

Örüntü Tanıma Uygulamalarında
Fraktal Boyut Yardımıyla Öznitelik Çıkarımı

Efnan Şora Günal

DOKTORA TEZİ

Elektrik ve Elektronik Mühendisliği Anabilim Dalı

Şubat 2010

Feature Extraction by Fractal Dimension
in Pattern Recognition Applications

Efnan Şora Günel

DOCTORAL DISSERTATION

Department of Electrical and Electronics Engineering

February 2010

Örüntü Tanıma Uygulamalarında
Fraktal Boyut Yardımıyla Öznitelik Çıkarımı

Efnan Şora Günal

Eskişehir Osmangazi Üniversitesi
Fen Bilimleri Enstitüsü
Lisansüstü Yönetmeliği Uyarınca
Elektrik ve Elektronik Mühendisliği Anabilim Dalı
Telekomünikasyon Bilim Dalında
DOKTORA TEZİ
Olarak Hazırlanmıştır

Danışman: Yrd. Doç. Dr. Selçuk CANBEK

Şubat 2010

ONAY

Elektrik ve Elektronik Mühendisliđi Anabilim Dalı Doktora öđrencisi Efnan Şora Günal'ın DOKTORA tezi olarak hazırladıđı “Örüntü Tanıma Uygulamalarında Fraktal Boyut Yardımıyla Öznitelik Çıkarımı” başlıklı bu çalıřma, jürimizce lisansüstü yönetmeliđin ilgili maddeleri uyarınca deđerlendirilerek kabul edilmiřtir.

Danıřman : Yrd. Doç. Dr. Selçuk CANBEK

İkinci Danıřman : _____

Doktora Tez Savunma Jürisi:

Üye : Prof. Dr. M.Şahin KOÇAK

Üye : Prof. Dr. Hüseyin AZCAN

Üye : Yrd. Doç. Dr. Selçuk CANBEK

Üye : Yrd. Doç. Dr. Nihat ADAR

Üye : Yrd. Doç. Dr. Erol SEKE

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun tarih ve
sayılı kararıyla onaylanmıřtır.

Prof. Dr. Nimetullah BURNAK

Enstitü Müdürü

ÖZET

Bu tez çalışmasında Fraktal Boyut (FD) kavramı, örüntü tanınmanın önemli konuları olan öznitelik çıkarımı ve seçiminde kullanılmıştır. Çalışmanın ilk bölümünde, klasik hesaplama yöntemleriyle elde edilen FD bilgisi, video kesme geçişlerinin belirlenmesi uygulamasında öznitelik çıkarımı amacıyla kullanılmıştır. Konuyla ilgili yapılan deneysel çalışmanın sonuçları, FD temelli özniteliklerin literatürdeki farklı öznitelikler kadar başarılı olduğunu göstermektedir. Sonraki adımda, FD temelli öznitelik çıkarımında iyileştirmeler yapılarak sadece kesme geçiş belirleme başarımını artırmakla kalmayıp ayrıca FD hesaplamadaki işlem karmaşıklığı da azaltılmıştır. Ayrıca, farklı video kesme geçiş türlerinin belirlenebilmesi için klasik eşikleme yöntemine alternatif olabilecek örüntü sınıflandırıcı temelli bir yöntem önerilmiştir. Sonraki aşamada, HSV renk uzayında yapılan FD ölçümlerinin görüntü bölütlemeye kullanımı incelenmiştir. Bu amaçla, farklı bitki türlerini içeren görüntülerin HSV renk bileşen değerleri ile bunlardan elde edilen bölgesel FD bilgileri kullanılarak öznitelik çıkarımı yapılmıştır. Bu öznitelikler daha sonra Bayes sınıflandırıcıya verilerek ilgili bitki türleri sınıflandırılmıştır. Deneysel sonuçlar, HSV bileşenleri yardımıyla elde edilen FD temelli özniteliklerin, yalnızca gri seviye değerleri kullanılarak çıkarılan öznitelikler kadar iyi sonuç verdiğini göstermektedir. Tüm öznitelikler birlikte kullanıldığında ise çok daha iyi bir başarıma ulaşıldığı gözlenmiştir. Çalışmanın diğer bir bölümünde, FD bilgisi ayırdedici öznitelik seçiminde kullanılmıştır. Bu çalışmanın uygulaması olarak beton gücünün belirlenmesinde beton bileşenlerinin katkısı tespit edilmiştir. Bu amaçla, bileşenlerdeki farklılıklar fraktal boyuttaki değişimlerle ilişkilendirilmiştir. Kapsamlı bir veritabanında yapılan deneysel çalışmalar, uygun bileşenleri kullanarak daha kuvvetli beton üretme ve dolayısıyla daha dayanıklı yapılar inşa etmede yol gösterici olabilecek sonuçlar vermiştir.

