



**SIVAS CUMHURİYET ÜNİVERSİTESİ**  
**Sosyal Bilimler Enstitüsü**  
**Yönetim Bilişim Sistemleri Ana Bilim Dalı**

**DOĞAL TAŞ KAROLARININ GÖRÜNTÜ İŞLEME VE MAKİNE  
ÖĞRENMESİ TEKNİKLERİ İLE SINIFLANDIRILMASI**

Yüksek Lisans Tezi

Mustafa TEMİZ

Sivas  
TEMMUZ 2018

SİVAS CUMHURİYET ÜNİVERSİTESİ  
Sosyal Bilimler Enstitüsü  
Yönetim Bilişim Sistemleri Ana Bilim Dalı

**DOĞAL TAŞ KAROLARININ GÖRÜNTÜ İŞLEME VE MAKİNE  
ÖĞRENMESİ TEKNİKLERİ İLE SINIFLANDIRILMASI**

Yüksek Lisans Tezi

Mustafa TEMİZ

**Tez Danışmanı**  
Doç. Dr. Oğuz KAYNAR

Sivas  
Temmuz 2018

## KABUL VE ONAY

**Üniversite:** : Cumhuriyet Üniversitesi  
**Enstitü** : Sosyal Bilimler Enstitüsü  
**Ana Bilim Dalı** : Yönetim Bilişim Sistemleri  
**Bilim Dalı** :  
**Tezin Başlığı** : Doğal Taş Karolarının Görüntü İşleme ve Makine Öğrenmesi Teknikleri ile Sınıflandırılması  
**Savunma Tarihi** : 23.07.2018  
**Danışmanı** : Doç. Dr. Oğuz KAYNAR

Unvanı - Adı Soyadı

İmza

**Jüri Başkanı** : Doç. Dr. Oğuz KAYNAR

**Üye** : Doç. Dr. Metin ZONTUL

**Üye** : Dr. Öğr. Üyesi Halil ARSLAN

**Oy Birliği**

**Oy Çokluğu**

Mustafa TEMİZ tarafından hazırlanan “Doğal Taş Karolarının Görüntü İşleme ve Makine Öğrenmesi Teknikleri ile Sınıflandırılması” başlıklı Yüksek Lisans Tezi, kabul edilmiştir.

.../.../2018

Prof. Dr. Ahmet ŞENGÖNÜL  
Enstitü Müdürü

## ETİK İLKELERE UYGUNLUK BEYANI

Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü bünyesinde hazırladığım bu Yüksek Lisans/Doktora/Sanatta Yeterlik tezinin bizzat tarafımdan ve kendi sözcüklerimle yazılmış orijinal bir çalışma olduğunu ve bu tezde;

- 1- Çeşitli yazarların çalışmalarından faydalandığımda bu çalışmaların ilgili bölümlerini doğru ve net biçimde göstererek yazarlara açık biçimde atıfta bulunduğumu;
- 2- Yazdığım metinlerin tamamı ya da sadece bir kısmı, daha önce herhangi bir yerde yayımlanmışsa bunu da açıkça ifade ederek gösterdiğimi;
- 3- Başkalarına ait alıntılanan tüm verileri (tablo, grafik, şekil vb. de dahil olmak üzere) atıflarla belirttiğimi;
- 4- Başka yazarların kendi kelimeleriyle alıntıladığım metinlerini, tırnak içerisinde veya farklı dizerek verdiğim yine başka yazarlara ait olup fakat kendi sözcüklerimle ifade ettiğim hususları da istisnasız olarak kaynak göstererek belirttiğimi,

beyan ve bu etik ilkeleri ihlal etmiş olmam halinde bütün sonuçlarına katlanacağımı kabul ederim.

24/07/2018

Mustafa TEMİZ



## ÖNSÖZ

Bu tez çalışmasında, öncelikle değerli hocam ve tez danışmanım Doç. Dr. Oğuz KAYNAR'a yapmış olduğu bilgi ve deneyim paylaşımlarından dolayı teşekkürü borç bilirim.

Desteklerini hiç bir zaman esirgemeyen ve aldığım her kararda arkamda duran kıymetli aileme ve tez çalışmasında karşılaştığım problemlere destek olarak çözüme ulaşmasına yardımcı olan çalışma arkadaşlarım Yasin GÖRMEZ, Mehmet Ali DEVECİ, Yunus Emre IŞIK, Ferhan DEMİRKOPARAN ve Murat Fatih TUNA' ya teşekkürlerimi sunarım.

Mustafa TEMİZ

Temmuz, 2018

# İÇİNDEKİLER

<b>İÇİNDEKİLER</b> .....	<b>i</b>
<b>TABLolar LİSTESİ</b> .....	<b>iii</b>
<b>ŞEKİLLER LİSTESİ</b> .....	<b>v</b>
<b>ÖZET</b> .....	<b>ix</b>
<b>ABSTRACT</b> .....	<b>xi</b>
<b>BÖLÜM 1</b> .....	<b>1</b>
<b>GİRİŞ</b> .....	<b>1</b>
<b>BÖLÜM 2</b> .....	<b>15</b>
<b>RENK VE YÜZEY ÖZİNİTELİKLERİNİN ÇIKARILMASI</b> .....	<b>15</b>
2.1 Gabor Filtresi .....	18
2.2 Gri Seviye Eş Oluşum Matrisi (Gray Level Co-Occurance Matrix-GLCM)	20
2.3 Dalgacık Dönüşümü (Wavelet Transform-DD) .....	22
2.4 Yerel Faz Kuantalama (Local Phase Quantization-LPQ).....	24
2.5 Yerel İkili Örüntü (Local Binary Pattern-LBP).....	25
<b>BÖLÜM 3</b> .....	<b>27</b>
<b>MAKİNE ÖĞRENMESİ VE SINIFLANDIRMA</b> .....	<b>27</b>
3.1 Yapay Sinir Ağları (YSA) .....	28
3.2 Naive Bayes .....	29
3.3 k En Yakın Komşu (k-Nearest Neighbour k-NN) .....	30
3.4. Destek Vektör Makineleri (Support Vector Machine-SVM) .....	31
3.5 Karar Ağaçları (Decision Tree-KA) .....	32
<b>BÖLÜM 4</b> .....	<b>35</b>
<b>VERİ SETİ ve UYGULAMA</b> .....	<b>35</b>
4.1 Doğal Taş Karolarına Ait Verilerin Elde Edilmesi.....	35

4.2 Desen ve Renge İlişkin Özniteliklerin Elde Edilmesi.....	36
4.3 Sınıflandırma Yöntemlerinin Uygulanması.....	39
<b>BÖLÜM 5.....</b>	<b>45</b>
<b>SONUÇ.....</b>	<b>45</b>
<b>KAYNAKÇA.....</b>	<b>49</b>
<b>ÖZGEÇMİŞ.....</b>	<b>59</b>

## TABLULAR LİSTESİ

<b>Tablo 4.1</b> Kullanılan Mermer Çeşit ve Örnek Sayıları.....	35
<b>Tablo 4.2</b> Desene İlişkin Öznitelikler.....	38
<b>Tablo 4.3</b> Renge İlişkin Öznitelikler .....	39
<b>Tablo 4.4</b> Sadece Desen Bilgisinin Bulunduğu Veri Setlerine İlişkin Sınıflandırma Sonuçları.....	40
<b>Tablo 4.5</b> Renk ve Desen Özniteliklerinin Birlikte Kullanıldığı Veri Setlerinden Elde Edilen Sınıflandırma Sonuçları .....	42





## ŞEKİLLER LİSTESİ

Şekil 1.1 Doğal Taş Grupları .....	1
Şekil 1.2 Doğal Taş İhracat Oranları .....	2
Şekil 1.3 Türkiye Doğal Taş ve Mermer Kaynakları Haritası (Ebren 2016).....	4
Şekil 1.4 Öznelik Çıkarımı .....	5
Şekil 1.5 Görüntü İşleme Temelli Doğal Taş Sınıflandırma .....	6
Şekil 2.1 Öznelik Çıkarım Şekilleri.....	16
Şekil 2.2 Piksel Değer Doğrultuları .....	20
Şekil 2.3 Eş Oluşum Matrisi .....	21
Şekil 2.4 Ayrık Dalgacık Dönüşümü .....	23
Şekil 2.5 Yerel Faz Kuantalama .....	25
Şekil 2.6 Yerel İkili Örüntü .....	26
Şekil 3.1 Yapay Sinir Ağ Yapısı.....	28
Şekil 3.2 Lineer Olarak Ayrılabilen ve Ayrılamayan Nitelik Uzayı .....	31
Şekil 3.3 Karar Ağacı Örneği.....	32
Şekil 4.1 Sınıflandırılan Doğal Taş Grupları .....	36



## KISALTMALAR

<b>GLCM</b>	: Gri Seviye Eş Oluşum Matrisleri (Gray Level Co-Occurance Matrix)
<b>LBP</b>	: Yerel İkili Örüntüler (Local Binary Pattern)
<b>GFB</b>	: Gabor Filtre Bankları
<b>DD</b>	: Dalgacık Dönüşümü(Wavelet Transform)
<b>LPQ</b>	: Yerel Faz Kuantalama (Local Phase Quantization)
<b>YSA</b>	: Yapay Sinir Ağları
<b>SVM</b>	: Destek Vektör Makineleri (Support Vector Machine)
<b>k-NN</b>	: k En Yakın Komşu (k- Nearest Neighbour)
<b>KA</b>	: Karar Ağaçları (Decision Tree)
<b>NB</b>	: Naive Bayes
<b>SDH</b>	: Toplam ve Fark Histogramları (Sum and Difference Histograms)
<b>CCR</b>	: Koordine Edilmiş Kümeler Temsili (Coordinated Clusters Representation)
<b>RGB</b>	: Red Green Blue
<b>HSV</b>	: Hue Saturation Value
<b>LVQ</b>	: Learning Vector Quantization
<b>PCA</b>	: Temel Bileşen Analizi (Principal Component Analysis)
<b>ILBP</b>	: Geliştirilmiş Yerel İkili Örüntü (Improved Local Binary Pattern-ILBP)
<b>CNN</b>	: Evrişimsel Sinir Ağı (Convolutional Neural Network)
<b>SDD</b>	: Sürekli Dalgacık Dönüşümü
<b>ADD</b>	: Ayrık Dalgacık Dönüşümü



## ÖZET

Doğal taş endüstrisinde sınıflandırma işlemi işletmeler için büyük önem arz etmektedir. Doğal taş parçaları içeriğinde bulunan minerallere bağlı olarak renk ve doku açısından farklı görünümlere sahip olabilmektedir. İnsan merkezli sınıflandırma işlemi gerçekleştirilirken görü kabiliyeti, farklı çevresel şartlar ve yorgunluk gibi etkenlerinde devreye girmesi ile yetersiz kalmakta ve hatalı sınıflandırmaya yol açmaktadır. Sınıflandırma aşamasında kişilerin vereceği hatalı kararlar işletme açısından hem ekonomik hem de markanın prestij kaybına neden olmaktadır. Doğal taş sektöründeki hızla artan rekabet ve küreselleşme sebebiyle önemi artan kalite kontrol süreçlerinin gelişimi için bilgisayar destekli görüntü işleme yöntemlerini kullanan doğal taş karolarını otomatik sınıflandırma ve derecelendirme sistemlerine her zamankinden daha çok ihtiyaç vardır. Bu tip otomatik sınıflandırma ve derecelendirme sistemlerinde doğal taş karolarına ait resimlerden görüntü işleme teknikleri yardımıyla renk ve yüzey hakkında bilgi verecek öznitelikler çıkarılmakta ve daha sonra bu öznitelikler kullanılarak elde edilen veri seti çeşitli yapay zekâ ve veri madenciliği teknikleriyle sınıflandırılmaktadır.

Bu çalışmada Sivas'ta faaliyet gösteren bir doğal taş üretici firmadan (Beta Mermer A.Ş) elde edilen toplam altı sınıf içeren doğal taş karolarına ait 996 resimden oluşan bir veri seti üzerinde sınıflandırma işlemi gerçekleştirilmiştir. Karolara ait desen bilgisinin elde edilmesinde Gabor Filtre Bankları (GFB), Gri Seviye Eş Oluşum Matrisleri (Gray Level Co-Occurance Matrix-GLCM), Dalgacık Dönüşümü(Wavelet Transform-WT), Yerel Faz Kuantalama (Local Phase Quantization-LPQ) ve Yerel İkili Örüntüler (Local Binary Pattern-LBP) yöntemleri kullanılmıştır. Mermerlere ilişkin renk bilgilerin elde edilmesinde ise her bir renk kanalına ilişkin çeşitli istatistiklerden yararlanılmıştır. Desene ilişkin öznitelikler yanında renk bilgisinin de kullanıldığı öznitelikler yardımıyla çeşitli veri setleri oluşturulmuştur. Böylelikle sadece desen bilgisi değil bunun yanında renge dayalı özniteliklerin de sınıflandırma başarısına olan etkisi incelenmeye çalışılmıştır. Daha sonra bu veri setlerinin sınıflama performansı, Yapay Sinir Ağları (YSA), Destek Vektör Makineleri (Support Vector Machine-SVM), k En Yakın Komşu (k- Nearest

Neighbour-k-NN), Karar Ağaçları (Decision Tree-KA), Naive Bayes (NB) gibi çeşitli yöntemler kullanılarak karşılaştırılmıştır.

**Anahtar Kelimeler:** Doğal taş sınıflandırma, gri seviye eş oluşum matrisi, yerel ikili örüntü, gabor filtre bankaları, dalgacık dönüşümü, yerel faz kuantalama.

## ABSTRACT

Classification process have a great importance on natural stone industry. Natural stone pieces may have different appearances in terms of both colour and texture depending on minerals involved in. Under the influence of some factors such as environmental circumstances and tiredness, vision capability which is necessary for human-centred classification can be insufficient and cause misclassification. Failure decisions made by people in the process of classification give raise to loss of prestige and economic in terms of operation.

There is a greater need than ever for natural stone tile classification and grading systems that use computer aided image processing methods for the development of quality control processes that are increasingly important due to the rapidly increasing competition and globalization in the natural stone industry.

In this type of automated systems features which can give information about colour and surface of natural stone tiles are extracted via image processing techniques and afterwards, data sets derived by using these features are classified via various techniques of both artificial intelligence and data mining.

In this study, a classification process was performed on a data set which is derived from a natural stone manufacturer operates in Sivas (Beta Mermer) and which consists of six classes and 996 images. Gabor Filter Bank (GFB), Gray Level Co-Occurance Matrix (GLCM), Wavelet Transform (DD), Local Phase Quantization (LPQ) and Local Binary Pattern (LBP) methods were used to acquire pattern information of tiles. Various statistics related to every single color channel were used to obtain color information on marbles. Various data sets were created with the help of the features that are used in the color information besides the features related to pattern. Thus the effect of not only the pattern information but also features related to color on the classification performance were tried to be examined. Data sets which contains only the pattern and features belongs to both pattern and colour were constituted. Finally, the classification performance of these data sets were compared with some methods such as Artificial Neural Network (YSA), Support Vector




Machine (SVM), k En Yakın Komşu (k-NN), Decision Tree (KA) and Naive Bayes (NB).

**Keywords:** Natural stone classification, grey level co-occurrence matrix, local binary pattern, gabor filter banks, wavelet transform, local phase quantization.

# BÖLÜM 1

## GİRİŞ

Doğal taşlar, insanlık tarihi boyunca ihtiyaçlara bağlı olarak çeşitli amaçları karşılamak için kullanılan, işlenmeye müsait değişik renk ve yüzeylere sahip değerli kaynaklardan biri olarak bilinmektedir (Ferreira, Giraldi 2017). Görselliğinde bulunan ihtişam ve güzellik ayrıca nispeten kolay ve ucuza temin edilmesinden dolayı yapı sektöründe sıklıkla tercih edilmektedir. Gelişen teknoloji ile birlikte istenen şekil ve boyutlara ayarlanabilen doğal taşlar inşaat sektöründe kaplama ve döşemeye ek olarak yer döşemesi, duvar kaplamaları, banyo ve mutfak dekorasyonlarında, özel imalat olarak ise cam, porselen, süs eşyası, heykel ve optik yapımında yoğun şekilde kullanılmaktadır. Doğal taş sektöründe başta mermer olmak üzere siyenit, bazalt, granit, kireç taşı, kum taşı, kuartz, kayağan taş gibi pek çok doğal taş türü bulunmaktadır (Sel 2006; López-Buendía vd. 2013; Taşligil, Şahin 2017).

