O., 2011, Neocortical Layer 4 as a Pluripotent Function Linearizer, *Journal of Neurophysiology*, 1 19, 105, 1342-1360.

Haghighat, M., Zonouz, S., & Abdel-Mottaleb, M., 2015, CloudID: Trustworthy cloud-based and cross-enterprise biometric identification. Expert Systems with Applications, 42(21), 7905-7916.

Haralick, R. M., 1979, Statistical and structural approaches to texture. Proceedings of the IEEE, 67(5), 786-804.

Haşiloğlu, A., 2001, Rotation-Invariant texture analysis and classification by artificial neural networks and wavelet transform, Turkish Journal of Engineering and Environmental Sciences 25.5, 405-413.

Heeger, D., 2006, *Perception Lecture Notes: Retinal Ganglion Cells*, http://www.cns.nyu.edu/~david/courses/perception/lecturenotes/ganglion/ganglion.html, [Ziyaret tarihi: 30 Kasım 2016].

Hyvärinen, A., Hurri, J., & Hoyer, P. O., 2009, Natural Image Statistics: A Probabilistic Approach to Early Computational Vision (Vol. 39). Springer Science & Business Media.

İsenkul, M. E., 2016, Korteks Tabanlı İmge Gösterim Kapasitelerinin Uzamsal Dönüşümler ve Makine Öğrenmesi Yöntemleriyle Ölçülmesi, Tez (PhD), İstanbul Üniversitesi.

Daugman, J. G., 1985, Uncertainty relation for resolution in space, spatial frequency, and orientation optimized by two-dimensional visual cortical filters. JOSA A, 2(7), 1160-1169.

Kartal, E., 2015, Enformatik Programı & Balaban M. E., Sınıflandırmaya Dayalı Makine Öğrenmesi Teknikleri ve Kardiyolojik Risk Değerlendirmesine İlişkin Bir Uygulama, Tez (PhD), İstanbul Üniversitesi.

Kashyap, R. L., & Khotanzad, A., 1986, A model-based method for rotation invariant texture classification. IEEE Transactions on Pattern Analysis and Machine Intelligence, (4), 472-481.

Krishnan, K. G., Vanathi, P. T., & Abinaya, R., 2016, Performance analysis of texture classification techniques using shearlet transform. In Wireless Communications, Signal Processing and Networking (WiSPNET), International Conference on (pp. 1408-1412), IEEE.

Liao, S., Law, M. W., & Chung, A. C., 2009, Dominant local binary patterns for texture classification. IEEE transactions on image processing, 18(5), 1107-1118

Maintz, T., 2005, Digital and medical image processing. Universiteit Utrecht.

Mishchenko, Y., 2017, *Makine Öğrenmesi Model Seçimi*, http://yumishch.me/MIT563.html, [Ziyaret Tarihi: 12.01.2017].

Mohri, M., Rostamizadeh, A. ve Talwalkar, A., 2012, *Foundations of Machine Learning*, The MIT Press, ISBN: 0-262-01825-X.

Doshi, N. P., & Schaefer, G., 2012, A comprehensive benchmark of local binary pattern algorithms for texture retrieval. In Pattern Recognition (ICPR), 2012 21st International Conference on (pp. 2760-2763). IEEE.

Nassi, J. J., & Callaway, E. M., 2009, Parallel processing strategies of the primate visual system. Nature Reviews Neuroscience, 10(5), 360-372.

Nizam, H., & Akın, S. S., 2014, Sosyal Medyada Makine Öğrenmesi ile Duygu Analizinde Dengeli ve Dengesiz Veri Setlerinin Performanslarının Karşılaştırılması. XIX. Türkiye'de İnternet Konferansı.

Obay, B. D., 2016, *Birincil Görme Korteksi (V1),* http://www.dicle.edu.tr/Contents/c1f85c00-cddf-4490-a4f4-72adb9f619bc.pdf, [Ziyaret tarihi: 1 Aralık 2016].

Ojala, T., Pietikäinen, M., & Harwood, D., 1996, A comparative study of texture measures with classification based on featured distributions. Pattern recognition, 29(1), 51-59.

Ojala, T., Pietikainen, M., & 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), 971-987.

Petkov, N., & Kruizinga, P., 1997, Computational models of visual neurons specialised in the detection of periodic and aperiodic oriented visual stimuli: bar and grating cells. Biological cybernetics, 76(2), 83-96.

Riaz, F., Hassan, A., Rehman, S., & Qamar, U., 2013, Texture classification using rotation-and scale-invariant gabor texture features. IEEE Signal Processing Letters, 20(6), 607-610.

Ruderman, D. L., 1994, The statistics of natural images. Network: computation in neural systems, 5(4), 517-548.

Schapire, R., 2008, *COS 511: Theoretical Machine Learning*, http://www.cs.princeton.edu/courses/archive/spr08/cos511/scribe_notes/0204.pdf, [Ziyaret Tarihi: 07.01.2017].

Sklansky, J., 1978, Image segmentation and feature extraction. IEEE Transactions on Systems, Man, and Cybernetics, 8(4), 237-247.

Somers, D. C., B, N. S. ve M, S., 1995, An emergent model of orientation selectivity in cat visual cortical simple cells, *Journal of Neuroscience*, 15, 5448-5465.

Takma, Ç., & Hülya, A. T. I. L., 2003, Bootstrap Metodu ve Uygulanışı Üzerine Bir Çalışma 1. Olasılık ve Bootstrap Metodu. Ege Üniversitesi Ziraat Fakültesi Dergisi, 40(3).

Tamura, H., Mori, S., & Yamawaki, T., 1978, Textural features corresponding to visual perception. IEEE Transactions on Systems, Man, and Cybernetics, 8(6), 460-473.