Anahtar Kelimeler: Fraktal boyut, örüntü tanıma, öznitelik çıkarma

SUMMARY

In this thesis study, fractal dimension (FD) concept is employed in feature extraction and selection which are crucial topics of pattern recognition. Initially, FD information, which is obtained by classic computation methods, is used for feature extraction in detection of video shot transitions. Results of the experimental study show that FD based features provide similar performance with respect to other features available in the literature. Next, FD based feature extraction method is improved so that not only the performance of shot transition detection increases but also algorithmic complexity of FD computation decreases. Additionally, a new video shot transition method based on pattern classifier is proposed as an alternative to classic threshold based detection method. In next part of the study, the use of FD measurements in HSV color space for image segmentation is investigated. For this purpose, feature extraction is carried out using regional FD information that is obtained from HSV color components belonging to images of various plant types. These features are then fed into Bayes classifier so that the regarding plant types are classified. Experimental results indicate that the features obtained with HSV components provide as good results as the ones that are extracted using gray scale values only. It is observed that even better performance is attained if all the features are used together. In another part of the study, FD information is used in selection of discriminative features. As the application of this part, contribution of concrete components in determining the concrete strength is evaluated. For this purpose, variations in the ingredients are characterized in terms of variations in FD. Experimental studies carried out in an extensive dataset provides pretty good results which may lead to manufacture stronger concrete, and consequently to construct stronger structures using appropriate components.

Keywords: Fractal dimension, pattern recognition, feature extraction

TEŞEKKÜR

Bu tez çalışmasının ortaya çıkmasındaki katkılarından dolayı başta danışmanım Yrd. Doç. Dr. Selçuk CANBEK olmak üzere tez izleme komitesinde yer alan Yrd. Doç. Dr. Nihat ADAR ve Prof. Dr. M.Şahin KOÇAK'a teşekkür ederim.

Ayrıca, doktora eğitimim süresince benden desteklerini esirgemeyen sevgili eşim Serkan ve aileme minnetlerimi sunarım.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	v
SUMMARY	vi
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
ŞEKİLLER DİZİNİ.....	x
ÇİZELGELER DİZİNİ.....	xii
SİMGELER VE KISALTMALAR DİZİNİ.....	xiv
1. GİRİŞ.....	1
1.1 Örüntü Tanıma	1
1.2 Öznitelik Çıkarımı.....	3
1.3 Öznitelik Seçimi.....	4
1.4 Sınıflandırma.....	6
1.5 Tez Çalışması	7
2. FRAKTAL GEOMETRİ	9
2.1 Temel Boyut Kavramları ve Fraktal Boyut.....	10
2.2 Görüntülerde Fraktal Boyut Hesaplama Yöntemi	19
2.3 Fraktal Temelli İlinti Boyutu Hesaplama Yöntemi.....	22
3. FRAKTAL BOYUT YARDIMIYLA ÖZİNİTELİK ÇIKARIMI.....	25
3.1 VİDEOLARDA KESME GEÇİŞLERİNİN BELİRLENMESİ	25
3.1.1 Mevcut Video Kesme Geçiş Belirleme Yöntemleri.....	30
3.1.2 Video Kesme Geçişlerinin FD Temelli Öznitelikler ve Eşikleme Yöntemi ile Belirlenmesi.....	32
3.1.3 Video Kesme Geçişlerinin FD Temelli Öznitelikler ve Örüntü Sınıflandırıcı ile Belirlenmesi.....	40
3.2 BİTKİLERİN SINIFLANDIRILMASI	42
4. FRAKTAL BOYUT YARDIMIYLA ÖZİNİTELİK SEÇİMİ	46