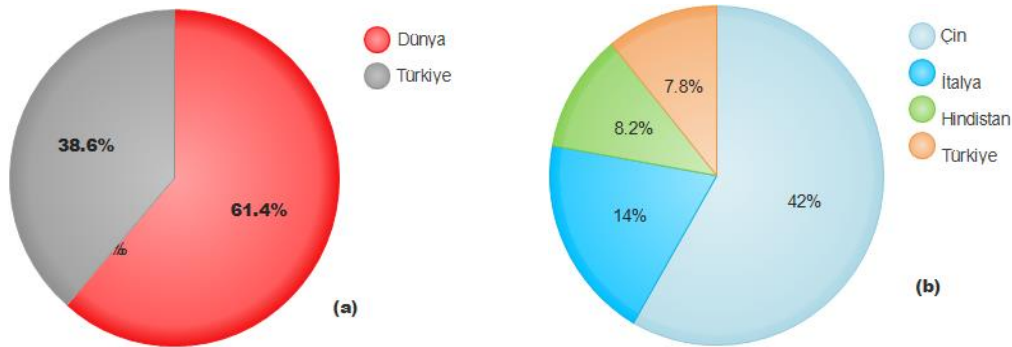


**Şekil 1.1** Doğal Taş Grupları

Son otuz yılda maliyet noktasında Çin' in devreye girmesi dünya genelinde fiyatların ucuzlamasına sebep olmuş ve insanların sağlıklı ve doğal ürünlere ilgi göstermesiyle de doğal taş kullanımının ülkemizde ve dünyada artışına sebep olmaktadır. Ülkemizde 1985 yılında gerçekleşen kanun değişikliği ile doğal taş ürünleri maden kapsamına alınmış ve doğal taş sektöründe üretim hızlı bir artış

göstermiştir (Sel 2006). Ayrıca, gelişmekte olan makine teknolojisi ve bu teknolojinin doğal taş sektöründe kullanımı ile ülkemizde bulunan doğal taş rezervlerin işlenmesi artmakta ve ülkemiz dünyanın en önemli doğal taş üreticileri arasında yer almaktadır (Şişeci, Çetişli 2012). 2013 yılında dünya doğal taş ihracatı 2009-2013 yılları arası ortalama %8,5 artarak 19,3 milyar dolara ulaşmıştır. 2013 yılında dünya ham-blok mermer ürün ihracatında Türkiye toplam ihracatın %38,6'sını gerçekleştirerek ilk sırada yer alırken, işlenmiş doğal taş ihracatında ise Çin (%42), İtalya (%14), Hindistan (%8,2) ardından %7,8'lik payla 4. sırada yer almıştır (innocentric 2014:3-42). 2017 yılında ise Doğal taş ihracatı 2016 yılına oranla %13.43 oranında artarak 7.9 milyon ton karşılığı 2 milyar 48 milyon dolar olarak gerçekleştirilmiştir (2017 Yılı Maden ve Doğal taş İhracat Değerlendirmesi ve Genel İstatistik Verileri, 2018). Şekil 1.2'de doğal taş ihracat oranları belirtilmektedir. Doğal taş sektöründe artan bu doğal taş ihracat artışı, ülkemizde mevcut doğal taş tüketimi, doğal taş makine üretimi ve bu makinelerin ihracatı ile ülkemiz ekonomisine önemli oranda katkı sağlamaktadır (Ebren 2016).

Doğal taş ihracatında ki hızlı artış işletmelerin dikkatini çekmekte ve bu sektöre olan ilgi günden güne artmaktadır. 2013 yılında yaklaşık 13,6 milyon m<sup>3</sup> üretim yapılmaktayken 2016 yılında yaklaşık 17,5 milyon m<sup>3</sup> doğal taş üretimi yapılmıştır (T.C. Enerji ve Tabii Kaynaklar Bakanlığı - Doğal Taşlar 2017).



**Şekil 1.2 Doğal Taş İhracat Oranları**

**(a) Toplam İhracat (b) İşlenmiş Doğal Taş İhracatı**

Doğal taş sektöründe ürünleri kalite gruplarına sınıflandırmak ve derecelendirmek amacıyla, renk, desen, kenar ve çatlak analizi gibi çeşitli yöntemler uygulanmaktadır. Kalite kontrol sürecinde üretilen ürünleri renk ve desenlerine göre

sınıflandırma işlemi son derece karmaşık problemlerden birini oluşturmaktadır. Bu karmaşıklığın en önemli sebebi yer altından çıkarılan her taşın renk ve desen görselliğinin benzerlik göstermesidir. Aynı mineralojik içeriğe sahip doğal taşlar renk ve yüzey açısından farklı görünümlere sahip olabilmekte veya farklı mineralojik içeriğe sahip doğal taşlar ise benzer görsel özellikler gösterebilmektedirler. Bu şekilde renk ve yüzey özellikleri açısından çok fazla sayıda doğal taş çeşidi bulunmakta ve bu doğal taş çeşitleri için tanımlanmış herhangi bir sınıflandırma tekniği bulunmamaktadır. Mevcut problemi çözmek için doğal taş örneklerine baskın renk tonlarından oluşan isimlendirmeler ('Denizli Traverteni', 'Zimbabve Siyahı', 'Tütün Kahverengisi') verilmektedir. Bu tür sınıflandırmalar ülkeden ülkeye değişiklik gösterebilmektedir. Bu problem kısmen Avrupa EN12440 (2009) tarafından belirlenen ortak sınıflandırma kriterlerinin tanımıyla bir nebze olsun çözümlenmesine karşın görsel temelde doğal taşları sınıflandırmak ve derecelendirmek için yeterli değildir (Bianconi vd. 2012).


Kalite kontrol süreci tüm sektörlerde olduğu gibi doğal taş üretim sektöründe de büyük bir öneme sahiptir. Doğal taş işletmeleri üretim son aşaması olan paketleme işlemi için kalitelerine göre doğal taşları sınıflamaya ihtiyaç duymaktadır. Bu işlem şimdiye kadar tecrübeli ve yetenekli işçiler tarafından el yardımı ile uygulanan manuel işlemler ile yapılmaktadır. Bu durum işçilerde sürekli benzer renk tonlarına bakmalarından kaynaklanan göz yorgunluğu oluşturmakta ve renk geçişlerini kaçırmalarına neden olmaktadır. Bir başka sorunda ise günün farklı saatlerinde farklı ışık miktarlarından dolayı farklı renge sahip doğal taş yüzeyleri aynı renk tonlarında algılanabilmektedir (Metlek 2015). İnsan kaynaklı kalite kontrol işlemlerinde öznellik ön planda olduğu için sınıflama işleminde meydana gelen hata oranı yüksek seviyelere ulaşmaktadır. Bu yöntemler çoğu zaman görsel görünümü birbirinden farklı üretim partilerinin oluşmasına, üzerinde anlaşılan numunelerle gönderilen partinin farklı olması nedeniyle üretici ile müşteri arasında anlaşmazlıklara ve ürünün iadesine kadar varan bir dizi problemlere ve ekonomik kayıplara sebep olmaktadır. Küreselleşmenin getirdiği rekabet ortamında oluşacak olan ekonomik kayıpların en aza indirilmesi ve hizmet standartlarının artırılması için doğal taş üreten işletmeler, doğal taş karolarını renk ve desen bilgilerine göre sınıflandıran

bilgisayar destekli otomatik sınıflandırma sistemlerine ihtiyaç duymaktadırlar (Bianconi vd. 2012, 2015).

Bu tür sistemlerin sağlayacağı olası avantajlar arasında şunlar belirtilebilir;

1. Standart, objektif ve tekrarlanabilir prosedürler yoluyla kalite kontrol sürecinde iyileşme,
2. Kalite kontrol sürecini üretim sonrasına değil üretim aşamasına entegre etme,
3. Aynı kalitede üretim sayesinde satış iadelerinin ve ilgili ekonomik kayıpların azaltılması,
4. Sınıflanan ürünlere ilişkin bilgileri saklama istendiğinde belirli kriterlere uygun olanları yeniden getirebilme, böylelikle daha iyi izlenebilirlik ve depo yönetimi elde etme (Bianconi vd. 2012).


Günümüzde 650 farklı renk ve desende mermer, traverten, granit gibi çeşitli doğal taş ürünleri bulunmakta ve bu ürünlerden 290 kadarı ülkemizde de bulunmaktadır. Bunun yanı sıra Denizli Traverteni, Elazığ Vişne gibi sadece ülkemizde çıkarılan doğal taşlar da mevcuttur (Taşlıgil, Şahin 2017). Doğal taşların önemli özellikleri arasında sahip oldukları renk ve desen bilgisi bulunmaktadır. Genellikle beyaz, siyah, gri veya sarı renklerine ve bunların tonlarına sahip olan doğal taşlar geniş bir renk aralığına ve çok çeşitli desen bilgisine sahiptir. Farklı özelliklere sahip bu doğal taşların görünüşleri de birbirinden farklı olmakta ve işletmeler için bu farklılıkları tespit ederek ayırım yapma işlemi önem arz etmektedir (Taşlıgil, Şahin 2017).



**Şekil 1.3** Türkiye Doğal Taş ve Mermer Kaynakları Haritası (Ebren 2016)

Cisimlerin görünümlerinin değerlendirme ve karşılaştırılması, yüzey derecelendirme, kusur tespiti, görüntü tabanlı cisim tanıma ve benzer görüntü gruplarının oluşturulması gibi pek çok uygulamada önemli rol oynamaktadır. Parke, seramik karo, deri ve dünya çapında 76.000 tondan fazla üretilen doğal taş vb. ürünler üzerinde bu işlemler yoğun olarak uygulanmaktadır (Bianconi vd. 2015).

Görüntü karşılaştırılması ve değerlendirilmesi vb. işlemlerinde yüzeylerin temel özelliklerini basit ve benzersiz bir şekilde temsil etmesini ve böylece nesnelerin doğru biçimde sınıflandırılmasını amaçlayan yüzey analizi işlemleri uygulanmaktadır. Yüzey analizi işlemleri uygulanırken öncelikli olarak yüzey öznelik çıkarım işlemleri uygulanmakta ve bu öznelikler üzerinden sınıflandırma işlemi gerçekleştirilmektedir. Öznelik çıkarım işlemleri, geniş veri kümesini daha az ve karakteristik veriler ile tanımlamak için gereken kaynak miktarını basitleştirmeyi içermektedir (Mohanaiah vd. 2013). Öznelik çıkarım işlemi temel olarak Şekil 1.3’de ifade edilmektedir.



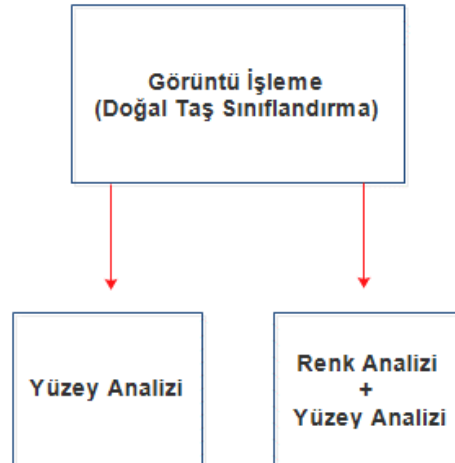
**Şekil 1.4** Öznelik Çıkarımı

Yüzey analiz işlemleri doğal taş işleme sektöründe de kullanılmakta ve doğal taşlara ait yüzeylere öznelik çıkarım işlemleri uygulandıktan sonra gerekli sınıflandırma yöntemlerine yer verilmektedir (Selver, Akay 2009). Sınıflandırma yöntemlerine üretim hattından elde edilen aynı kalite doğal taşları bir araya toplamak için ihtiyaç duyulmaktadır. Daha önceleri insan kaynaklı olarak uygulanan doğal taş sınıflandırma aşaması zamanla gelişen teknoloji ve rekabet ortamında makine öğrenmesi ve bilgisayar görü kavramlarının da gelişmesinden dolayı yerini makine

merkezli sınıflandırma yapılarına bırakmaktadır. Doğal taş çeşitlerine makine öğrenmesi yöntemleri ile sınıflandırma işlemi uygulanırken doğal taşların sahip olduğu renk ve desenlerin oluşturduğu yüzey bilgilerinden yararlanılmaktadır (Bianconi vd. 2012).

Doğal taş mermer ve fayansların sınıflandırılmasına ilişkin çalışmalara ilgi giderek artmış ve bu konuda çeşitli yaklaşımlar önerilmiştir. Genel olarak, bu yöntemleri görüntü işleme temelli ve spektrofotometrik verilere dayanan yöntemler olarak iki grupta toplamak mümkündür. Görüntü işleme temelli yaklaşımları ise tek başına yüzey doku özelliklerine dayanan yöntemler ile renk ve yüzey doku özelliklerinin birlikte kullanıldığı yöntemler olarak ikiye ayrılmaktadır (Bianconi vd. 2012).

- Görüntü işleme temelli yöntemler
  - Yüzey doku özelliklerine göre
  - Renk ve yüzey doku özelliklerinin birleşimi ile elde edilen özelliklere göre
- Spektrofotometrik verilere dayanan yöntemler



**Şekil 1.5** Görüntü İşleme Temelli Doğal Taş Sınıflandırma

Sınıflandırma öncesinde yüzeylere ilişkin temel renk ve yüzey özellikleri basit ve benzersiz bir şekilde temsil eden öznitelikler elde edilerek daha sonra bu öznitelikler

yardımla çeşitli sınıflayıcılar kullanılarak doğal taş karolarının doğru bir şekilde sınıflandırılması sağlanmaktadır (Mohanaiah vd. 2013).

Bilgisayarlı görü yardımla cisimlerin görsel görünümünün karşılaştırılma, sınıflandırılma ve değerlendirilme çalışmaları, kusur tespiti, yüzey derecelendirme, benzer görüntü gruplarını bulma ve görüntü tabanlı cisim tanımlama şeklinde sınıflandırılabilir. Özellikle cisimlerin yüzeylerinden elde edilen renk ve desen bilgisine bağlı olarak aynı görsel görünüme sahip cisimlerin sınıflandırılması ve yüzeyde oluşan kusurların tespitine ilişkin birçok endüstri dalında başarılı uygulamalar mevcuttur (Bianconi vd. 2015).

Doğan ve Akay (2010) mermer bloklarını kalitelerine göre otomatik olarak sınıflandırmak için Adaboost sınıflandırma algoritmalarını kullanarak yeni bir hiyerarşik sınıflandırma yöntemi önermişlerdir. Öznitelik çıkarım yöntemi olarak toplamsal ve farksal histogram (Sum Difference Histogram-SDH) yöntemini kullanan Doğan ve Akay ardından bu öznitelik değerlerini kullanarak farklı Adaboost algoritmalarına dayalı sınıflandırıcıları önerdikleri yöntemde kullanarak sınıflandırma işlemini gerçekleştirmişlerdir. Önerdikleri yöntemin performans değerlerini destek vektör makineleri ve yapay sinir ağları yöntemleri ile karşılaştırmış ve önerdikleri yöntemin sınıflandırma başarısının daha yüksek olduğunu ifade etmişlerdir (Doğan, Akay 2010).

Ershad (2011) granit, mermer, traverten ve balta taşı gibi değişik doğal taş türlerini sınıflayan bir çalışma gerçekleştirmiştir. Ortalama her grup için yüksek çözünürlüklü 20 adet resim bulunan bir veri seti elde etmişler ve bu resimlerden 52 tanesi eğitim geri kalan 28 resim ise test amacıyla kullanılmıştır. Makalede temel granül parçacıkları yöntemi önerilmiş, bu yaklaşımla öncelikle granüllere ilişkin histogramlar ve histogramlara ilişkin istatistiksel yöntemler yardımla bazı öznitelikler elde edilmiştir. Doku sınıflandırmasına ilişkin doğruluk ve kaliteyi artırmak amacıyla her bir renk kanalından ayrı ayrı elde edilmiştir. Önerilen öznitelik çıkarma yönteminin başarısı gri seviye eş oluşum matrisi (Gray Level Co-Occurance Matrix-GLCM) ve yerel ikili örüntü (Local Binary Pattern-LBP) yönteminden elde edilen özniteliklerle karşılaştırmak için k en yakın komşu (k Nearest Neighbour-k-NN) (k=1, k=3, k=5), Karar ağaçları (KA), J48 Tree ve Naive Bayes (NB)



sınıflandırıcıları kullanılmıştır. Tüm sınıflayıcılar için en yüksek başarı oranları önerilen yöntemden elde edilmiştir (Ershad 2011).

Topalova ve Tzokev (2010) tarafından yapılan çalışmada renk histogramlarına dayanan dört sınıf ve beş parlaklık varyasyonu içeren benzer renklere sahip mermer karo parçalarının sınıflandırılması için bir yöntem önerilmiştir. Histogramlar yardımıyla elde edilen öznitelik değerleri ile eğitilen yapay sinir ağını programlanabilir mantık denetleyicisinde gerçekleştirerek gerçek zamanlı bir sınıflandırıcı elde etmişlerdir (Topalova, Tzokev 2010).

Kurmyshev vd. (2003) 'Rosa Porrino' isimli cilalanmış granit karo parçalarının sınıflandırılması için koordine edilmiş kümelenmeler temsiline (Coordinated Clusters Representation-CCR) dayanan bir çalışma gerçekleştirmişlerdir. Yüzey öznitelik bilgileri gri seviyeli resimlerden elde ediliyorken ve renk bilgileri ise RGB (Red Green Blue) renk kanallarından elde edilmektedir daha sonra yüzey bilgisi ve renk bilgisinin birlikte kullanımı ile öznitelik değerleri oluşturulmaktadır (Sánchez-Yáñez vd. 2003).

Luis-Delgado vd. (2003) mermer parçalarını düşük, ticari ve yüksek kalite olmak üzere üç gruba ayırmış ve bu mermer gruplarını sınıflandırmak için dalgacık dönüşümünden faydalanmışlardır. Her bir grupta bulunan mermer türlerinden eğitim ve test için 10 adet resim kullanmış ve dalgacık dönüşümü yöntemini kullanılarak elde edilen öznitelikler üzerinden LVQ (Learning Vector Quantization) yapay sinir ağını eğiterek mermer kalitelerine göre doğal taşları başarılı bir şekilde sınıflandırmışlardır (Luis-Delgado vd. 2003).

Sousa ve Pinto (2004) mermer parçalarını sahip oldukları baskın renk bilgileri ve üzerlerinde bulunan damarlara göre sınıflandırma işlemi uygulamışlardır. Renk kanallarından elde edilen öznitelikler genetik algoritma, bulanık mantık, benzetimli tavlama, yapay sinir ağları ve bu sınıflandırma yöntemlerinin kombinasyonları yardımıyla sınıflandırma işlemi gerçekleştirmişlerdir. Bu sınıflayıcılar içerisinde genetik algoritma yöntemi ile eğitilen bulanık sınıflayıcıyla en başarılı sonuçları elde etmişlerdir (Sousa, Pinto 2004).