Tan, T., Li, X., Chen, X., Zhou, J., Yang, J., & Cheng, H. (Eds.)., 2016, Pattern Recognition: 7th Chinese Conference, CCPR 2016, Chengdu, China, November 5-7, 2016, Proceedings (Vol. 662). Springer.

Torres, R. C., 2012, *What are retinal receptive fields?*, https://project.inria.fr/keops/what-are-retinal-receptive-fields/, [Ziyaret tarihi: 30 Kasım 2016].

Tuceryan, M., & Jain, A. K., 1993, Texture analysis. Handbook of pattern recognition and computer vision, 2, 235-276.

Tübitak Projesi, 2016, Makine Öğrenmesi Yöntemleriyle Kortikal Katman-4 İmge Gösteriminin Kapasitesinin Ölçülmesi, 114E071.

Türk Dil Kurumu, 2017, *Öğrenme*, http://www.tdk.gov.tr/, [Ziyaret Tarihi: 07.01.2017].

Unser, M., 1995, Texture classification and segmentation using wavelet frames. IEEE Transactions on image processing, 4(11), 1549-1560.

van der Helm, Peter A., *Cognitive architecture or the neural signature of transparallel processing*, https://perswww.kuleuven.be/~u0084530/doc/architecturehtml, [Ziyaret tarihi: 30 Kasım 2016].

van der Helm, P. A., 2012, Cognitive architecture of perceptual organization: From neurons to gnosons. Cognitive processing, 13(1), 13-40.

Varma, M., & Zisserman, A., 2005, A statistical approach to texture classification from single images. International journal of computer vision, 62(1), 61-81.

Whitman R., Polit A., 1974, Texture matching, Kybernetik 16.3, 155-162.

Wikipedia, 2016, *Brodatz database download*, http://sipi.usc.edu/database/database.php?volume=textures, [Ziyaret Tarihi: 30 Kasım 2016].

Wikipedia, 2016, *imge nedir?*, http://www.tdk.gov.tr/index.php?option=com_gts&arama=gts&guid=TDK.GTS.58357e4f527342.06239412, [Ziyaret Tarihi: 30 Kasım 2016].

Wikipedia, 2016, *Receptive Field*, https://en.wikipedia.org/wiki/Receptive_field, [Ziyaret tarihi: 30 Kasım 2016].

Wikipedia, 2017, *Regresyon analizi*, https://tr.wikipedia.org/wiki/Regresyon_analizi, [Ziyaret Tarihi: 12.01.2017].

Wikipedia, 2017, *DVM iki sınıfı ayıran hiper düzlemler*, http://slideplayer.biz.tr/slide/2536104/, [Ziyaret Tarihi: 18.01.2017].

Wikipedia, 2017, *DVM için çoklu sınıf problemleri*, http://ulusaltezmerkezi.com/destek-vektor-makineleri-coklu-sinif-problemleri-icin-cozum-onerileri/, [Ziyaret Tarihi: 18.01.2017].

Wikipedia, 2017, *Karışıklık matrisi*, http://slideplayer.biz.tr/slide/3030436/, [Ziyaret Tarihi: 21.01.2017].

Wikipedia, 2017, *Görüntü öteleme, döndürme, kesme, ölçekleme işlemleri*, http://www.yalova.edu.tr/Files/UserFiles/70/aliiskurt/IMAGE_PROCESS/kulis_ilk_konular.pdf , [Ziyaret Tarihi: 10.03.2017].

Wikipedia, 2017, *Histogram Equalization*, http://www.cs.utah.edu/~jfishbau/improc/project2/ , [Ziyaret Tarihi: 12.03.2017].

Wikipedia, 2017, *Difference of Gaussians: Mexican hat*, http://micro.magnet.fsu.edu/primer/java/digitalimaging/processing/diffgaussians/index.htm, [Ziyaret Tarihi: 13.03.2017].

Yan, J., Sun, Y., Guan, Y., & Hu, X., 2016, A texture descriptor combining fractal and LBP complex networks. In Bioinformatics and Biomedicine (BIBM), 2016 IEEE International Conference on (pp. 524-524). IEEE.

Yavuz, Z., & Kose, C., 2014, Blood vessel segmentation from retinal images based on enhencement methods. In Signal Processing and Communications Applications Conference (SIU), 2014 22nd (pp. 907-910). IEEE.

Zhao, X., Evans, N., & Dugelay, J. L., 2011, A co-training approach to automatic face recognition. In Signal Processing Conference, 2011 19th European (pp. 1979-1983),IEEE.

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	Hatice Nizam
Doğum Yeri	İstanbul
Doğum Tarihi	06.02.1992
Uyruğu	☑ T.C. ❒ Diğer:
Telefon	
E-Posta Adresi	haticenizam@outlook.com
Web Adresi	

Eğitim Bilgileri	
Lisans	
Üniversite	Trakya Üniversitesi
Fakülte	Mühendislik Fakültesi
Bölümü	Bilgisayar Mühendisliği
Mezuniyet Yılı	2014

Yüksek Lisans	
Üniversite	İstanbul Üniversitesi
Enstitü Adı	Fen Bilimleri Enstitüsü
Anabilim Dalı	Bilgisayar Mühendisliği Anabilim Dalı
Programı	Bilgisayar Mühendisliği Programı
Mezuniyet Tarihi	2017

Makale ve Bildiriler
Nizam, Hatice, and Saliha Sıla Akın. "Sosyal Medyada Makine Öğrenmesi ile Duygu Analizinde Dengeli ve Dengesiz Veri Setlerinin Performanslarının Karşılaştırılması." *XIX. Türkiye'de İnternet Konferansı* (2014).