5. DENEYSEL ÇALIŞMALAR.....	50
5.1 Video Kesme Geçişlerinin FD Temelli Öznitelikler ile Belirlenmesi Deneyleri	50
5.1.1 Geçişlerin Eşikleme Yöntemi ile Belirlenmesi Deneyleri.....	51
5.1.2 Geçişlerin Örüntü Sınıflandırıcı ile Belirlenmesi Deneyleri	61
5.2 Bitkilerin Sınıflandırılması Deneyleri.....	68
5.3 Öznitelik Seçimi Deneyleri.....	69
6. SONUÇLAR	74
KAYNAKLAR DİZİNİ	76
ÖZGEÇMİŞ	84

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 1.1. Örüntü tanıma süreci	3
Şekil 2.1. Temel tamsayı boyutları (a) Nokta (0-boyut) (b) Çizgi (1-boyut) (c) Düzlem 2-boyut (d) Katı (3-boyut)	10
Şekil 2.2. Topolojik eşdeğer eğriler (a) Düz çizgi (b) Eğri (c) ‘Kırıklı Eğri’	11
Şekil 2.3. Topolojik eşdeğer yapılar (iki delikli yüzeyler)	11
Şekil 2.4. Temel şekillere ait Öklit ve Topolojik boyutlar (a) Tek nokta (b) Doğrudaş noktalar kümesi (c) Düzleme yayılmış noktalar kümesi (d) Uzaya yayılmış noktalar kümesi (e) Doğru parçası (f) Düzlemdeki eğri (g) Uzaydaki eğri... 13	13
Şekil 2.5. (a) Fraktal nesne, (b) Fraktal olmayan nesne (Addison’dan, 1997)	14
Şekil 2.6. Doğadaki bazı fraktal yapılar (Miquel, 2010) (a) Eğrelti otu, (b) Ağaç dalları, (c) Kıyı şeridi, (d) Bitki yaprağı, (e) Şimşek görüntüsü, (f) Bakteri (Bildirgeç, 2010)	15
Şekil 2.7. Temel geometrik nesnelere kendine benzer şekiller oluşturma (a) Doğru Parçası (uzunluk=L), (b) Kare (Alan=A), (c) Küp (Hacim = V).....	16
Şekil 2.8. Von Koch eğrisinin kendine benzeşim yoluyla oluşturulması	17
Şekil 2.9. (a) Gri renkli düzlem $FD_{gri} = 2.000$ (b) Siyah renkli düzlem $FD_{siyah} = 2.000$ (c) Lena görüntüsü $FD_{LENA} = 2.381$	18
Şekil 2.10. (a) 100×100 boyunda gri seviye görüntü. (b) (a) daki görüntünün 0-255 arası gri renkte 3-boyuttaki da yeğlilik yüzeyi	20
Şekil 2.11. M×M ölçülerinde s × s boyundaki alt bölgelere ölçeklendirilen görüntü yeğlilik yüzeyi.....	21
Şekil 2.12. En küçük kareler yaklaşımı yöntemi ile FD hesaplama	22
Şekil 3.1. Video sahnesindeki kesme geçiş tipleri.....	26
Şekil 3.2. Ardışık çerçevelerdeki ani kesme geçişi (a) k. Çerçeve (b) (k+1). Çerçeve .	27
Şekil 3.3. Çözülme (dissolve) tipi kesme geçişine örnek ardışık video çerçeveleri.....	27
Şekil 3.4. Gürültü içeren ardışık video çerçeveleri.....	28
Şekil 3.5. Yatay kayma hareketine(panning) örnek ardışık video çerçeveleri	28