Martí'nez-Alajarín vd. (2005) üretim hattında mermer plakaların farklı gruplara sınıflandırılması için gerçek zamanlı otomatik bir sistem önerisinde

bulunmuşlardır. Görüntü analizi üzerindeki renk gösterimi etkisini değerlendirmek için dört farklı renk uzayı (RGB, XYZ, YIQ ve K-L) kullanılmıştır. Her bir renk uzayı için renk kanallarının her birine toplam ve fark histogram yöntemi uygulanmış, çeşitli istatistikler yardımıyla elde edilen öznitelik vektörünün boyutu temel bileşen analizi (Principle Component Analysis- PCA) ile düşürülerek öznitelik çıkarma işlemi gerçekleştirilmiştir. Elde edilen öznitelikler çok katmanlı bir algılayıcı sinir ağının eğitiminde kullanılmış ve sonuçta %98.9'luk başarılı sınıflandırma oranı elde etmişlerdir (Martínez-Alajarín vd. 2005).

Lepistö vd. (2005) tarafından yapılan çalışmada yüzeye ilişkin öznitelikleri HSV (Hue Saturation Value) renk uzayında her bir renk kanalına farklı seviyelerde Gabor filtreleri uygulayarak elde etmişlerdir. k-NN sınıflayıcısı kullanılarak yapılan çalışmada her bir renk kanallarından elde edilen özniteliklerin sadece gri seviyeden elde edilen öznitelikler ile karşılaştırması yapılmış ve her bir renk kanalı kullanılması performansı önemli ölçüde artırdığını ifade etmişlerdir (Lepistö vd. 2005).

Bianconi ve Fernández (2006) granit sınıflandırması için farklı Gabor filtre bankaları kullanmışlardır. Çalışmada HSV ve RGB renk uzaylarında her bir renk kanalına Gabor filtreler uygulanarak öznitelikler elde edilmiştir. 4 farklı granit parçasının sınıflandırıldığı çalışmada k-NN sınıflayıcı kullanılmıştır. Farklı renk kanallarından elde edilen özniteliklerin çeşitli kombinasyonlarını kullanmanın sınıflandırma başarısını önemli ölçüde artırdığını belirtmişlerdir (Bianconi, Fernández 2006).

Bianconi vd. (2015) tarafından yapılan bir başka çalışmada ise granit yüzeylerini sınıflandırmada farklı renk uzayları kullanmanın sınıflandırma üzerinde ki başarısı araştırılmıştır. 25 farklı granit sınıfının karşılaştırıldığı çalışmada k-NN sınıflayıcısı kullanılarak farklı renk uzaylarından elde edilen özniteliklerin performanslarında önemli bir farklılık gözlemlenmemiş, doğrusal sınıflayıcının kullanıldığı çalışmalarda Lab ve Luv uzaylarından elde edilen öznitelikler diğerlerine oranla daha iyi sonuçlar verdiğini gözlemlemişlerdir (Bianconi vd. 2015).

Selver vd. (2007) tarafından yapılan çalışmada 193 adet mermer görüntüsünden oluşan ve uzmanlar tarafından fiziksel özellikleri dikkate alınarak dört sınıfa ayrılan bir veri seti oluşturmuşlardır. Mermer parçalarına dair renk, desen

ve tektüreliliğin önemli olduğu çalışmada bu özelliklerin tekrar edilebilirliğine ilişkin öznitelikleri çıkarmak amacıyla toplam ve fark histogram matrislerinden ve gri seviye eş oluşum matris yöntemlerinden faydalanmışlardır. Elde edilen öznitelikler temel bileşen analizi yardımıyla boyut düşürülerek farklı renk uzaylarının başarıma etkisini incelemişlerdir (Selver vd. 2007).

Selver vd. (2009) başka bir çalışmada mermer karolarının sınıflandırılması için toplam ve farka dayalı histogram bilgileri ve Ayrık Wavelet dönüşümünden elde ettikleri öznitelikleri yapay sinir ağları yardımıyla sınıflandırmışlardır. Toplam ve farka dayalı histogramlardan her bir kanal için 7 farklı istatistik (mean, variance, energy, correlation, entropy, contrast, homogeneity) kullanarak toplamda her bir resim için 21 öznitelik elde etmişlerdir. Ayrık dalgacık dönüşümü içinse her bir seviyede bir adet alçak geçiren, üç adet yüksek geçiren filtre yardımıyla (yatay, düşey ve diagonal) 4 adet resim elde edilmiş ve bu resimlerden ortalama, standart sapma ve varyans yardımıyla toplamda 3 seviyeli bir dönüşüm sonucunda 1x36 boyutunda bir öznitelik vektörü elde edilmiştir. Her iki yöntemden elde edilen öznitelikler ayrı ayrı ve birleştirilerek ağların eğitimde kullanılmıştır. Ayrıca çalışmada PCA(Principle Component Analysis) yöntemi kullanılarak boyut düşürmenin etkisi ile RGB haricinde üç farklı renk uzayı (KL, XYZ ve YIQ) için karşılaştırmalar yapılmıştır (Selver, Akay 2009).

Fernández vd. (2011) yaptıkları çalışmada çeşitli döndürme koşulları altında, farklı granit yüzey özelliklerini karşılaştırmak için yerel ikili örüntüler(Local Binary Pattern-LBP), koordineli kümeler temsili ve geliştirilmiş yerel ikili örüntüler(Improved Local Binary Patterns-ILBP) yöntemlerini kullanmışlardır. Geliştirilmiş yerel ikili örüntülerin diğer iki yöntemle oranla daha iyi sonuçlar verdiğini ifade etmişlerdir (Fernández vd. 2011).

Abadi ve Banihashemi (2015) yaptıkları çalışmada dört gruptan 124 adet resim içeren bir dizi traverten taşının sınıflandırılmasını incelemişlerdir. Öznitelik çıkarma yaklaşımı olarak toplam ve fark histogramı (Sum Difference Histogram-SDH) kullanılmış ve elde edilen özniteliklere çeşitli sınıflandırma algoritmaları uygulanmıştır. Deney sonuçları önerilen yaklaşımın traverten taşlarında kabul

edilebilir bir sınıflandırma performansına sahip olduğunu belirtmişlerdir (Abadi, Banihashemi 2015).

Renk ve yüzey özelliklerinin granit sınıflamasında birlikte kullanıldığı bir çalışmada Bianconi vd. (2012) tarafından gerçekleştirilmiştir. 12 adet granit sınıfı üzerinde gerçekleştirilen deneylerde renk ve yüzey bilgisine ilişkin çeşitli yöntemler yardımıyla öznitelikler çıkarılmıştır. GLCM, LBP ve Gabor filtreleri yardımıyla yüzey özellikleri elde edilirken RGB ve HSV renk alanları kullanılarak renk bilgisine ait öznitelikler çıkarılmıştır. Tek başına yüzey bilgisinden elde edilen öznitelikler ile renk ve yüzey bilgisinden elde edilen özniteliklerin farklı şekillerde birleştirilmesi ile çeşitli öznitelik setleri oluşturulmuştur. Yüzey bilgisinden elde edilen öznitelikler genelde gri seviye resimlerden oluşurken bazı yüzey öznitelik yöntemleri ayrı ayrı renk kanallarına ve renk kanalı çiftlerine uygulanarak öznitelikler de elde edilmiştir. Daha sonra bu öznitelikler Destek Vektör Makineleri (Support Vector Machine-SVM), En Yakın Komşu, Naive Bayes ve Lineer sınıflandırıcı kullanılarak sınıflandırılmışlardır. Sonuçlar, renk ve yüzey bilgisine dayalı sınıflamanın oldukça etkili olduğunu ve tek başına yüzeysel özelliklere dayalı önceki yöntemlerden daha iyi sonuçlar verdiğini göstermektedir. Parametreleri optimize edilmiş destek vektör makineleri ise sınıflandırma performansı en yüksek yöntem olarak belirtilmiştir (Bianconi vd. 2012).

Araújo vd. (2010) spektrometre yardımı ile elde ettikleri 16 farklı çeşide sahip granit verilerini destek vektör makineleri ile sınıflamaya çalışmışlardır. Spektrometreden ve renk metre yardımıyla elde edilen verilerle granit sınıflamasının yapıldığı diğer bir çalışma Prieto vd. (2008) tarafından gerçekleştirilmiştir (Araújo vd. 2010; Prieto vd. 2008).

Huang vd. (2016) 20 farklı çeşit granit görüntüsünü, gri seviye eş oluşum matrisleri, gabor filtreleri ve renk bilgisi olarak HSV renk alanından elde ettikleri öznitelikler ile birleştirerek destek vektör makineleri yardımı ile sınıflandırma işlemi gerçekleştirmişlerdir. Diğer çalışmalardan farklı olarak renk bilgisi, HSV renk uzayında ki her bir renk kanalının histogram bilgileri 16, 4, 4 olacak şekilde kuantalanarak birleştirip tek bir vektör haline getirmişlerdir (Huang vd. 2016).

Son zamanlarda Ferreira ve Girdali (2017) tarafından yapılan bir çalışma ise diđerlerinden farklılık göstermektedir. Çalışmada öznitelik mühendisliğini kullanarak renk ve yüzeye ilişkin öznitelikleri manuel olarak çıkarmak yerine bu özniteliklerin evrişimsel sinir ağıları (Convolutional Neural Network-CNN) kullanılarak otomatik olarak çıkarılması önerilmiştir. Yeni bir CNN ağı tasarlamak yerine daha önceden binlerce resimle eğitilmiş Mnist1, Mnist2, Mnist3 ve CIFAR CNN ağlarından yararlanılmış, bu ağların sınıflandırma katmanındaki önceki katmanlarından elde edilen öznitelikler çıkarmak amacıyla kullanılmıştır. Transfer öğrenme olarak adlandırılan bu yöntem sayesinde yeni bir ağı tasarlama ve oldukça uzun zaman alan ve birçok örneğe ihtiyaç duyulan ağı eğitime sorunun üstesinden gelinmiştir. Önceden eğitilen ve filtre parametreleri belirlenen bu ağlara uygun boyutlara granit resimleri uygulanarak öznitelikler elde edilmiştir. Çalışmada iki farklı sınıflama yaklaşımdan yararlanılmıştır. Birinci yaklaşımda her bir CNN den elde edilen öznitelikler birleştirilmiş, elde edilen birleştirilmiş öznitelik vektörü sınıflandırma işleminde kullanılmış, diđer yaklaşımda ise her bir CNN yardımıyla elde edilen öznitelikler farklı sınıflayıcılar ile birlikte kullanılmış ve nihai sınıf en çok oylama yöntemiyle belirlenmiştir. Önerilen yöntem literatürde kullanılan öznitelik çıkarmaya dayalı yöntemlere göre daha iyi sonuçlar vermiştir. CNN ağları ve çok sınıflı ayırma analizinin birlikte kullanıldığı diđer bir çalışma ise Filisbino vd. (2017) tarafından gerçekleştirilmiştir. Bianconi vd. (2015) ile aynı veri setini kullanan çalışmada CNN yardımıyla öznitelikler çıkarılarak bu öznitelikleri çok sınıflı ayırma analizinde kullanarak sınıflandırma işlemini gerçekleştirmişlerdir (Ferreira ve Girdali 2017; Filisbino vd. 2017).

Bu tez çalışmasında, Sivas ilinde faaliyet gösteren Beta Mermer A.Ş den elde edilen mermer fayansların bilgisayarlı görü yardımıyla otomatik olarak sınıflandırılması için bir sistem tasarlanması amaçlanmaktadır. Bu sistem mermer parçalarında ki renk ve desen farklılıklarını algılamakta ve mermer parçalarındaki farklılıkları algılama işleminde ise, parçaların yüzeylerine ait bilgilerin analiz edilmesi gerekmektedir. Yüzey analizi işlemlerinden sonra sınıflandırma işlemi uygulanarak mermer blokları ayırımı yapılmaktadır. Mermer fayanslara ilişkin farklı renk ve yüzey tanımlayıcılarının grafik sınıflandırmadaki performansı incelenmektedir.

Tez çalışmasının giriş kısmında doğal taşlar ve çeşitleri, kullanım alanları, ülkemizde ve dünyada doğal taş üretimine ilişkin genel bilgilere yer verilmiştir. Ardından sektörde kalite kontrol sürecinde karşılaşılan ve çözülmesi son derece karmaşık ve zor bir problem olan doğal taşların sınıflandırılması ve derecelendirilmesi konusu ele alınmıştır. Daha sonrasında ise problemin çözümü için literatür incelenerek, sunulan çözüm önerileri ve yaklaşımlara yer verilmiştir. Bölüm 2’de sınıflama öncesinde renk ve yüzey öznelik bilgisinin çıkarılmasına ilişkin yöntemler, Bölüm 3’te ise çalışmada kullanılan sınıflandırma algoritmaları ele alınmıştır. Bölüm 4’de önerilen yaklaşımların performansını karşılaştırmak için yapılan deneyler ve uygulamalara yer verilmiştir. Elde edilen sonuçlar Bölüm 5’de tartışılarak ileride yapılacak çalışmalar için önerilerde bulunulmuştur.



## BÖLÜM 2

### YÜZEY ve RENK ÖZİNİTELİKLERİNİN ÇIKARILMASI

Öznitelik bilgisi, temel olarak görüntüye ait gözlemlenebilir ve ölçülebilir bilgi şeklinde tanımlanmaktadır. Öznitelik çıkarımı ise görüntüde bulunan ilgisiz bilgilerin elenerek sadece ilgili özelliklerin belirlenmesi ve görüntüye ait karakteristik özelliklerin elde edilmesi işlemidir. Görüntü işleme uygulamalarında yüksek boyutlu veriler kullanıldığında bu verilerin işleme süreleri ve yüksek boyutların getirisi olarak ilgisiz bilgi miktarı da artmaktadır. Öznitelik çıkarım yöntemleri ile orijinal verilerde bulunan karakteristik özellikler korunarak daha küçük boyutlara indirgenmesi sağlanmaktadır (Alpaslan 2013).

Öznitelik çıkarım işlemi yapılacak olan sınıflandırma işleminin başarısını önemli derecede etkilemektedir. Doğru seçilmiş öznitelik değerleri, sadece ilgili ve karakteristik verilerden oluştuğu için sınıflandırma başarısını olumlu yönde etkilemektedir. Öznitelik çıkarımının genel amacı, sınıfa ait genel bilgileri daha küçük boyutlara taşıyarak doğru şekilde ilgili sınıfı temsil etmektir (Alpaslan 2013).

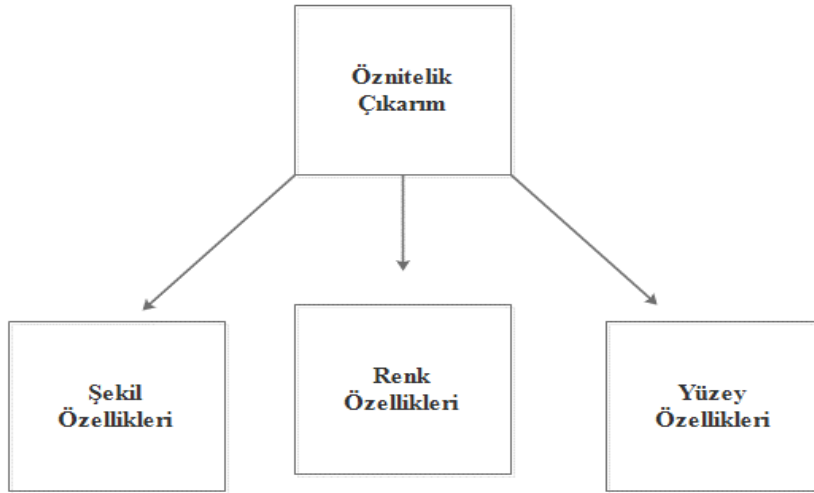
Görüntü tanıma ve sınıflandırma işleminde, farklı açılarda ve farklı ışık şiddetlerinde elde edilen görüntüden etkilenmeyecek öznitelik kümesinden oluşan öznitelik vektörlerine ihtiyaç duyulmaktadır. İşlenecek görüntülere dair bu tür problemleri aşmak için görüntünün yoğunluğa sahip olduğu bölgeleri kullanan bölgesel görüntü betimleyicileri oluşturulmaktadır. Görüntü yoğunluğuna sahip bölgeler, görüntünün gradyant vektörlerine, rengine, içerdiği desene veya bu bilgilerin birleşimine bağlı olarak belirlenmektedir (Kurt 2013).

Öznitelik çıkarım yöntemleri, düşük düzey öznitelik çıkarım ve yüksek düzey öznitelik çıkarım yöntemleri olarak iki gruba ayrılmaktadır. Düşük düzey öznitelik çıkarım yöntemleri nokta ve çizgi kenar köşesi gibi görüntüde ki küçük ayrıntılar üzerinde çalışmaktadır ve şekil bilgisi olmadan otomatik olarak çıkartılmaktadır. Yüksek düzey öznitelik çıkarım yöntemi ise görüntüde bulunan nesnelere ve daha



büyük şekilleri algılamak için düşük seviyeli öznitelik çıkarım yöntemlerinin geliştirilmesi ile oluşturulmuştur (Goel vd. 2017).

Görüntü sınıflandırma işleminde görüntü ayırt etme işlemi görüntülerin sahip oldukları yerel özellikler kullanılarak yapılmakta ve bu özellikler renk yoğunluğu, görüntüde bulunan nesnelere kenar uzantıları ve yüzeyleri gibi çeşitli anahtar parçalardan oluşmaktadır. Öznitelik çıkarım yöntemi verimliliğinin yüksek olması, görüntüler üzerinde yapılan eşleştirme ve desen tanıma gibi işlemleri geliştirmekte ve doğruluk oranını artırmaktadır. Görüntü eşleştirme ve desen tanıma çalışmalarında yüksek derecede doğruluk oranı ilgili bilgiden elde edileceği için öznitelik çıkarım işlemindeki verimliliğin yüksek olması gerekmektedir. Öznitelik çıkarmak için kullanılan çok fazla sayıda öznitelik çıkarım yöntemi bulunmaktadır. Öznitelik çıkarım yöntemleri öznitelik elde etmek için görüntüde bulunan nesnelere ait renk, yüzey ve şekil görüntü özellik bilgilerini kullanmaktadır. Öznitelik çıkarmak için kullanılan bu tekniklerin genel olarak sınıflandırılması Şekil 2.1’de gösterilmektedir (Goel vd. 2017).