Şekil 3.6. Süpürme tipi (wipe) kesme geçişine örnek ardışık video çerçeveleri	29
Şekil 3.7. Zumlama(zooming) tipi kesme geçişine örnek ardışık video çerçeveleri	29
Şekil 3.8. Ardışık çerçevelerdeki bölgeler (a) Kesme geçişi içermeyen futbol videosu (b) Kesme geçişi içeren tenis videosu.....	34
Şekil 3.9. FDD öznitelikleri (a) Her çerçeve için tek FD (b) Her çerçeve için dört FD (İşaretli noktalar kesme geçişlerinin olduğu noktaları göstermektedir)	36
Şekil 3.10. Test videosuna ait tek bir video çerçevesi için elde edilen $\log(N_r) - \log(1/r)$ grafikleri (a) $2 \leq s \leq (M/2)$ aralığında DBC yöntemi ile elde edilmiş, (b) DBC yöntemi ile elde edilmiş $\log(N_r) - \log(1/r)$ ve SDBC yöntemi kullanılarak, elde edilen doğru parçası.	38
Şekil 3.11. Test videosuna ait FDD öznitelik değerleri (a) SDBC yöntemi (b) DBC yöntemi (c) DBC ve SDBC arasındaki mutlak hata farkı ($r_{p_1} = 1/4, r_{p_2} = 1/40$). (Grafiklerdeki işaretli noktalar gerçek kesme geçişi olan çerçeveleri göstermektedir).....	39
Şekil 3.12. Sınıflandırmada kullanılan bitki görüntüleri (a) Aranılan bitki türünün detaylı görüntüsü (b) Bitki türüne göre elle sınıflandırma	44
Şekil 4.1. Beton öznitelik değeri grafikleri (1-100 arası: Sınıf 1, 101-200 arası: Sınıf 2, 201-300 arası: Sınıf 3): (a) Çimento (b) Yüksek Fırın Cürufu (c) İnce Kül (d) Su (e) Süperakışkanlaştırıcı (f) Kaba Agregası (g) İnce Agregası (h) Yaş.....	48
Şekil 5.1. (a) FDD, (b) SAD, (c) B2B, (d) INT. (Grafiklerdeki işaretli noktalar gerçek kesme geçişi olan çerçeveleri göstermektedir.)	53
Şekil 5.2. 2-sınıf için dağılım grafiği.....	62
Şekil 5.3. 3-sınıf için dağılım grafikleri (a) FDD, (b) B2B, (c) SAD, (d) INT	64
Şekil 5.4. Normalize edilmiş ve FD değerlerine göre büyükten küçüğe sıralanmış beton öznitelik değeri grafikleri (1-100 arası: Sınıf 1, 101-200 arası: Sınıf 2, 201- 300 arası: Sınıf 3) : (a) Yaş (b) Çimento (c) Süperakışkanlaştırıcı (d) Su (e) İnce Agregası(f) Kaba Agregası (g) Yüksek Fırın Cürufu (h) İnce Kül	71

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 1.1. SFS aşamaları	5
Çizelge 1.2. SBS aşamaları.....	6
Çizelge 4.1. Veri kümesindeki beton bileşenlerinin listesi.....	47
Çizelge 4.2. Dayanıklılık sınıfları.....	47
Çizelge 5.1. FDD _{DBC} , SAD, B2B, INT sonuçları (a) Dereceli geçişler (b) Ani geçişler (c) Tüm geçişler	54
Çizelge 5.2. FDD _{DBC} , FDD _{SDBC(1x1)} , FDD _{SDBC(2x2)} sonuçları (a) Dereceli geçişler (b) Ani geçişler (c) Tüm geçişler.....	56
Çizelge 5.3. FDD, SAD, B2B, INT sonuçları (a) Dereceli geçişler (b) Ani geçişler (c) Tüm geçişler	57
Çizelge 5.4. Çözülme (dissolve) geçiş sonuçları	58
Çizelge 5.5. Yatay kayma (panning) geçiş sonuçları.....	58
Çizelge 5.6. Süpürme (wipe) geçiş sonuçları	58
Çizelge 5.7. Zumlama (zoom) geçiş sonuçları	59
Çizelge 5.8. FDD, SAD, B2B, INT sonuçları (a) Dereceli geçişler (b) Ani geçişler (c) Tüm geçişler	60
Çizelge 5.9. 2-sınıf için tanıma oranları	62
Çizelge 5.10. 2-sınıf için karışım matrisi.....	62
Çizelge 5.11. 3-sınıf için Bayes Sınıflandırıcı ile Tanıma Oranları (%)	65
Çizelge 5.12. 3-sınıf için Bayes Sınıflandırıcı ile Standart Sapma (σ) değerleri	65
Çizelge 5.13. 3-sınıf için karışım matrisi (FDD).....	66
Çizelge 5.14. 3-sınıf için karışım matrisi (B2B).....	66
Çizelge 5.15. 3-sınıf için karışım matrisi (SAD).....	66
Çizelge 5.16. 3-sınıf için karışım matrisi (INT)	67
Çizelge 5.17. Bayes bitki sınıflandırma oranları (%)	69