**Şekil 2.1** Öznitelik Çıkarım Şekilleri

a. Renk ile ilgili öznitelik çıkarım

Görüntü öznitelik çıkarım işlemlerinde görüntüleri ayırt etmek için RGB, HSV, LUV ve HMMD gibi çeşitli renk alanları kullanılmaktadır. Görüntü

öznitelik çıkarımı için çeşitli teknikler uygulanmasına rağmen renk tabanlı öznitelik çıkarım işlemi görüntü öznitelik çıkarım işleminde önemli bir tekniktir (Pachouri, Barve 2015). Literatürde kullanılan çeşitli renk alanları Stanchev vd. (2003) tarafından ele alınmaktadır (Stanchev, Green Jr, Dimitrov 2003). Renkli, gri tonlu veya ikili görüntü olmak üzere görüntüler üç ana grup altında sınıflandırılmaktadır. Ayrıca görüntülerden öznitelik çıkarım için renk histogramları (Color Histogram), renk tutarlılık vektörü (Color Coherence Vector), renk momentleri (Color Moments) ve renk kordonu (Color Correlogram) yöntemleri de kullanılmaktadır. Bu yöntemler ise görüntü piksel yoğunluklarının ortalama, standart sapma ve çarpıklık değerlerinin çıkarılmasına dayanmaktadır (Goel vd. 2017).

b. Desen ile ilgili öznitelik çıkarım

Görüntülere ait desenlerden öznitelik çıkarım teknikleri ise kontur tabanlı ve bölge tabanlı yöntemler olmak üzere iki ana başlık altında incelenmektedir. Kontur tabanlı teknikler, görüntüye ait sadece sınır bilgilerinden çıkarılan öznitelikleri oluşturmakta iken bölge tabanlı yöntemler ise tüm görüntüyü oluşturan öznitelik bilgileri çıkartılmaktadır (Goel vd. 2017).

c. Yüzey ile ilgili öznitelik çıkarımı

Yüzey bilgisi, bilgisayar görü uygulamalarında işlenecek görüntülerde bulunan nesnelere belirlemek ve ayırt etmek için kullanılan önemli özelliklerden biridir (Hossain, Serikawa 2013). Yüzey bilgisi özelliklerini kullanmak için çeşitli yüzey analiz yöntemleri mevcuttur. Yüzey analiz yöntemleri istatistiksel, yapısal, model tabanlı ve dönüşüm tabanlı yöntemler olmak üzere dört kategoriye ayrılmaktadır. İstatistiksel yüzey analiz yöntemleri, gri seviye histogramlar yardımıyla görüntü bölgelerinde bulunan nesnelere yüzey bilgisini tanımlamaktadır (Bharati vd. 2004). Yapısal yüzey analiz yöntemleri ise bir takım yerleştirme kurallarına göre düzenlenmiş benzer görüntü doku hücrelerinin tespit edildiği yöntemlerdir (Zhang, Tan 2002). Model tabanlı yüzey analiz teknikleri, ilgili pikselin komşu piksel yoğunluklarının ağırlıklı ortalamasına dayalı olarak görüntüdeki her pikselin

deneysel modeli oluşturularak gerçekleştirilen yüzey analiz tekniğidir. Dönüşüm tabanlı yüzey analiz teknikleri ise görüntüyü piksel yoğunluğu çeşitlerinin konumsal frekans özelliklerini kullanarak yeni bir forma dönüştürmesiyle gerçekleştirilen yüzey analiz tekniğidir (Bharati vd. 2004).

Literatürde pek çok öznelik çıkarım tekniği bulunmaktadır. Öznelik çıkarım yöntemlerinin verimliliği tanıma problem türüne ve mevcut verilere bağlı olarak değişmektedir. Öznelik çıkarım yöntemlerinin performans karşılaştırması farklı veri setlerine ve farklı sınıflayıcılara bağlı olarak esnek ve değişken sonuçlar vereceği için bu karşılaştırma işlemi kolay bir işlem değildir (Trier vd. 1995).

Yüzeye ilişkin öznelikler genellikle gri seviyedeki renk kanallarına uygulanırken bazı çalışmalarda bu yöntemler ayrı ayrı renk kanallarına uygulanarak elde edilen öznelikler birleştirilmektedir. Yüzey bilgisine ilişkin öznelikleri çıkarmak amacıyla Gabor filtresi, Gri Seviye Eş Oluşum Matrisi, Dalgacık Dönüşümü, Yerel Faz Kuantalama ve Yerel İkili Örüntü öznelik çıkarım yöntemleri ele alınmıştır.

## 2.1 Gabor Filtresi

Gabor filtresi, bilgisayar görü alanında özellikle ışık değişimi ve gölge etkisi bulunan ortamlara ait görüntülerden öznelik çıkarım yöntemi olarak yaygın bir şekilde kullanılan bir tekniktir. Canlılarda ki görme sinirlerinin yönelim seçici ve uzaysal frekans özelliklerinden esinlenerek oluşturulmuştur. Filtre kullanılmasıyla görüntüde bulunan nesnelerin belirli bir yöne uzanan ayrıtları belirlenmektedir ve bu özelliğinden dolayı doku betimleme, tekstil kumaş hatası tespit etme, yüzey sınırlarını belirleme, yüzey görüntüsü bölütleme, ayrıştırma ve sınıflama çalışmalarında yaygın şekilde kullanılmaktadır (Çelik vd. 2012). Gaussian kernel fonksiyonu ile karmaşık sinüs dalgasının modülasyonu ile elde edilen bu dönüşüm mekânsal uzayda çalışmaktadır (Aygün vd. 2017).

Eşitlik 2.1'de Gabor dönüşümüne ait genel denklem verilmektedir.

$$g(x, y; \lambda, \theta, \sigma, \gamma) = \exp\left(-\frac{x'^2 + y'^2}{2\sigma^2}\right) \cdot \cos\left(2\pi \frac{x'}{\lambda}\right) \quad (2.1)$$
$$x' = x \cdot \cos \theta + y \sin \theta \quad y' = -x \cdot \sin \theta + y \cdot \cos \theta$$

Burada  $g$  gabor çekirdek fonksiyonunu temsil etmektedir.  $(x, y)$  piksel konumunu,  $\theta$  aranan örüntünün açısını,  $\lambda$  aranan örüntünün dalga boyunu,  $\sigma$  aranan örüntünün ölçeğini,  $\gamma$  ise gabor çekirdeğinin en boy oranını vermektedir. Uygun  $\theta$  değerleri ile çok sayıda gabor çekirdekleri elde edilecektir. Bu çekirdekler içerisinden maksimum olan seçilir ve etkin görüntü elde edilmektedir (Yavuz, Köse 2012).

İki boyutlu Gabor fonksiyonunun büyüklüğü kullanılarak  $N_S$  sayıda farklı ölçek değeri,  $N_O$  sayıda farklı döndürme açısı kullanılarak toplamda  $(N_S \times N_O)$  sayıda filtreden oluşan bir filtre bankası oluşturulmaktadır. Her bir filtre çıktısı vektör forma çevrilip uç uca eklenerek Gabor özneteliği elde edilmektedir. Elde edilen öznetelik vektörü çok yüksek boyutlarda ise aşağı örnekleme ya da boyut indirgeme teknikleri kullanılarak yüksek boyutsallık kurtarılabilir (Yavuz vd. 2013).

Gabor filtresi kullanılarak hesaplanan parametreler:

Gri seviye görüntülere ilişkin her bir Gabor filtre matrisinden elde edilen matris  $M \times N$  boyutlu  $I_{ij}$  matrisi olsun. Buna göre (Acar, Özerdem 2012):

- Ortalama

$$O_{ij} = \frac{1}{MN} \sum_i^M \sum_j^N I_{ij}$$

- Standart Sapma

$$S_{ij} = \frac{1}{MN} \sum_i^M \sum_j^N (I_{ij} - O_{ij})^2 I_{ij}$$


- Entropi

$$E_{ij} = - \sum_{i,j} I(i,j) \cdot \log(I_{ij})$$

## 2.2 Gri Seviye Eş Oluşum Matrisi (Gray Level Co-Occurance Matrix-GLCM)


GLCM, görüntülerde bulunan yüzeylere dair özellik çıkarma işleminde yoğun olarak kullanılan istatistiksel bir yöntemdir ve ilk olarak 1973 yılında Haralick tarafından önerilmektedir (Jiaoyan vd. 2004). Aralarında belirli bir uzaklık bulunan ve belirli bir yönü bulunan bir çift gri seviyeli pikselin birbirlerine göre oluşum sıklıklarını belirten matrislerdir (Güven vd. 2014). İlk piksel referans olarak ikinci piksel ise komşu piksel olarak kullanılmaktadır (Çalışkan, Ergen 2014).  $P(i, j | \theta, d)$  tahminine dayanmaktadır ve bu matris, pikseller arasında  $\theta$  açı değerine sahipken ve aralarındaki uzaklık  $d$  iken gri seviyesi  $i$ ' den gri seviyesi  $j$ ' ye geçme olasılığını ifade etmektedir (Cavalin, Oliveira 2017).

İlk adımda, görüntüde bulunan piksel değerlerinin  $\theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ$  doğrultularında ki birlikteliklerine bakılarak eş oluşum matrisleri oluşturulur ve eş oluşum matrisleri gri seviyeye indirilmiş görüntü için kare matristen oluşmaktadır (Kaynar vd. 2017).



Şekil 2.2 Piksel Değer Doğrultuları

Her bir  $d$  ve  $\theta$  değerleri için ayrı ayrı kare matris oluşturulmaktadır. Matris oluşturulurken öncelikli olarak  $G \times G$  boyutunda ( $G$  gri düzeyini belirtmektedir) bütün elemanları 0 olan bir matris oluşturulmaktadır. Görüntünün ilk pikselinden itibaren belirlenen yönde komşu iki piksel birlikte analiz edilir ve oluşturulan matriste satır numarası birinci piksel değeri, sütun numarası ikinci piksel değeri olan hücre 1 artırılarak tüm piksel değerleri bu şekilde incelenene kadar bu işlem devam eder ve böylece eş oluşum matrisi oluşturulur (Kaynar vd. 2017).



**Şekil 2.3** Eş Oluşum Matrisi

Eş oluşum matrisi oluşturulduktan sonra veri setinde özellik olarak kullanılmak üzere görüntüye dair zıtlık (kontrast) enerji, bağımlılık (correlation), ve homojenlik (homegeneity) değerleri hesaplanarak işlem sonlandırılmaktadır (Çalışkan, Ergen 2014).

Zıtlık (Kontrast): Komşu iki piksel arasındaki yoğunluk veya gri seviye varyasyonlarının ölçümü olarak tanımlanmaktadır. Zıtlık kavramı Eşitlik 2.2’de matematiksel olarak ifade edilmektedir.

$$\sum_{i,j} |i - j|^2 P(i, j) \quad (2.2)$$

Eşitlik 2.2’de kullanılan i ve j değerleri satır-sütun indislerini göstermektedir.

Enerji: Görüntünün homojenlik değeri olarak tanımlanmaktadır. Görüntü ne kadar homojen olur ise enerji değeri o kadar yüksek olur. Eşitlik 2.3’de matematiksel olarak tanımlaması yapılmaktadır.

$$\sum_{i,j} P(i, j)^2 \quad (2.3)$$

Bağımlılık (Correlation): Eş oluşum matrisi içerisinde gri seviye değerlerinin lineer bağımlılığını hesaplamaktadır. Aynı zamanda referans pikselin komşu piksel ile nasıl bir şekilde bağlantılı olduğunu göstermektedir.

$$\frac{\sum_{i,j} (ij) P - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (2.4)$$

Eşitlik 2.4’de P ifadesi indislerin karşılık geldiği gri seviye eş oluşum matris elemanını,  $\sigma$  standart sapmayı ve  $\mu$  ise ortalamayı göstermektedir.

Homojenlik: Görüntü içerisinde bulunan farklı bölgelerde ki benzerliklerin ölçüsüdür (Çalışkan, Ergen 2014). Eşitlik 2.5’de homojenlik kavramı matematiksel olarak ifade edilmektedir.

$$\sum_{i,j} \frac{P(i,j)}{1+|i-j|} \quad (2.5)$$

### 2.3 Dalgacık Dönüşümü (Wavelet Transform-DD)

Dalgacık Dönüşüm (DD) analiz uygulamaları bilim ve mühendislikte ilk olarak 1990' lı yıllarda kullanılmaya başlanmış ve günümüzde araştırmacıların sayısı hızlı bir şekilde artmaktadır (Addison 2002). DD yaklaşımını tanımlamadan önce Fourier yaklaşımı ele alınacak olursa, görüntü işleme çalışmalarında frekans ortamında gerçekleştirilen filtreleme tekniği olarak kullanılmaktadır. Bu yaklaşım, görüntüyü sinüs ve cosinüs parçalarına ayırmak için kullanılan görüntü işleme yöntemidir. Fourier yaklaşımında sadece frekans bilgisine yer verilmekte zaman bilgisi ise dikkate alınmamaktadır. Bu nedenle görüntüye dair tüm frekans değerleri bilinmekte fakat ilgili değerlerin hangi zaman dilimlerinde ulaşıldığına dair bilgi vermemektedir (Çelik vd. 2012).

DD, Fourier dönüşümünün yetersiz kaldığı bu noktada frekanslarının olduğu yer ve zamana dair daha ayrıntılı bilgi veren ve bölümlene tekniğine dayanan dönüşüm yöntemidir. DD, sinyalin hem zaman hem de frekans alanlarında incelenmesini kolaylaştıran bir dönüşümdür. DD işleminde ana dalgacık adı verilen sınırlı süreli, düzensiz ve asimetrik sinyal parçalarının farklı ölçeklerde ötelenmiş şekilleri kullanılmaktadır (Çelik vd. 2012).

DD için düşük frekans değerlerinde geniş, yüksek frekans değerlerinde dar olan değişken pencereleme boyutuna sahip olması bu dönüşümün en büyük avantajı olarak belirtilmektedir. Bu dönüşümün değişken pencereleme boyutuna sahip olması ise tüm frekans aralıklarında en iyi zaman-frekans çözünürlüğünü sağlamasına neden olmaktadır (Şengür vd. 2009).

DD son yıllarda işaret işleme, haberleşme, ekonomi ve imge işleme gibi farklı alanlarda öznitelik çıkarımı yöntemi olarak ayrıca imgelerin ve işaretlerin çok çözünürlüklü analizi için yoğun olarak kullanılan bir yöntemdir (Şengür vd. 2009).

DD, uygulama şekline göre sürekli ve ayrık dalgacık dönüşümü olmak üzere iki başlık altında ele alınmaktadır (Yıldız, Buldu 2017).





## 2.4 Yerel Faz Kuantalama (Local Phase Quantization-LPQ)

Yerel faz kuantalama (LPQ) yöntemi Ojansivu vd. tarafından mekânsal bulanıklaştırma yöntemi olarak sunulan ve görüntüye dair bilgileri analiz etmek için Fourier Dönüşümü'nü kullanan, sonuçların ise histogram olarak sunulduğu etkili ve yaygın olarak kullanılan yüzey tanımlayıcısıdır. Fourier faz spektrumunun bulanık değişmezlik özelliğine dayanmaktadır(Günay, Nabiyev 2016).

Yerel faz kuantalama değerleri resimlerin her bir pikseli için yerel komşuluk faz değerleri, Hızlı Fourier dönüşümü kullanılarak Eşitlik 2.6'da hesaplanmaktadır.

$$F(u, x) = \sum_{y \in N_x} f(x - y) e^{-j2\pi u^T y} = w_u^T f_x \quad (2.6)$$

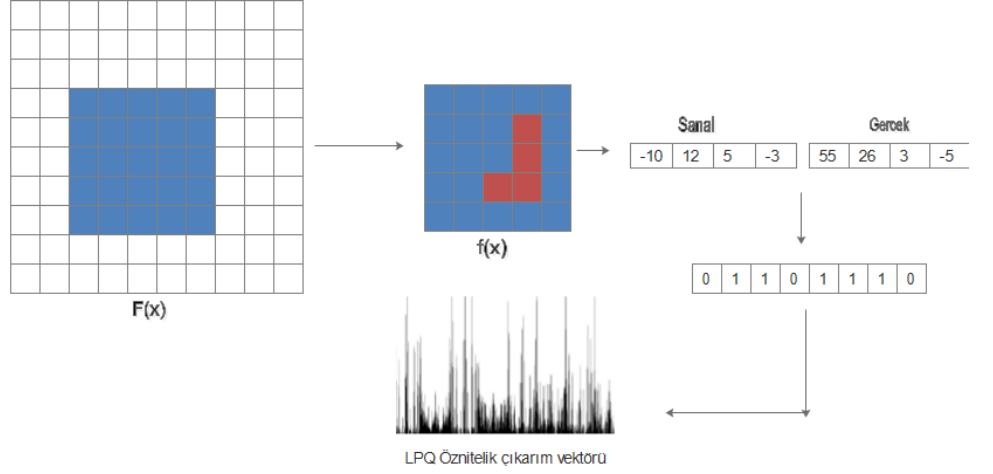
Eşitlik 2.6 da kullanılan  $x$ , merkez pikselin konumu;  $N_x$ , MxM boyutundaki yerel bölgenin komşu piksellerin koordinatlarını;  $w_u$  iki boyutlu Ayırık Fourier Dönüşümünün  $u$  frekansındaki temel vektörünü;  $f_x$  ise Fourier transformunu temsil etmektedir (Günay, Nabiyev 2016).

LPQ' da 2 boyutlu frekansa karşılık gelen sadece  $u_1=[a,0]^T$ ,  $u_2=[0,a]^T$ ,  $u_3=[a,a]^T$ ,  $u_4=[a,-a]^T$  nin oluşturduğu dört karmaşık (gerçek görüntü ve sanal görüntü) katsayı dikkate alınmıştır. Her piksel konumu için  $G_x$  vektör sonuçları elde edilmektedir ve ardından bu vektörler,

$$q_j = \begin{cases} 1, & g_j \geq 0 \\ 0, & \text{değilse} \end{cases} \quad (2.7)$$

ile kuantalanmaktadır. Eşitlik 2.7'de belirtilen  $g_j$ ,  $G_x$ ' in  $j$ . bileşenidir.

Fourier katsayılarında ki faz bilgisi, her bir bileşenin elde edilen vektör sonuçlarında ki gerçek ve sanal bölümlerin işaretlerini gözlemleyerek kaydedilmektedir. Bu işlem basit bir nicenlendirici kullanılarak gerçekleştirilmektedir. Ortaya çıkan nicelendirilmiş katsayılar 0-255 arasında tamsayı bir değer ile temsil edilmektedir. Elde edilen değerlerin histogramı öznitelik vektörü olarak kullanılmaktadır (Yuan vd. 2012; Günay, Nabiyev 2016; Isaac, Wilscy 2015).



Şekil 2.5 Yerel Faz Kuantalama

## 2.5 Yerel İkili Örüntü (Local Binary Pattern-LBP)

LBP ilk olarak 1990’lı yıllarda Ojala vd. tarafından tanıtılan istatistiksel analizlere dayanan güçlü bir yüzey özellik çıkarım yöntemidir (Zhou vd. 2013; Ojala vd. 1996). Algoritmanın ilk aşamasında imge öncelikle gri tonlu resim haline dönüştürülmektedir. Gri tonlu piksellerin yoğunlukları 3x3 boyutunda ki matrislerle ifade edilmekte ve merkez piksellerinde ki gri tonlu yoğunluk değeri alt sınır değeri olarak belirlenmektedir. Komşu matris değerleri de merkez pikselin değerine göre güncellenmektedir.

$$LBP_{P,R}(x_c, y_c) = \sum_{n=0}^{P-1} \delta(g_n - g_c) 2^n \quad (2.8)$$

Eşitlik 2.8 de  $g_c, (x_c, y_c)$  koordinat konumlarında merkez pikselin değeri iken  $g_n$  ise R,P genliğine sahip olan merkez piksel etrafındaki sekiz pikselden seçilen herhangi bir piksel olarak tanımlanmaktadır.  $\delta(.)$  işaret fonksiyonu ise Eşitlik 2.9 da ifade edilmektedir:

$$\delta(x) = \begin{cases} 1 & \text{if } x > 0, \\ 0 & \text{değilse} \end{cases} \quad (2.9)$$

Komşu pikselin yoğunluğu merkez pikselin yoğunluğuna eşit veya merkez pikselin yoğunluğundan büyük ise komşu pikselin yeni değeri ‘1’ olarak, değilse ‘0’ olarak güncellenmektedir. Komşuların bu ikili sayılarla ifade edilmiş yeni şeklinden

ikili sayılarla 8 bitlik sıralı bir sayı üretilmekte ve üretilen bu sayı ondalık sayıya dönüştürülerek merkez pikselin yeni değeri olarak atanmaktadır.



**Şekil 2.6** Yerel İkili Örüntü

Bu işlem resim üzerindeki tüm pikseller için uygulanmaktadır. Böylece her bir piksel için 0 ile n arasında değerler elde edilmekte ve her bir değerden kaç adet bulunduğu dair m boyutlu özellik vektörü çıkartılmaktadır. Makine öğrenmesi yöntemlerinde kullanılmak üzere algoritma sonlandırılmaktadır (Kaynar vd. 2017).

## BÖLÜM 3

### MAKİNE ÖĞRENMESİ VE SINIFLANDIRMA

Veri madenciliği büyük ölçekli veriler içerisinde önceden bilinmeyen anlamlı bilgileri üretme süreci olarak tanımlanmaktadır. Bu işlem veri tabanı yöntemi, istatistik teknikleri ve makine öğrenmesi gibi yöntemler kullanılarak gerçekleştirilmektedir (Albayrak, Yılmaz 2009).

Veri madenciliğinde amaç, analiz edilerek bilgi çıkarılması zor olan büyük veri yığınlarını analiz ederek anlamlı, gizli ve faydalı olabilecek bilgi çıkarmak; bu bilgileri içerisinde barındıran bir model oluşturarak yeni gelecek bir veri nesnesi hakkında yorum yapmayı ve bu veri hakkında tahminde bulunmayı sağlamaktır (Coşkun, Baykal 2011).

Makine öğrenmesi, verilen bir problemi ortamdaki edindiği bilgiye göre modelleyen yapay zekâ disiplininin bir alt dalıdır (Nizam, Akın 2014).

Makine öğrenmesi yöntemleri, veriden örüntü tespit etme ve akılcı karar verme için istatistik ve bilgisayarın hesaplama gücünden faydalanmaktadır. Makine öğrenmesi teknikleri sınıflandırma problemlerinde başarılı bir şekilde kullanılmaktadır (Kaya, Yıldız 2014).

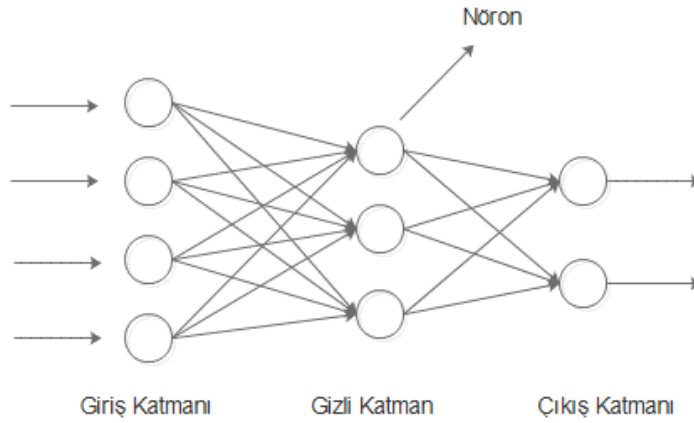
Makine öğrenmesi yöntemleri denetimsiz ve denetimli öğrenme olarak ikiye ayrılmaktadır. Denetimsiz öğrenmede, öğrenme sırasında algoritmaya örneklerin sınıfları hakkında bir bilgi verilmez. Denetimli öğrenmede ise örneklerle birlikte sınıfları da öğrenme algoritmasına verilir. Böylece, sınıflandırma işlemi sonucunda örneklere ait sınıflar tahmin edilerek yakalanan başarı oranı üzerinde fikir yürütülebilmektedir (Güner 2008).

Öznitelik çıkarım işlemleri tamamlandıktan sonra sınıflandırıcılar kullanılarak doğruluk oranları değerlendirilmektedir. Sınıflandırıcı bir örnekte bulunan çeşitli özellikleri alarak bu örneğin ait olduğu sınıfı tahmin etme işlemi yapmaktadır. Sınıflandırma işlemi için pek çok yöntem bulunmasından dolayı doğru sınıflandırıcıyı kullanma konusunda karar verme süreci zor bir işlemdir. Bu çalışmada Yapay Sinir Ağları (YSA), Naive Bayes, k – En Yakın Komşu (k-NN),

Destek Vektör Makineleri (SVM) ve Karar Ağaçları (KA) sınıflandırma yöntemleri ele alınmıştır.

### 3.1 Yapay Sinir Ağları (YSA)

Yapay Sinir Ağları (YSA), insan beyni dikkate alınarak oluşturulan bir makine öğrenmesi yöntemidir. Ağırlıklı bağlantılar ile birbirine bağlanan işlem elemanlarından oluşmaktadır. İşlem elemanlarının her biri kendi belleğine sahiptir. Bu işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarına YSA adı verilmektedir. Bir yapay sinir ağı, yapay sinir hücresi (nöron), bağlantılar ve öğrenme algoritması olmak üzere üç yapıdan oluşmaktadır. Nöronlar bir yapay sinir ağının temel işlem elemanlarıdır. Nöronların bağlantılar aracılığı ile bir araya geldikleri yapılar yapay sinir ağı sistemini oluşturmaktadır (Kaynar vd. 2017; Çuhadar, Kayacan 2005).



Şekil 3.1 Yapay Sinir Ağ Yapısı

Bir yapay sinir ağı: girdi katmanı, gizli katman ve çıkış katmanı olmak üzere üç katmandan oluşmaktadır. Girdi katmanı, dışardan gelen verilerin okunduğu katmandır. Her bir nöron bir parametre temsil etmektedir. Bu yüzden girdi katmanında özellik sayısı kadar nöron bulunmaktadır. Bir diğer katman gizli katmandır. Girdi katmanından aldıkları sinyalleri çıktı katmanına gönderme işlevi olan bu katman dış ortamdan bağlantısız şekilde işlem görmektedir. Gizli katmanda yer alacak nöron sayısı uzman tecrübesine bağlı olarak değişmektedir ve bu sayı sistemin performansı için önemlidir. Son olarak sınıfların belirlendiği katman olan

çıkı katmanı bulunmaktadır. Çıkı katmanı bilgilerin dışarıya aktarılması işlevini görmektedir (Kaynar vd. 2017; Çuhadar, Kayacan 2005).

Yapay sinir ağı sisteminde bilgiler, nöronlar arasında bulunan bağlantılara verilen ağırlık değerleri ile ağ yapısında dağınık bir şekilde saklanmaktadır. Yapay sinir ağlarında öğrenme işlevi, örnekler üzerinden eğitilerek yapılmaktadır. Danışmanlı ve danışmansız öğrenme olarak ikiye ayrılmaktadır. Danışmanlı öğrenmede, ağ sistemi kullanılmadan önce eğitilmelidir. Danışmansız öğrenme ise doğru çıkış verisine dair herhangi bir bilgisi olmayan ve giriş bilgisine göre örneklem oluşturan öğrenme modelidir (Kaynar vd. 2017; Çuhadar, Kayacan 2005).

### 3.2 Naive Bayes

Naive Bayes (NB) algoritması belirli bir veri kümesindeki değerlerin frekanslarını ve kombinasyonlarını dikkate alarak olasılık kümesini hesaplayan basit bir olasılıksal sınıflandırma yöntemidir. Bayes teoreminden türetilen bu yöntem, özniteliklerin olasılıksal dağılımlarına ve birbirlerine bağılıklarına dayalı olarak çalışmaktadır (Alver vd. 2015). Bayes Teoremi dikkate alındığında algoritma;

Veri setine ait elamanlardan oluşan sınıfların  $H_i$  ve bu sınıflara ait etiketlerin belirli olduğu varsayılmaktadır. Sınıf etiketleri özelliklerden oluşan vektörler ( $X$ ) ile temsil edilmektedir. Naive Bayes sınıflandırıcısı bir vektörün herhangi bir sınıfa ait olup olmadığını bulmak için tüm sınıflar içerisinde en yüksek ardışık olasılığına sahip değeri bulmaya çalışmaktadır.

$$P(H_i|X) = \frac{P(X|H_i) P(H_i)}{P(X)} \quad (3.1)$$

Eşitlik 3.1 de bulunan  $P(X|H_i) P(H_i)$  ifadesi en büyük değeri almalıdır.  $P(H_i)$  ifadesi,  $H_i$  sınıfındaki eleman sayısının, tüm eleman sayısına oranını temsil etmektedir. Sonuç olarak maksimum  $P(X|H_i) P(H_i)$  ifadesine sahip olan  $H_i$  sınıfını,  $X$  vektörünün sınıfı olarak seçmektedir (Kaynar vd. 2017).

Naive Bayes yöntemi, test edilecek olan veriye ait sınıfı tahmin etmek için Gauss dağılımlarından faydalanmakta ve Eşitlik 3.2 ve Eşitlik 3.3'de ifade edilen denklemler kullanılmaktadır.

$$g(x, \mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (3.2)$$

$$P(X|C_i) = g(x_k, \mu_{C_i}, \sigma_{C_i}) \quad (3.3)$$

Eşitlik 3.3'de  $\mu$  ortalamayı,  $\sigma$  standart sapmayı,  $x$  öznitelik ifadelerine karşılık gelmektedir.  $P(X|C_i)$  ise  $X$  özneliğinin  $C_i$  sınıfına ait olma olasılığını ifade etmektedir (Alver vd. 2015).

### 3.3 k En Yakın Komşu (k-Nearest Neighbour k-NN)

Sınıflama amacı ile kullanılan bir diğer teknik ise örneklem yolu ile öğrenmeye dayanan k-en yakın komşu algoritmasıdır. k-NN algoritmasında tüm örneklem bir örüntü uzayında saklanmaktadır. k-NN parametrik olmayan basit bir öğrenme algoritmasıdır. Algoritmanın parametrik olmaması temel veri dağılımında herhangi bir varsayım yapmaması avantajını sunmaktadır. Ayrıca k-NN tüm eğitim verilerini korumakta ve eğitim veri setine dayanarak karar vermektedir (Anchalia, Roy 2014). k-NN Algoritması, bilinmeyen bir örneklemin hangi sınıfa ait olduğunu belirlemek için örüntü uzayını inceleyerek bilinmeyen örnekleme en yakın olan k örneklemini bulur. Burada ki örnekleme yakınlık ve uzaklık değerleri genellikle Öklid tekniği ile hesaplanmaktadır. Bu teknik Minkowski ölçütünün özel parametrelerle ayarlanması ile elde edilmektedir.

Minkowski genelleştirilmiş bir mesafe hesaplama yöntemidir ve Eşitlik 3.3'de ifade edilmektedir;

$$D_{Min}(x, y) = (\sum_{i=1}^n |x_i - y_i|^p)^{\frac{1}{p}} \quad (3.3)$$

Minkowski hesaplama yönteminde p=2 değeri verilerek Öklid tekniği elde edilir ve matematiksel olarak;


$$D_{L2}(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (3.4)$$

Eşitlik 3.4'de belirtilmektedir (Emhan 2017).

Bu değerler hesaplandıktan sonra daha önce karşılaşılmayan örneklem, k en yakın komşu içerisinde en çok benzediği sınıfa atanmaktadır (Ayık vd. 2007).

### 3.4. Destek Vektör Makineleri (Support Vector Machine-SVM)

Destek Vektör Makineleri (SVM) Vapnik tarafından istatistiksel öğrenme teorisi ve yapısal riski en aza indirme ilkesine dayanan sınıflandırma problemlerinin çözümü amacıyla önerilmiştir (Ekici vd. 2009; Zhi-qiang vd. 2005). El yazımı ve parmak izi tanıma, ses tanıma ve resim tanıma gibi birçok alanda kullanılmaktadır (Türkoğlu, Hanbay 2015). Destek vektör makinelerinin ana amacı iki sınıfa ait verileri ayırabilecek en uygun hiper düzlemi belirlemektir (Kayaalti vd. 2010). Destek vektör makineleri, verilerin lineer olarak ayrılabilirliği ve lineer olarak ayrılamamaları şeklinde iki başlık altında incelenmektedir. Lineer olarak ayrılan verilerden maksimum sınıra bulunması oldukça kolay bir işlem olmasına rağmen, lineer olarak ayrılamayan verilerden maksimum sınıra bulunması için, verilerin lineer olarak ayrılabilirlikleri bir uzaya taşınması gerekmektedir (Atasever 2011).



Şekil 3.2 Lineer Olarak Ayrılabilen ve Ayrılamayan Nitelik Uzayı

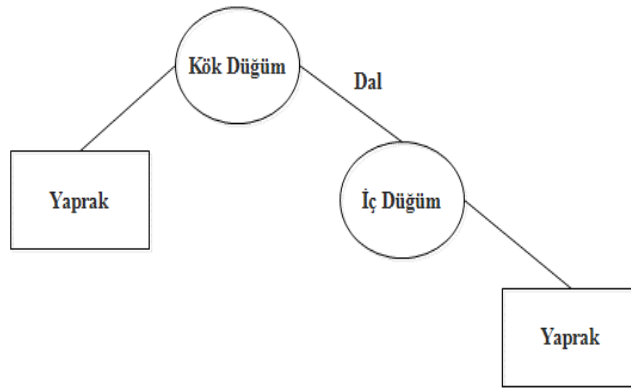
SVM'nin sahip olduğu algoritmalar ilk olarak iki sınıflı doğrusal verilerin problemi için tasarlanmış daha sonra çok sınıflı ve doğrusal olmayan verilerin sınıflandırılması için genelleştirilmiştir. Destek vektör makineleri, verileri iki veya daha çok sınıfa ayırmak için iki boyutlu uzayda doğrusal, üç boyutlu uzayda düzlemsel çok boyutlu uzayda ise hiper düzlem ayırma mekanizmalarını kullanan makine öğrenmesi yöntemidir. Çekirdek fonksiyonları ile kullanıldığında, farklı veri yapılarına uygulanacak normal forma göre daha iyi esneklik sağlamaktadır. Destek vektör makinelerinde ki amaç, hataların karesini en aza indirecek ayırıcı belirlemektir. Hatayı en az seviyeye indiren iki destek vektörü seçilerek bu düzlemler arasında ki uzaklık maksimum hale getirilmektedir. Bu iki vektörün orta noktasında



w vektörü seçilmekte ve daha sonra yeni x değeri için,  $y = w^t x + b$  işleminin sonuç değeri hesaplanarak verinin sınıfına karar verilmektedir. Burada w ifadesi ağırlık vektörünü, b skaleri de bir sapma değerini ifade etmektedir. Eğer bir veri setinde iki den fazla sınıf mevcut ise bire karşı bir veya bire karşı hepsi ayırım yöntemi kullanılarak çok sınıflı verilerin sınıflandırılması gerçekleştirilmektedir. Bu yöntemlerde farklı sınıf sayısı kadar ikili sınıflayıcı kullanılmaktadır. İlgilenilen sınıf etiketi 1, diğer tüm sınıflar -1 değeri ile etiketlenerek sınıflandırma işlemi yapılmaktadır. Elde edilen sonuçların hepsi birleştirilerek nihai sınıf bilgisi elde edilmektedir (Kaynar vd. 2017).