Çizelge 5.18. Beton özniteliklerine ait azalan sıradaki FD değerleri	70
Çizelge 5.19. FD, SFS, SBS yöntemleri yardımıyla farklı öznitelik alt kümeleri için sınıflandırma oranları(%).....	72
Çizelge 5.20. (a) FD (b) SFS (c) SBS yöntemlerine göre en iyi öznitelik kümeleri	72

SİMGELER VE KISALTMALAR DİZİNİ

B2B	Seleden Seleye Histogram Farkı (Bin to Bin)
<i>D</i>	Hausdorff- Besicovitch Boyutu
<i>D_C</i>	İlinti Boyutu (Correlation Dimension)
<i>D_E</i>	Öklit Boyutu (Euclidean Dimension)
<i>D_S</i>	Benzerlik Boyutu (Similarity Dimension)
<i>D_T</i>	Topolojik Boyut (Topological Dimension)
DBC	Farka Dayalı Kutu Sayma (Differential Box Counting)
DTM	Dinamik Eşikleme Yöntemi (Dynamic Threshold Method)
FD	Fraktal Boyut (Fractal Dimension)
GP	Grassberger-Procaccia İlinti boyutu (Correlation Dimension)
HI	Histogram Kesişimi (Histogram Intersection)
INT	Histogram Farkı
LSF	En Küçük Kareler Yaklaşımı (Least Square Fitting)
SAD	Mutlak Farklar Toplamı (Sum of Absolute Difference)
SBS	Ardışık Geri Yönde Seçim (Sequential Backward Selection)
SDBC	Basitleştirilmiş Farka Dayalı Kutu Sayma (Simplified DBC)
SFS	Ardışık İleri Yönde Seçim (Sequential Forward Selection)

BÖLÜM 1

GİRİŞ

1.1 Örüntü Tanıma

Örüntü tanıma, amacı nesnelere değişik sayıdaki kategori veya sınıflara ayırma olan bilimsel bir disiplindir. Uygulamaya bağlı olarak bu nesnelere görüntü, sinyal dalga yapıları veya sınıflandırılabilir herhangi bir ölçüm olabilir. Bu nesnelere en genel tanım olarak örüntü adı verilir. Uzun bir tarihçesi olan örüntü tanıma, 1960'lardan önce istatistiksel alandaki teorik araştırmalarla sınırlı kalsa da son yıllarda bilgisayar teknolojisindeki hızlı gelişme bu alandaki uygulamaların artmasına olanak sağlamıştır. Endüstriyel üretimde otomasyon uygulamalarının artışı, bilgi geri çağırımı ve elde edilmesi gibi alanlardaki artan talep, örüntü tanımayı günümüzün mühendislik uygulama ve araştırma konularında önemli bir noktaya getirmektedir. Örüntü tanıma çoğu akıllı makine sistemlerinde karar vermede bütünleyici bir parça olarak yer alır (Theodoridis and Koutroumbas, 2003).