### 3.5 Karar Ağaçları (Decision Tree-KA)

Karar ağaçları (KA), güvenilirliğin yüksek olması ve yorumlanabilirliğin kolay olmasından dolayı veri sınıflandırma ve görüntü işleme işlemlerinde yaygın olarak kullanılan sınıflandırma yöntemidir. KA, sınıflandırma işlemlerinde ardışık veya çok aşamalı bir yaklaşım kullanmaktadır. Karmaşık bir sınıflandırma problemi aşamalı hale getirilerek basit hale dönüştürülmekte ve daha rahat bir karar verme işlemi gerçekleşmektedir. Karar ağaçlarının temel yapısı Şekil 3.3'de görüldüğü gibi düğümler, yaprak ve dallardan oluşmaktadır. Ağaç yapısında her bir öznelik bir düğüm tarafından temsil edilmektedir. Eğitim verilerine ait öznelik bilgilerinden yararlanılarak bir karar ağacı yapısı oluşturulmasında temel prensip, verilere ilişkin bir takım sorular sorulması ve bu sorulara verilen cevaplardan hareketle en kısa sürede sonuca gidilmesidir (Kavzoglu, Colkesen 2010).



Şekil 3.3 Karar Ağacı Örneği

Karar ağaçları uygulamasında iki aşamalı bir işlem yürütülmektedir. İlk aşamada, önceden oluşturulan bir eğitim veri seti, model oluşturmak için sınıflama algoritması tarafından analiz edilir. Bu aşama öğrenme aşaması olarak da adlandırılmaktadır. İlk aşamanın sonunda öğrenilen model, karar ağacına veya sınıflama kurallarına dönüştürülmektedir. İkinci aşamada ise bir test verisi sınıflama kurallarına veya karar ağacına uygulanarak doğruluk belirlenir, test örneklerinde belirlenen sınıf ile modelin tahmin ettiği sınıf karşılaştırılmaktadır. Eğer modelin doğruluğunun kabul oranı yüksek ise, oluşturulan kurallar yeni verilerin sınıflandırılmasında kullanılabilir (Özkes 2003). Karar ağaçlarının oluşturulmasında ki en önemli adımlardan biri hangi öznitelik değerlerine göre ağaç yapısının belirleneceğidir. Bu problemi çözmek için Quinlan tarafından bilgi kazanç oranı yaklaşımı önerilmiştir (Quinlan 2014). Bu yaklaşıma göre hangi öznitelige göre dallanmanın yapılacağına karar vermek için entropi kurallarını içeren bilgi teorisi kullanılmıştır. Entropi, sistemdeki belirsizlik veya düzensizliğin ölçüsü olarak tanımlanmaktadır.

Bir veri setinin  $C_1, C_2, \dots, C_n$  şeklinde sınıflardan oluştuğu ve  $T$ 'nin sınıf değerlerini gösterdiği kabul edilsin,

Olasılık değeri;

$$P_i = (C_i/|T|) \quad (3.5)$$

şeklinde Eşitlik 3.5'de hesaplanmaktadır.

Entropi değeri;

$$Entropi(T) = -\sum_{i=1}^n p_i \log_2(p_i) \quad (3.6)$$

Eşitlik 3.6'de tanımlanmaktadır.

Veri setindeki  $B$  öznitelğine göre  $T$  sınıf değerleri  $T_1, T_2, \dots, T_n$  şeklinde alt kümelere ayrılmaktadır. Bu öznitelik değerleri kullanılarak  $T$  sınıf değerlerinin bölünmesi sonucunda elde edilecek kazanç,

$$Kazanç(B, T) = Entropi(T) - \sum_{i=1}^n \frac{|T_i|}{|T|} Entropi(T_i) \quad (3.7)$$

Eşitlik 3.7'de hesaplanmaktadır.

T kümesi için B özneliğinin değerinin belirlenmesinde bölümlene bilgi kullanılmakta ve B ifadesi,

$$\text{Bölümlene Bilgisi (B)} = - \sum_{i=1}^k \frac{|T_i|}{|T|} \log_2 \left\{ \frac{|T_i|}{|T|} \right\} \quad (3.8)$$

şeklinde hesaplanmaktadır.

Bu durumda kazanç oranı,

$$\text{Kazanç Oranı} = \frac{\text{Kazanç(B,T)}}{\text{Bölünme Bilgisi(B)}} \quad (3.9)$$

şeklinde Eşitlik 3.9'de hesaplanmakta ve Kazanç oranı, sınıflandırma işleminde kullanılacak ayırma ile elde edilen bilgi oranını vermektedir (Kavzoglu, Colkesen 2010).

## BÖLÜM 4

### VERİ SETİ ve UYGULAMA


#### 4.1 Doğal Taş Karolarına Ait Verilerin Elde Edilmesi

Bu çalışmada kullanılan doğal taş mermer veri seti Sivas bölgesinde üretim yapan Beta Mermer A.Ş. şirketi tarafından çıkarılan doğal taş mermerlere ait resimlerden oluşmaktadır. Çalışmada 3 farklı renk ve 2 kalite grubundan oluşan toplam altı sınıfa ait doğal taş karoları üzerinde sınıflandırma işlemi gerçekleştirilmiştir. Renk ve doku bilgilerine bağlı olarak seçici uzmanlar tarafından etiketlenerek oluşturulan bu altı sınıf Beyaz1, Beyaz2, Medium1, Medium2, Wanlut1 ve Wanlut2 şeklindedir.

Beta Mermer A.Ş. şirketi tarafından üretilen mermer karolarına ait görüntüler 1024x1024 formatında olup, ışık oranı değişmeyen bir ortamda farklı açıdan kaynaklanacak parlaklık ve rotasyon problemlerini önlemek amacıyla sabitlenmiş bir kamera yardımıyla elde edilmiştir. Toplam 996 görüntüden oluşan veri setinin sınıflara göre dağılımı Tablo 4.1’ de ve her sınıftan bir karo örneği ise Şekil 4.1’de verilmiştir.

**Tablo 4.1** Kullanılan Mermer Çeşit ve Örnek Sayıları

Mermer Çeşit	Örnek sayısı (N)
Beyaz1	227
Beyaz2	87
Medium1	176
Medium2	170
Wanlut1	199
Wanlut2	137



**Şekil 4.1** Sınıflandırılan Doğal Taş Grupları; (a): 1.sınıf kalite beyaz mermer (b): 2.sınıf kalite beyaz mermer (c): 1.sınıf kalite medium mermer (d): 2.sınıf kalite medium mermer (e): 1.sınıf kalite wanlut mermer (d): 2.sınıf kalite wanlut mermer

#### **4.2 Desen ve Renge İlişkin Özniteliklerin Elde Edilmesi**

Çalışmada ilk olarak kamera aracılığı ile üretim tesisinde bulunan ürünlerin görüntüleri alınmıştır. Resimlerde herhangi gürültü ve bozulma gibi sorunlar olmadığından herhangi bir ön işleme yöntemine gerek duyulmamıştır. Ardından veri setine Bölüm 2’ de tanımlanan öznitelik çıkarım teknikleri uygulanarak yüzey desen ve renk bilgisine ilişkin öznitelikler elde edilmiştir. Yüzeyle ait desen bilgileri genellikle gri resimler üzerinden elde edilirken renge ilişkin öznitelikler RGB ve HSV renk uzayında her bir renk kanalından hesaplanan çeşitli istatistikler yardımıyla oluşturulmuştur.

Desene ilişkin özniteliklerin çıkarılması için GLCM, LBP, Gabor, LPQ ve Dalgacık dönüşümlerinden yararlanılmıştır.

GLCM yönteminde gri seviyeye dönüştürülmüş resimlere komşuluk uzaklığı  $d=1$  alınarak  $\theta=0^\circ, 45^\circ, 90^\circ, 135^\circ$  yönlerinde eş oluşum matrisleri elde edilmiştir. Daha sonra elde edilen bu matrisler yardımıyla enerji (energy), ilişki (correlation), homojenlik (homegenity) ve zıtlık (contrast) değerleri hesaplanarak her bir yön için 4

farklı öznitelik elde edilmiştir. 4 farklı yönde bulunan eş oluşum matrisleri için toplam 16 adet öznitelik kullanılmıştır.

LBP yönteminde gri seviyedeki resimler piksel yarıçapı  $r=1$ , pencere boyutu  $3 \times 3$  olarak belirlenmiş ve 8 bitlik döndürme yönünden bağımsız 10 adet öznitelik elde edilmiştir.

Gabor filtre öznitelik çıkarım yönteminde ise gri seviyedeki görüntü ve Gabor dalgacıği evriştirilerek filtrelenmiş görüntü elde edildikten sonra, filtrelenmiş görüntünün ortalama değeri, standart sapması ve entropisi öznitelik olarak hesaplanır. Daha sonra, öklid metriği kullanılarak veri tabanındaki görüntülerle birlikte hangi sınıfa ait olduğu araştırılır. Her bir görüntü için  $[4 \ 16]$  aralığında 4 er olacak şekilde artan dalga boyu ve  $[0 \ 90]$  derece aralığında 10 ar artan şekilde dereceler kullanılmıştır. Bu şekilde sadece doku bilgisi için 120 adet öznitelik değeri elde edilmiştir.

Görüntü LPQ tanımlayıcılarını oluşturmak için birleştirilmiş olan ayrık dikdörtgen alt bölgelere ayrılmıştır. Bu çalışmada yapılan tüm deneylerde görüntüde bulunan her bir pikselin pencere boyutu  $M = 10$  olarak değerlendirilen  $10 \times 10$  komşuluğu dikkate alınmış ve piksel yarıçapı  $r = 3$  olarak ayarlanmıştır. Toplam 256 adet öznitelik değeri elde edilmiştir.

Dalgacık dönüşümünün kullanıldığı öznitelik çıkarma işleminde çok seviyeli dalgacık dönüşümü analizinden (MRWA-Multi Resolution Wavelet Analysis) yararlanmıştır. 2 seviyeli dalgacık dönüşümünün kullanıldığı yöntemde, resimlere 2 boyutta Haar dalgacık dönüşümü uygulanarak her seviye için düşük frekanslı bileşenleri içeren yaklaşık matrisi ve yüksek frekanslı bileşenleri içeren yatay, dikey ve diagonal olmak üzere üç adet detay matrisler elde edilmiştir. Matrislerden elde edilen enerji fonksiyonları ( $E_a$ ,  $E_h$ ,  $E_v$ ,  $E_d$ ) yardımıyla toplamda dört adet enerji değeri elde edilmiştir. Her bir seviyedeki matrislere ilişkin enerji fonksiyonları yardımıyla toplam yetmiş beş adet öznitelik elde edilmiştir. Desene ilişkin öznitelik çıkarım yöntemleriyle elde edilen öznitelik sayıları Tablo 4.2' de verilmiştir.

**Tablo 4.2** Desene İlişkin Öznitelikler ve Renk Alanları

Öznitelik Çıkarım Yöntemi	Renk Uzayı	Öznitelik Sayıları
<b>Gabor</b>	Gri	120
<b>Glem</b>	Gri	16
<b>Lbp</b>	Gri	10
<b>Lpq</b>	Gri	256
<b>Wavelet</b>	RGB	75

Renklere ilişkin öznitelik çıkarmak amacıyla RGB ve HSV renk uzaylarında çeşitli istatistikler yardımıyla öznitelikler elde edilmiştir. RGB renk uzayı kırmızı, yeşil ve mavi olmak üzere üç renkten oluşmaktadır. Doğadaki her hangi bir renk bu üç rengin farklı oranlarda birleşmesinden meydana gelmektedir. HSV renk uzayı ise RGB renk uzayına doğrusal dönüşümler uygulanarak elde edilmiş şeklidir. HSV (Hue, Saturation, Value) renk uzayında ise renkleri sırasıyla renk özü, doygunluk ve parlaklık olarak tanımlamaktadır. Renk özü, mavi, sarı, yeşil vb. gibi rengin baskın dalga uzunluğunu belirlemektedir.  $0^{\circ}$  ile  $360^{\circ}$  dereceleri arasında açısal bir değer almaktadır. Doymunluk değeri, rengin canlılığını belirlemektedir. Yüksek doymunluk değerleri canlı renkler oluşmasına neden olurken, düşük olasılık değerleri ise rengin gri tonlarına yaklaşmasına neden olmakta ve 0-100 arasında değer almaktadır. Parlaklık değeri, rengin aydınlığını yani içindeki beyaz oranını belirlemektedir. Doymunluk değeri gibi parlaklık değeri de 0 ile 100 arasında değer almaktadır (Dipova, 2018).

RGB ve HSV renk uzaylarından elde edilen öznitelikler iki gruba ayrılmıştır. 1. grupta renk öznitelikleri olarak ortalama, standart sapma ve çarpıklık değerlerini gösteren momentler kullanılırken 2. grupta 25, 50, 75' lik yüzdilik değerini gösteren istatistiklerden yararlanılmıştır. Renklere ilişkin öznitelikler Tablo 4.3' te verilmiştir.

**Tablo 4.3** Renge İlişkin Öznitelikler

	RGB			HSV			Toplam
	R	G	B	H	S	V	
RGB_M_STD_Skew	3	3	3	-	-	-	9
RGB_PER_25_50_75	3	3	3	-	-	-	9
HSV_M_STD_Skew	-	-	-	3	3	3	9
HSV_PER_25_50_75	-	-	-	3	3	3	9

Desen ve renk bilgilerine ilişkin öznitelikler yardımıyla çeşitli veri setleri oluşturularak Bölüm 3’ de detayları verilen sınıflama algoritmaları yardımıyla deneyler gerçekleştirilmiştir. Genel olarak veri setlerini iki grupta toplamak mümkündür. 1. grupta sadece desen bilgisinin yer aldığı özniteliklerden oluşan veri setleri, 2. grupta ise desen ve renk bilgisinden elde edilen özniteliklerin çaprazlanarak birleştirilmesi sonucunda elde edilen veri setleri yer almaktadır.

### 4.3 Sınıflandırma Yöntemlerinin Uygulanması

Oluşturulan veri setlerinin sınıflandırma başarımını karşılaştırmak için Yapay Sinir Ağları, Destek Vektör Makineleri, k En Yakın Komşu, Karar Ağaçları ve Naive Bayes sınıflandırma algoritmaları kullanılmıştır.

Tüm sınıflayıcılar için 5 katlı çapraz doğrulama yöntemi uygulanarak veri seti 5 eşit parçaya bölünmüştür. Her seferinde ilgili veri setinin farklı bir %20’lik kısmı test için, kalan %80’lik kısım ise eğitim için kullanılmıştır. 5’er kez çalıştırılan sınıflayıcılar için ortalama başarı oranları ve standart sapmaları elde edilmiştir.

Sınıflayıcıların performansını etkileyen unsurlardan biri de parametrelerinin doğru olarak belirlenmesidir. Yapay sinir ağlarında 3 katmandan oluşan ileri beslemeli bir ağ yapısı kullanılmıştır. Ağın çıkış katmanı sayısı sınıf sayısına eşit olacak şekilde 6 olarak belirlenmiş giriş katmanındaki nöron sayısı ise kullanılan veri setindeki öznitelik sayısına eşitlenmiştir. Gizli katmandaki nöron sayısı ise çeşitli denemeler sonucunda 10 olacak şekilde tespit edilmiştir. Ağın eğitiminde geri yayılım algoritması kullanılmış, iterasyon sayısı 1000 öğrenme oranı 0.005 ve momentum katsayısı 0.9 olacak şekilde ayarlanmıştır. Ayrıca ağın aşırı öğrenmesini engellemek için eğitim veri setinin %20 lik kısmı doğrulama amacıyla kullanılmıştır.



SVM algoritmasında ise C ceza katsayısı ve epsilon parametresi ile çekirdek fonksiyonun belirlenmesi sınıflayıcının performansını belirleyen önemli parametrelerdir. C değeri tüm eğitim veri setlerinin dağılımı dikkate alınarak bu veri setlerindeki minimum ve maksimum değerleri de dikkate alacak şekilde 1 olarak belirlenmiş epsilon değeri ise  $[2^{-5}, 2^{-4} \dots, 2^1]$  olacak şekilde değiştirilerek çeşitli deneyler yapılmıştır. Deneylerde çekirdek fonksiyonu olarak lineer, rbf gibi çekirdek fonksiyonları kullanılmış, deneyler sonucunda SVM parametreleri sırayla C=1, epsilon=0.002, çekirdek fonksiyon=rbf olacak şekilde tespit edilmiştir.

k en yakın komşu algoritması kullanılarak yapılan sınıflandırma işleminde ağırlıklandırılmış k-NN algoritması kullanılmıştır. En uygun k sayısının tespit edilmesi için k değeri 1 ile 20 arasında değiştirilerek çeşitli deneyler gerçekleştirilmiş sonuçta en uygun k değeri olarak 10 belirlenmiştir. Komşulukların hesaplanmasında uzaklık hesaplama kriteri olarak da Öklid uzaklığı kullanılmıştır.

Karar ağacı algoritmasında en önemli adımlardan biri dallanma kriterini veya hangi öznelik değerine göre ağaç yapısının oluşturulacağını belirlenmesidir. Bu belirleme işlemi için Bilgi kazancı, Gini indeksi, Ki-Kare olasılık tablo istatistiği ve Towing kuralı gibi yaklaşımlar kullanılmaktadır (Kavzoglu ve Colkesen 2010). Bu çalışmada ağaç türü olarak Medium Tree, dallanma kriteri olarak Gini indeksi ve maksimum dallanma sayısı ise 20 olarak tanımlanmıştır.

Naïve Bayes sınıflandırma algoritması test edilecek veriye ait olan sınıfı tahmin etmek için Gaussian dağılımını kullanmaktadır.