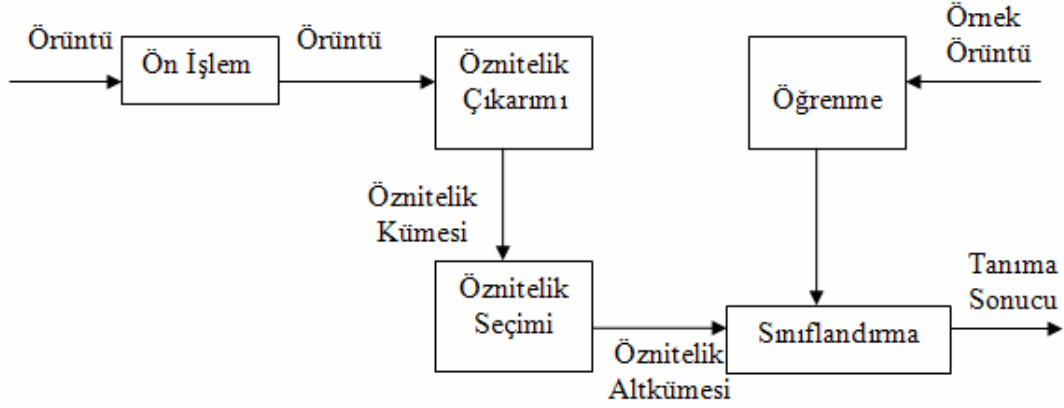
İnsanlar çevrelerini algılamada gözlerini, kulaklarını, burunlarını ve tat alma hücreleri gibi duyu organlarını kullanırlar. İnsanların vücudunda doğal algılayıcılar olarak bulunan bu sensörler beyindeki algılama için gerekli uyarımı sağlarlar (Paulus and Hornegger, 2003). Algılama, bir diğer ifade ile biyolojik örüntü tanıma, bu uyarımlara ek olarak, önceki deneyim ve öğrenmelere dayalı olarak kendiliğinden yapılır. Günümüzde teknoloji ve sanayi alanlarındaki hızlı gelişmeler sektörleri, verimliliği arttırmak amacıyla insan gücü ile yapılabilen birçok işlemi, daha hızlı ve otomatik bir şekilde yapabilmeyi yollarını bulmaya sevk etmiştir. Bu gereksinimler teknolojik açıdan örüntü tanıma uygulama alanlarının artışına sebep olmuştur.

Çevreyi veya durumları teknolojik olarak yapay algılamayı sağlayan örüntü tanıma süreçlerinde, insanlardaki duyu organlarının işlevlerini sağlayan sensörler

kullanılmaktadır. Çevremiz sensörler tarafından kaydedilebilir ve ölçülebilir büyüklüklerden oluşmaktadır. Sensörlerin çıktıları bilgisayar sistemlerine aktarılarak, daha sonra örüntü tanıma sürecinde sistem tarafından işlenmek üzere sayısal sinyallere dönüştürülmektedir. Örneğin, ses için mikrofon, görüntü için CCD kamera gibi özel cihazlar kullanılarak veriler kaydedilmektedir. Elde edilen sensör verisi kullanılan sensörün kalitesine bağlıdır. Sayısal sinyaller bilgisayar temelli bir şekilde birleştirilmektedirler. Sensör verisinin işlenmesine sinyal işleme adı verilir. Kullanım alanına göre, görüntü işleme ve konuşma işleme olarak isimlendirilebilmektedir. Bir diğer ifade ile uygulamalardaki örüntü tanıma, bilgisayarın elde edilen bir sinyalin ne demek istediğini anlamaya çalışmasıdır (Paulus and Hornegger, 2003).

Sayısal görüntüler ve konuşma sinyalleri günümüz bilgisayar ve sesli-görsel ekipmanlarında oldukça fazla kullanılmaktadır. Sayısal yüksek-tanımlı (HD) videolar bu duruma uygun bir örnek olarak gösterilebilir. Tüm bilgisayarlar video ve ses destekli, sayısal görüntü ve yazıları birleştiren programları çalıştırabilir durumdadır. Bu gelişmelerin sonucunda örüntü tanımanın çok çeşitli kullanım alanları ortaya çıkmıştır. Barkod okuyucular, bilgisayarlarla akustik haberleşme, diyalog sistemleri, konuşmacı tanıma sistemleri, sismik sensörden gelen sinyallerin tanımlanması; endüstride görsel bilgi kullanılarak robot kontrolü ve otonom cihazların kullanılması; tıpta bilgisayar destekli tıbbi tanılama temelli X-ray veya MR görüntülerinin, kalp ve beyin sinyallerinin incelenmesi; askeri alanda uydu görüntülerinin işlenmesi, örüntü tanıma uygulamalarının yaygın örneklerindedir (Paulus and Hornegger, 2003). Ayrıca, son yıllarda meteorolojik hava tahmini, hava kirliliği tahmini, canlı sınıflandırma ve bunların yanı sıra güvenlik konusunda artan talepler doğrultusunda yüz, retina, parmak izi, el yazısı tanıma gibi alanlarındaki çalışmalar ön plana çıkmaktadır.