Sadece desen bilgisinin öznelik olarak kullanıldığı veri setleri üzerinde gerçekleştirilen sınıflama işlemlerine ilişkin sonuçlar Tablo 4.4'de verilmiştir.

**Tablo 4.4** Sadece Desen Bilgisinin Bulunduğu Veri Setlerine İlişkin Sınıflandırma Sonuçları

	KA (%)	SVM (%)	K-NN (%)	YSA (%)	NAİVE (%)
GABOR	59.0	70.6	60.3	<b>72.0</b>	52.1
GLCM	50.3	72.6	53.3	<b>73.1</b>	47.2
LBP	58.2	70.2	65.2	<b>70.4</b>	56.4
LPQ	66.9	88.1	73.5	<b>89.3</b>	58.9
WAVELET	64.4	78.8	65.5	<b>78.9</b>	57.3

Tablo 4.4'den de görüleceği üzere öznitelik çıkarım yönteminden bağımsız olarak tüm sınıflama yöntemleri içerisinde en başarılı sonuçlar Yapay Sinir Ağları'ndan elde edilmiştir. SVM sınıflayıcıdan elde edilen başarımların YSA sınıflayıcının başarımlarına oldukça yakındır. YSA ve SVM arasındaki doğruluk oranlarındaki en büyük fark %1.4'lük Gabor Filtreleri öznitelik çıkarım yönteminde edilmiştir. Diğer yöntemlerde bu fark daha da düşüktür. Örneğin Wavelet öznitelik çıkarım yönteminden elde edilen veri setinde YSA ve SVM arasındaki fark sadece %0.1'dir. Bu sonuçlar göstermektedir ki her iki sınıflayıcı da başarılı şekilde granit karolarının sınıflandırmasında bir birlerinin yerine kullanılabilir. k En Yakın Komşu ve Naïve Bayes sınıflayıcılar YSA ve SVM sınıflayıcılara oranla daha düşük başarımlarına sahiptirler.

Tablo 4.4 öznitelik çıkarım yöntemleri açısından ele alındığında en yüksek başarımların LPQ yöntemiyle elde edilen veri setinde gözlemlenmiştir. Yüksek başarımların elde edildiği diğer bir öznitelik çıkarım yöntemi ise Wavelet yöntemidir. LBP, GLCM ve Gabor öznitelik çıkarım yöntemleri sadece YSA ve SVM sınıflayıcılar da %72'ler civarında yüksek başarımlar elde ederken diğer sınıflayıcılar için bu öznitelik çıkarım yöntemleri %50 civarında değerler olarak düşük başarımlar sergilemişlerdir.

Desene ait 5 farklı yöntem ve renge ait 4 farklı öznitelik çıkarım yönteminden elde edilen özniteliklerin çaprazlanarak birleştirilmesi neticesinde  $5 \times 4 = 20$  farklı veri seti oluşturulmuştur. Sınıflama algoritmalarının bu veri setlerine uygulanmasıyla elde edilen sonuçlar Tablo 4.5' de özetlenmiştir.

**Tablo 4.5** Renk ve Desen Özniteliklerinin Birlikte Kullanıldığı Veri Setlerinden Elde Edilen Sınıflandırma Sonuçları

	KA (%)	SVM (%)	K-NN (%)	YSA (%)	NAİVE (%)
<i>GABOR_HSV_M_STD_SKEW</i>	67.0	80.6	70.6	<b>80.7</b>	63.2
<i>GABOR_RGB_M_STD_SKEW</i>	63.6	76.4	67.8	<b>76.8</b>	60.7
<i>GABOR_HSV_PER_25_50_75</i>	67.0	78.0	69.8	<b>79.6</b>	61.3
<i>GABOR_RGB_PER_25_50_75</i>	64.7	76.7	69.5	<b>79.3</b>	57.1
<i>LBP_HSV_M_STD_SKEW</i>	66.8	<b>80.7</b>	73.0	76.9	67.5
<i>LBP_RGB_M_STD_SKEW</i>	64.5	<b>73.8</b>	68.8	68.9	60.1
<i>LBP_HSV_PER_25_50_75</i>	65.6	<b>74.6</b>	68.6	68.7	63.3
<i>LBP_RGB_PER_25_50_75</i>	65.8	<b>75.5</b>	70.1	74.6	65.3
<i>GLCM_HSV_M_STD_SKEW</i>	66.7	78.0	69.5	<b>78.5</b>	62.1
<i>GLCM_RGB_M_STD_SKEW</i>	58.4	71.9	61.9	<b>73.5</b>	59.1
<i>GLCM_HSV_PER_25_50_75</i>	65.2	72.2	64.6	<b>72.3</b>	61.2
<i>GLCM_RGB_PER_25_50_75</i>	59.9	74.7	65.3	<b>75.9</b>	60.8
<i>WAVELET_HSV_M_STD_SKEW</i>	67.2	<b>82.8</b>	72.5	82.2	65.0
<i>WAVELET_RGB_M_STD_SKEW</i>	64.3	<b>78.1</b>	69.5	78.0	64.7
<i>WAVELET_HSV_PER_25_50_75</i>	66.4	<b>79.4</b>	70.2	79.1	65.3
<i>WAVELET_RGB_PER_25_50_75</i>	64.6	<b>80.6</b>	68.9	80.1	60.8
<i>LPQ_HSV_M_STD_SKEW</i>	71.2	90.2	76.2	<b>92.0</b>	62.9
<i>LPQ_RGB_M_STD_SKEW</i>	69.8	88.7	74.9	<b>91.4</b>	62.7
<i>LPQ_HSV_PER_25_50_75</i>	70.3	89.4	75.2	<b>91.3</b>	62.3
<i>LPQ_RGB_PER_25_50_75</i>	68.0	89.7	74.8	<b>91.3</b>	60.5

Tablo 4.4 ve Tablo 4.5 karşılaştırıldığında renk bilgisinin desen öznitelikleriyle birleştirildiği tüm veri setleri, sadece desen bilgisinin kullanıldığı veri setlerine oranla daha yüksek sınıflama başarımı elde edilmiştir. Bu durum göstermektedir ki kullanılan desen öznitelik çıkarma yönteminden bağımsız olarak renk bilgisinde eklenmesi sınıflandırma başarısını artıran bir durumdur. Tablo 4.5’de görüleceği üzere yine en yüksek başarımlar YSA ve SVM sınıflayıcılardan elde edilmiştir. Her bir öznitelik çıkarım yöntemi için YSA ve SVM sınıflayıcıları renk bilgisinden bağımsız olarak ilgili grupta en yüksek başarımları veren sınıflayıcılar olmuşlardır.

Renk bilgisinin eklenmesiyle başarımlar önemli derecede artmıştır. Öyle ki LPQ desen öznitelikleriyle renk bilgisinin birleştirildiği veri setlerinde YSA

sınıflayıcı %90 üzerinde bir doğru sınıflama performansı gösterirken, aynı veri setleri için SVM'den elde edilen başarı oranları %89 civarına yükselmiştir. LPQ öznitelik çıkarım yöntemine eklenen renk bilgileri içerisinde en yüksek başarı ise HSV kanalından elde edilen momentlere ilişkin özniteliklerin eklenmesiyle oluşturulan LPQ\_HSV\_M\_STD\_SKEW veri setinde gözlenmiştir.

Benzer durumlar Gabor, LBP ve GLCM veri seti gruplarında da gözlemlenmiştir. HSV kanalından momentler yardımıyla elde edilen renk bilgisine sahip veri setleri diğer renk bilgisinin elde edildiği yöntemlerden daha yüksek performans göstermiştir. Bu durum bir tek Wavelet veri seti grubunda farklılık göstermektedir. Bunun nedeni desen bilgisi çıkarmak üzere kullanılan Wavelet yönteminin gri seviye resimlere uygulamak yerine RGB kanalındaki her bir renk kanalına uygulanmasından kaynaklanmaktadır. Ekstradan renk özelliklerinin Wavelet yöntemiyle çıkarılan desen öznitelikleriyle birleştirilmesi performans açısından çok büyük artışlara neden olmamıştır.

Renk bilgisinin eklendiği durumdaki sınıflama işlemlerinde en düşük değerler yine Naïve Bayes ve Karar Ağaçları'nda gözlemlenmiştir. k-NN sınıflayıcısı çoğu durumda bu iki sınıflayıcıdan iyi YSA ve SVM sınıflayıcılarından daha düşük başarı göstermiştir.



## BÖLÜM 5

### SONUÇ

Doğal taş sektöründe üretilen ürünlerin kalite, renk ve desen açısından sınıflandırılması, çözülmesi gereken önemli problemlerden birini oluşturmaktadır. Geleneksel üretim yöntemlerinde sınıflandırma işlemi, yüzey şekillerine, renklerine, barındırdıkları delik ve çatlak gibi kusurlarına göre karar veren seleksiyon işçileri tarafından göz yardımıyla yapılmakta ve bu işlem tamamen çalışanların öznel değerlendirmelerine göre gerçekleştirilmektedir. Fakat uzun süreli çalışmanın getirmiş olduğu yorgunluk ve dikkatsizlik yanlış kararlar verilmesine sebep olmaktadır. Bu nedenle sağlıklı bir sınıflandırma işlemi yapılamamakta ve her zaman aynı kaliteyi yakalamak mümkün olmamaktadır. Bu durum satıcılarla alıcılar arasında sorunlar yaşanmasına, iade partilerin oluşmasına, müşteri kaybına kadar varan bir dizi sorunun oluşmasına ve sonuçta büyük ekonomik kayıplara neden olmaktadır. Bu sorunlar bilgisayar destekli görü yardımıyla oluşturulacak otomatik sınıflandırma yapan makineler ve robotik sistemlerin geliştirilmesi ile ortadan kaldırılabilecektir.

Bu tez çalışmasında ise otomatik olarak sınıflayan sistemlerin ve cihazların oluşturulmasında önemli bir aşama olan görüntü işleme teknikleri ve makine öğrenmesi teknikleri ile doğal taşların sınıflandırılması problemi ele alınmıştır. Bu amaçla Beta Mermer A.Ş. tarafından Sivas bölgesinde çıkarılarak üretimi gerçekleştirilen doğal taş karoları üzerinde çeşitli çalışmalar yapılmıştır.

Farklı desen ve renklere sahip doğal taş karolarına ait resimleri sınıflamak amacıyla öncelikle farklı yöntemler kullanılarak desen ve renk bilgisi içeren öznitelikler elde edilmiş daha sonra çeşitli makine öğrenmesi teknikleri yardımıyla sınıflandırma işlemleri gerçekleştirilmiştir.

Desene ait özniteliklerin çıkarılmasında 5 farklı yöntem (LBP, GLCM, LPQ, Wavelet ve Gabor), renk bilgisine ait öznitelikler içinse 2 farklı renk uzayına (RGB, HSV) ait renk kanallarından momentler (ortalama, standart sapma, çarpıklık) ve yüzdelikler (%25, %50,%75) yardımıyla istatistikler hesaplanmıştır. Az sayıda ve

ayrıt ediciliği yüksek öznitelikler, hem işlem zamanını hem de sınıflayıcı başarımını olumlu yönde etkileyen önemli unsurlardan birini oluşturduğundan mümkün olduğunca az sayıda ve ayrıt ediciliği yüksek özniteliklerin belirlenmesine çalışılmıştır. Böylece renkli yüzeye sahip doğal taş karoları için sınırlı sayıda öznitelik ile başarılı bir sınıflandırma doğruluğu sağlayan bir dizi görsel tanımlayıcı önerilmiştir. Renk ve desene ilişkin öznitelikler elde edildikten sonra çeşitli veri setleri oluşturulmuştur. Genel olarak bu veri setleri iki grupta ele alınmış ve sınıflandırma işlemleri bu iki grup veri seti üzerinde gerçekleştirilmiştir. 1. grup veri setleri sadece desen bilgisinin çıkarıldığı öznitelik çıkarma yöntemleri ile elde edilmiştir. Bu grupta beş farklı veri seti oluşturulmuştur. 2. gruptaki veri setleri ise desen veri setindeki öznitelikler ile renklerden elde edilen öznitelikler çaprazlanarak birleştirilmesi sonucu elde edilmiştir. Bu grup için beş farklı desen ve dört farklı renk çıkarma yönteminden elde edilen özniteliklerin çaprazlanması sonucu yirmi farklı veri seti oluşturulmuştur.

Yapılan deneylerde desen bilgisi yanında renk bilgisi kullanmanın sınıflandırma başarısını artırıp artırmadığı sorusu araştırılmış ve sonuçlar göstermiştir ki desen bilgisine ek olarak renk bilgisi kullanıldığında sadece desen bilgisinin kullanıldığı durumdan daha başarılı sonuçlar elde edilmiştir. Renk bilgisi dahil edildiğinde sınıflama başarısında ortalama %8 civarında bir iyileşme gözlemlenmiştir.

Sadece desen bilgisinin kullanıldığı veri setlerinde en yüksek sınıflama başarısı LPQ yöntemiyle özniteliklerin çıkarıldığı veri setlerinde elde edilmiştir. Tüm sınıflayıcılar için bu veri seti yüksek başarımlı göstermiştir. Diğer öznitelik çıkarma yöntemleri bazı sınıflayıcılar için yüksek başarımlı gösterirken bazı sınıflama algoritmaları için başarımlı değeri düşük kalmıştır.

Sınıflayıcılar açısından durum ele alındığında her iki grup veri seti içinde öznitelik çıkarma yönteminden bağımsız olarak YSA ve SVM sınıflayıcılar en yüksek başarımlı sahip olan sınıflayıcılar olarak belirlenmişlerdir. Birbirine oldukça yakın doğru sınıflama başarısına sahip olan bu sınıflayıcılardan biri diğerinin yerine kullanılabilir. Her iki sınıflayıcı içinde renk ve desen bilgisinin birlikte kullanıldığı veri setlerinde başarı oranı %90'lar gibi yüksek bir değere ulaşmıştır.

Sınıflandırma yöntemleri içerisinde Naive Bayes (NB) yöntemi en düşük sınıflandırma başarısına sahip yöntem olarak gözlemlenmiştir. Bu durum sadece desen bilgisine dayanan sınıflandırma işlemlerinde değil aynı zamanda desen ve renk bilgisinin birlikte kullanıldığı sınıflandırma işlemlerinde de görülmektedir.

Çalışmamızda daha çok öznitelik çıkarım yöntemleri ve bunların sınıflandırıcılar üzerindeki başarımı incelenmiştir. Belirli teknikler yardımıyla öznitelikleri çıkarmak, birleştirmek ve en iyi öznitelikleri seçme işlemi tarafımızca gerçekleştirilmiştir. İlerde özniteliklerin otomatik olarak çıkarıldığı evrimsel sinir ağları, oto kodlayıcı gibi derin öğrenme mimarilerinin de kullanılacağı daha geniş çalışmalar planlanmaktadır.

Literatürdeki çalışmalarda kullanılan doğal taş veri setleri açık erişimli olmadığından deneyleri ortak veri setlerinde tekrarlayarak sonuçları diğer çalışmalarla karşılaştırmak mümkün olmamıştır. Bu nedenle veri setimizin açık erişimli hale getirilerek, sonuçların karşılaştırılabilme imkânının sağlanabileceği ortak bir veri seti oluşturulması ve böylelikle ileride yapılacak çalışmalara katkı sağlanması planlanmaktadır.

İleriki çalışmalarda sistemin gerçek zamanlı hale getirilerek sınıflandırma işleminin üretim sırasında kullanılması ve robotik sistemlere entegre edilerek ayırma ve paketleme işlemlerin otomatik olarak gerçekleştirilmesi yapılacak çalışmalar arasındadır. Böylelikle kalite kontrol süreci de üretim sonunda değil üretim aşamasında gerçekleştirilmiş olacaktır. Sistemin var olan kurum kaynak planlama yazılımları ile entegre hale getirilerek iyi depo ve stok yönetiminin oluşturulması da hedefler arasındadır.

Benzer bir sistemin karoların üretim sonrası dizim işlemlerine uygulanması düşünülmektedir. Üretim sonrası gerçekleştirilen dizim işleminde genel olarak homojenliği, desen dağılımını ve renk uyumunu bozan karoların seçilme işlemi yapılmaktadır. Bu işleminde, geliştirilecek bir sistemle otomatik hale getirilmesi ve entegre bir sistemin doğal taş sektörüne kazandırılması böylelikle ülke ekonomisine katkı sağlanması amaçlanmaktadır. Bu yönüyle gerçekleştirdiğimiz çalışma hedeflenen sistemi gerçekleştirmedeki önemli adımlardan birini oluşturmaktadır.





## KAYNAKÇA

- “2017 Yılı Maden ve Doğaltaş İhracat Değerlendirmesi ve Genel İstatistik Verileri”. (2018). *Türk Mermer Maden Vakfı* (blog). Erişim 11 Temmuz 2018. <http://turkmermermadenvakfi.org/2017-yili-maden-ve-dogaltas-ihracat-degerlendirmesi/>.
- Abadi Mohammad Shams Esfand ve Banihashemi Navid (2015). “Automatic classification of travertine stones based on sum and difference histograms algorithm”. *IEEE Machine Vision and Image Processing (MVIP), 2015 9th Iranian Conference on*, 132–137.
- Acar Emrullah ve Özerdem Mehmet Siraç (2012). “Image classification of Kiziltepe cropland by using Gabor Wavelet Transform”. *2012 20th Signal Processing and Communications Applications Conference (SIU)*, 1-4.
- Addison, Paul S. (2002). “The Illustrated Wavelet Transform Handbook: Introduction Theory and Applications in Science, Engineering”. *Medicine and Finance, IOP Publishing, Bristol*, 1-378.
- Albayrak Ali Sait ve KOLTAN YILMAZ Şebnem (2009). “Veri madenciliği: Karar ağacı algoritmaları ve İMKB verileri üzerine bir uygulama”. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* 14 (1), 31-49.
- Alpaslan Nuh (2013). “Gradyan Tabanlı Heterojen Öznitelik Çıkarma Yöntemlerine Yeni Yaklaşımlar”. Yüksek Lisans Tezi, Malatya: İnönü Üniversitesi, 1-79.
- Alver Seyfullah, Ay Sinan ve Tetik Yusuf Engin (2015). “A Novel approach for the detection of diabetic retinopathy disease”. *2015 23rd Signal Processing and Communications Applications Conference (SIU)*, 1401-4.
- Anchalia Prajesh P. ve Kaushik Roy (2014). “The k-nearest neighbor algorithm using MapReduce paradigm”. *Intelligent Systems, Modelling and Simulation (ISMS), 2014 IEEE 5th International Conference on*, 513–518.
- Araújo María, Martínez Javier, Ordóñez Celestino ve Vilán José Antonio (2010). “Identification of granite varieties from colour spectrum data”. *Sensors* 10 (9): 8572–8584.

- Atasever Ümit Haluk (2011). “ Uydu Görüntülerinin Sınıflandırılmasında Hızlandırma (Boosting), Destek Vektör Makineleri, Rastgele Orman (Random Forest) ve Regresyon Ağaçları Yöntemlerinin Kullanılması”. Yüksek Lisans Tezi, Kayseri: Erciyes Üniversitesi, 1-65.
- Aygün Sercan Yalçın Hülya ve Güneş Ece Olcay (2017). “Seed texture classification by random forest and neural networks”. *2017 25th Signal Processing and Communications Applications Conference (SIU)*, 1-4.
- Ayık Y. Ziya, Özdemir Abdülkadir ve Yavuz Uğur (2007). “Lise Türü ve Lise Mezuniyet Başarısının, Kazanılan Fakülte ile İlişkisinin Veri Madenciliği Tekniği ile Analizi”. *Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi* 10 (2), 441-454.
- Bharati Manish H., Liu J. Jay ve MacGregor John F. (2004). “Image texture analysis: methods and comparisons”. *Chemometrics and Intelligent Laboratory Systems* 72 (1): 57-71.
- Bianconi Francesco, Bello Raquel, Fernández Antonio ve González Elena (2015). “On Comparing Colour Spaces From a Performance Perspective: Application to Automated Classification of Polished Natural Stones”. *New Trends in Image Analysis and Processing -- ICIAP 2015 Workshops*, 71-78.
- Bianconi Francesco ve Fernández Antonio (2006). “Granite texture classification with Gabor filters”. *Proc. of the 18th International Congress on Graphical Engineering, Sitges (Spain), May*.
- Bianconi Francesco, González Elena, Fernández Antonio ve Saetta Stefano A. (2012). “Automatic classification of granite tiles through colour and texture features”. *Expert Systems with Applications* 39 (12): 11212-18.
- Cavalin Paulo ve Oliveira Luiz S. (2017). “A Review of Texture Classification Methods and Databases”. *2017 30th SIBGRAPI Conference on Graphics, Patterns and Images Tutorials (SIBGRAPI-T)*, 1-8.
- Coşkun Cengiz ve Baykal Abdullah (2011). “Veri Madenciliğinde Sınıflandırma Algoritmalarının Bir Örnek Üzerinde Karşılaştırılması”. *Akademik Bilişim, Malatya*, 51–58.

- Çalışkan Abidin ve Ergen Burhan (2014). "Palmprint recognition system based on gray level cooccurrence matrix". *2014 22nd Signal Processing and Communications Applications Conference (SIU)*, 826-29.
- Çelik H. İbrahim, L. Dülger Canan ve Topalbekiroğlu Mehmet (2012). "Görüntü İşleme Teknikleri Kullanarak Kumaş Hatalarının Belirlenmesi". *Tekstil Teknolojileri Elektronik Dergisi* 6 (1): 22–39.
- Çuhadar Murat ve Kayacan Cengiz (2005). "Occupancy Rate Forecasting in Lodging Properties by Using Artificial Neural Networks: An Experimental Study of Lodging Properties in Turkey. Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye'deki Konaklama İşletmeleri Üzerine Bir Deneme". *Anatolia Turizm Araştırmaları Dergisi* 16 (Temmuz): 24-30.
- Dipova Nihat (2018). "Görüntü Analizi Yöntemlerinin Geoteknik Mühendisliğinde Kullanımı". *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi* 9 (1): 33–44.
- Doğan Hatice ve Akay Olcay (2010). "Using AdaBoost classifiers in a hierarchical framework for classifying surface images of marble slabs". *Expert Systems with Applications* 37 (12): 8814–8821.
- Ebren Yiğit (2016). "Dış Ticarete Doğal Taş İhracatının Artış Olasılıklarının İncelenmesi". Yüksek Lisans Tezi, İzmir: Dokuz Eylül Üniversitesi, 1-79.
- Ekici S., Yıldırım S., ve Poyraz M. (2009). "Mwsafe koruma için örüntü tanıma uygulaması". *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, Cilt24, sy 1*: 51–61.
- Emhan Ömer (2017). "Yukarı – Aşağı İmleç Hareketine İlişkin Eeg Kayıtlarının Ayrık Dalgacık, Knn ve Dvm ile Sınıflandırılması". Yüksek Lisans Tezi, Diyarbakır: DİCLE ÜNİVERSİTESİ, 1-83.
- Ershad, Shervan Fekri (2011). "Color Texture Classification Approach Based on Combination of Primitive Pattern Units and Statistical Features". *The International journal of Multimedia & Its Applications* 3 (3): 1-13.
- Fernández Antonio, Ghita Ovidiu, González Elena, Bianconi Francesco ve Whelan Paul F. (2011). "Evaluation of robustness against rotation of LBP, CCR and

- ILBP features in granite texture classification”. *Machine vision and Applications* 22 (6): 913–926.
- Ferreira Anselmo ve Giraldi Gilson (2017). “Convolutional Neural Network approaches to granite tiles classification”. *Expert Systems with Applications* 84: 1-11.
- Filibino Tiene, Giraldi Gilson, Sim Lucas, ve Thomaz Carlos (2017). “Combining Deep Learning and Multi-class Discriminant Analysis for Granite Tiles Classification”. *IEEE Computer Vision (WVC), 2017 Workshop of*, 19–24.
- Günay Asuman ve Nabiyev Vasif (2016). “Yüz Bölgelerinin Yaş Tahmini Başarımlarının Yaş Gruplarına Göre Değerlendirilmesi”. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi* 9 (2): 1-10.
- Güner Edip Serdar (2008). “Türkçe İçin Derlem Tabanlı Bir Anafor Çözümleme Çalışması”. Yüksek Lisans Tezi, Edirne: Trakya Üniversitesi, 1-74.
- Güven Ayşegül, Uzunhisarcıklı Esmâ ve Göreke Volkan (2014). “Gri Seviyeli Eşoluşum Matrisleri Kullanılarak Sayısal Mamogram Görüntüsünden Doku Özniteliklerinin Çıkarılması ve Yapay Sinir Ağı ile Kitle Tespiti.” *Biyomedikal Görüntü İşleme ve Yapay Zekâ Uygulamaları*, 95-98.
- Hossain Shahera ve Serikawa Seiichi (2013). “Texture databases – A comprehensive survey”. *Pattern Recognition Letters, Smart Approaches for Human Action Recognition*, 34 (15): 2007-22.
- Huang Silan, Zhong Shangping ve Chen Kaizhi (2016). “A novel method of stone surface texture image recognition”. *IEEE Signal and Image Processing (ICSIP), IEEE International Conference on*, 146–150.
- Innocentric (2014). “Doğal Taş ve Mermer Sektörü Kümesi”. İhtiyaç Analizi ve Sektör Stratejisi Raporu, IC Danışmanlık ve Eğitim.
- Isaac Meera Mary ve Wilsy M. (2015). “Image Forgery Detection Based on Gabor Wavelets and Local Phase Quantization”. *Procedia Computer Science, Second International Symposium on Computer Vision and the Internet (VisionNet’15)*, 58 (Ocak): 76-83.

- Jiaoyan Ai, Di Liu ve Xuefeng Zhu (2004). "Combination of wavelet analysis and color applied to automatic color grading of ceramic tiles". *Pattern Recognition, 2004. IEEE ICPR 2004. Proceedings of the 17th International Conference on*, 3:235–238.
- Kavzoglu Taskin ve Colkesen Ismail (2010). "Karar Ağaçları İle Uydu Görüntülerinin Sınıflandırılması: Kocaeli Örneği (Classification of Satellite Images Using Decision Trees: Kocaeli Case)". *Harita Teknolojileri Elektronik Dergisi 2* (Ocak): 36-45.
- Kaya Çetin ve Yıldız Oktay (2014). "Makine Öğrenmesi Teknikleriyle Saldırı Tespiti: Karşılaştırmalı Analiz". *Marmara Fen Bilimleri Dergisi 26* (3): 89-104.
- Kayaalti Ömer, Aksebzeci B. Hakan, Asyali M. Hakan, Karahan Ö. İbrahim, Deniz Kemal ve Öztürk Mehmet (2010). "Texture analysis of liver cirrhosis". *2010 15th National Biomedical Engineering Meeting*, 1-4.
- Kaynar Oğuz, Işık Yunus Emre, Görmez Yasin ve Demirkoparan Ferhan (2017). "Fabric defect detection with LBP-GLMC". *2017 International Artificial Intelligence and Data Processing Symposium (IDAP)*, 1-5.
- Kaynar Oğuz, Aydın Zafer ve Görmez Yasin (2017). "Sentiment Analizinde Öznitelik Düşürme Yöntemlerinin Oto Kodlayıcı Derin Öğrenme Makinaları ile Karşılaştırılması". *Bilişim Teknolojileri Dergisi 10*(3): 319-326.
- Kaynar Oğuz, TUNA Murat Fatih, GÖRMEZ Yasin ve DEVECİ Mehmet Ali (2017). "Makine Öğrenmesi Yöntemleriyle Müşteri Kaybı Analizi". *C.Ü. İktisadi ve İdari Bilimler Dergisi 18*(1): 1-10.
- Kurt Zühal (2013). "Temel Bileşen Analiziyle Öznitelik Seçimi ve Görsel Nesne Sınıflandırma". Yüksek Lisans Tezi, Eskişehir: Eskişehir Osmangazi Üniversitesi, 1-90.
- Lepistö Leena, Kunttu Iivari ve Visa Ari JE (2005). "Rock image classification using color features in Gabor space". *Journal of Electronic Imaging 14* (4): 040503.
- López-Buendía Angel M., Guillem Celia, Cuevas J. M., Mateos F., ve Montoto M. (2013). "Natural stone reinforcement of discontinuities with resin for industrial processing". *Engineering Geology 166* (Supplement C): 39-51.

- Luis-Delgado José D., Martínez-Alajarín Juan ve Tomás-Balibrea Luis-Manuel (2003). “Classification of marble surfaces using wavelets”. *Electronics Letters* 39 (9): 714–715.
- Martínez-Alajarín Juan, Luis-Delgado José D. ve Tomás-Balibrea Luis-Manuel (2005). “Automatic system for quality-based classification of marble textures”. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)* 35 (4): 488–497.
- Metlek Sedat, Cetisli Bayram ve Senel Ahmet Fatih (2015). “Classification of travertine plates with image processing”. *IEEE Signal Processing and Communications Applications Conference (SIU), 2015 23th*, 1497–1500.
- Metlek, Sedat (2015). “Doğal Taş Plakaların Makine Görmesi İle Otomatik Sınıflandırılması”. Yüksek Lisans Tezi, Isparta: Süleyman Demirel Üniversitesi, 1-100.
- Mohanaiah P., Sathyanarayana P. ve Gurukumar L. (2013). “Image Texture Feature Extraction Using GLCM Approach”. *International Journal of Scientific and Research Publications*. 3(5): 290-295.
- Nizam Hatice ve Akın Saliha Sıla (2014). “Sosyal medyada makine öğrenmesi ile duygu analizinde dengeli ve dengesiz veri setlerinin performanslarının karşılaştırılması”. *XIX. Türkiye’de İnternet Konferansı*, 1-6.
- Ojala Timo, Pietikäinen Matti ve Harwood David (1996). “A comparative study of texture measures with classification based on featured distributions”. *Pattern recognition* 29 (1): 51–59.
- Özekes, Serhat (2003). “Veri Madenciliği Modelleri ve Uygulama Alanları”. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi* 2 (3): 65-82.
- Pachouri Kapil Kumar ve Barve Atul (2015). “A Comparative Analysis & Survey of various Feature Extraction Techniques” 6 (1): 377-79.
- Prieto Beatriz, Sanmartín Patricia, Silva Brenda de Melo ve Verdú F. M. M. (2008). “An effective method for characterizing colour by contact measurement in granitic rocks”. *Óptica Pura y Aplicada* 41 (4): 389–396.

Quinlan J. Ross (2014). *C4. 5: programs for machine learning*. Elsevier.

Rajkumar Goel Vineet Kumar, Srivastava Saurabh ve A. K. Sinha (2017). “A Review of Feature Extraction Techniques for Image Analysis”. *International Journal of Advanced Research in Computer and Communication Engineering* 6 (2): 153-55.

Sánchez-Yáñez Raúl E., Kurmyshev Evgenii V. ve Fernández Antonio (2003). “One-class texture classifier in the CCR feature space”. *Pattern Recognition Letters* 24 (9-10): 1503–1511.

Sel Mimar Engin (2006). “Dünya ve Türkiye Ölçeğinde Doğal Taş ve Seramik Kaplama Malzemelerinin Sektörel Analizi”. Yüksek Lisans Tezi, İstanbul: İstanbul Teknik Üniversitesi, 1-91.

Selver M. Alper ve Akay Olcay (2009). “Evaluating clustering methods for classification of marble slabs in an automated industrial marble inspection system”. *IEEE Electrical and Electronics Engineering, 2009. ELECO 2009. International Conference on*, II–115.

Sousa João M. C., ve Pinto João R. Caldas (2004). “Comparison of Intelligent Classification Techniques Applied to Marble Classification”. *Image Analysis and Recognition*, 802-9.

Stanchev Peter, Green Jr David ve Dimitrov Boyan (2003). “High level color similarity retrieval”. *International Journal "Information Theories & Applications"*.Cilt:10, 283-287.

Şengür Abdülkadir, Türkoğlu İbrahim ve İnce M. Cevdet (2009). “Endoskopik Görüntülerin Değerlendirilmesinde Görüntü İşleme Temelli Akıllı Bir Karar Destek Sistemi”. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi* 15 (1): 33-42.

Şişeci Melike ve Bayram Çetişli (2012). “Traverten Plaka Taşlarda Sınıfların K-ortalamalar ve Bulanık C-ortalamalar Kümeleme Yöntemleri ile Belirlenmesi”. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi* 16 (3), 238-247.

Taşligil Nuran ve Şahin Güven (2017). “Yapı Malzemesi Olarak Kullanılan Türkiye Doğal Taşlarının İktisadi Coğrafya Odağında Analizi”. *Marmara Coğrafya Dergisi*, sy 33 (Mart): 607-40.



“T.C. Enerji ve Tabii Kaynaklar Bakanlığı - Doğal Taşlar” (2017). Erişim 30 Haziran 2018. <http://www.enerji.gov.tr/tr-TR/Sayfalar/Dogal-Taslar>.

Topalova Irina ve Tzokev Alexander (2010). “Automated texture classification of marble shades with real-time PLC neural network implementation”. *IEEE Neural Networks (IJCNN), The 2010 International Joint Conference on*, 1–8.

Trier Øivind Due, Jain Anil K., ve Taxt Torfinn (1995). *Feature Extraction Methods For Character Recognition - A Survey*, 1-24.

Türkoğlu Muammer ve Hanbay Davut (2015). “Classification of the grape varieties based on leaf recognition by using SVM classifier”. *2015 23rd Signal Processing and Communications Applications Conference (SIU)*, 2674-77.

Yavuz Hasan Serhan, Çevikalp Hakan ve Edizkan Rıfat (2013). “Automatic face recognition from frontal images”. *2013 21st Signal Processing and Communications Applications Conference (SIU)*, 1-4.

Yavuz Zafer ve Köse Cemal (2012). “Bulanık C-Kümeleme Algoritması ile Retinal Kan Damarı Bölütleme Retinal Vessel Segmentation with Fuzzy C-Means Clustering Algorithms”. *ELECO '2012 Elektrik - Elektronik ve Bilgisayar Mühendisliği Sempozyumu*, 562-566.

Yıldız Kazım ve Buldu Ali (2017). “Kumaş hata tespiti ve sınıflandırmada dalgacık dönüşümü ve temel bileşen analizi”. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi* 23 (5): 622-27.

Yuan Baohua, Honggen Cao ve Jiuliang Chu (2012). “Combining Local Binary Pattern and Local Phase Quantization for Face Recognition”. *2012 International Symposium on Biometrics and Security Technologies*, 51-53.

Zhang Jianguo ve Tan Tieniu (2002). “Brief review of invariant texture analysis methods”. *Pattern recognition* 35 (3): 735–747.

Zhi-qiang Jiang, Hang-guang Fu ve LI Ling-jun (2005). “Support vector machine for mechanical faults classification”. *Journal of Zhejiang University-SCIENCE A* 6 (5): 433–439.

Zhou Shu-Ren, Yin Jian-Ping ve Zhang Jian-Ming (2013). “Local binary pattern (LBP) and local phase quantization (LBQ) based on Gabor filter for face representation”. *Neurocomputing* 116: 260–264.



## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

Adı Soyadı : Mustafa TEMİZ  
Uyruđu : T.C.  
Doğum Tarihi ve Yeri : 20.08.1991 SİVAS  
e-posta : temizmustafa@cumhuriyet.edu.tr

### EĞİTİM

Derece	Kurum	Mezuniyet Yılı
Yüksek Lisans	Cumhuriyet Üniversitesi	2018
Lisans	Erciyes Üniversitesi	2015

### YABANCI DİL BİLGİSİ

İngilizce YDS (62.5) E-YDS (62.5) YÖKDİL (77.5)