Örüntü tanıma süreci temel öğeleri, önışlem (gürültü azaltma, önvurgulama, v.b.), öznitelik çıkarımı, öznitelik seçimi, öğrenme ve sınıflandırmadır (Şekil 1.1).



Şekil 1.1. Örüntü tanıma süreci

Öznelikler çıkarılmadan önce, sinyal bir önışlemden geçirilebilir. Önışlemin amacı, analizin sonraki aşamalarında yapılacak hesaplamayı basitleştirmektir. Bu amaçla, sinyal değişik yöntemlerle iyileştirilebilir. Örnek olarak, önışlem basamaklarından birisi görüntülerin yumuşatılmasıdır (smoothing). Yumuşatma istenmeyen detayları veya gürültüleri azaltacak ve sonraki işlemleri hızlandıracaktır. Süzgeçleme, görüntü ölçülerinin veya konuşma sinyallerinin süresinin değişmesi gibi işlemler de önışlem örnekleri olarak verilebilir. En temel ön işlemlerden birisi de giriş sinyallerini normalize etmektir. Ön işlemler problemten bağımsızdır. Diğer bir ifade ile, gösterim şekli değişmez; yani, örüntüler örüntülere, görüntü matrisleri görüntü matrislerine veya ses sinyalleri yine ses sinyallerine dönüştürülür. Sadeleştirme sağlayan bu önışlemlerin ardından öznelikler çıkarılır (Paulus and Hornegger, 2003).

1.2 Öznelik Çıkarımı

Öznelik, örüntüye dair ölçülebilir ya da gözlenebilir bilgi şeklinde ifade edilebilir. Önışlemin ardından, örüntüler daha küçük boyuttaki öznelik kümelerine veya vektörlerine dönüştürülür. Öznelik çıkarımı temel anlamda bir çeşit boyut

indirgeme yöntemidir. Özellikle görüntü işleme uygulamalarında kullanılan veriler çok yüksek boyutlu olduğu için bu verilerin orijinal halleriyle kullanılması işlem süresini büyük oranda artırmaktadır. Öznitelik çıkarım yöntemleriyle, orijinal verilerin ilgisiz ve fazla bilgileri elenip karakteristik özellikleri korunarak, daha küçük boyutlara indirilmesi sağlanır (Theodoridis and Koutroumbas, 2003).

Sayısal öznitelikler, örüntünün sınıfını niteleyen gerçel sayılar veya vektörler kümesi şeklinde olabilir. Ses sinyali için sinyalin frekans bilgisi kullanılırken, görüntü için ortalama gri-seviye renk değeri önemli bir öznitelik olarak kullanılabilir (Paulus and Hornegger, 2003). Görüntü işleme uygulamalarında öznitelik çıkarımı, sayısal görüntülerin şekillerinin belirlenmesi, tanınması ve sınıflandırılması gibi süreçlerde kullanılmaktadır.

1.3 Öznitelik Seçimi

Öznitelik çıkarma işleminde, örüntüdeki gereksiz bilgilerin elenmesiyle belirli ölçüde boyut indirgeme sağlanır. Öznitelik seçimi aşamasında ise mevcut özniteliklerin ayırdedicilikleri çeşitli ölçütlere göre değerlendirilip varolan öznitelik kümesinden daha ayırdedici bir altküme bulunması amaçlanır (Bellman, 1961; Jain and Zongker, 1997; Theodoridis and Koutroumbas, 2003). Gereğinden fazla sayıda öznitelik kullanılmasının örüntü sınıflandırma başarımını düşürmesi, “boyutun laneti (curse of dimensionality)” olarak adlandırılmış ve uygun öznitelik seçiminin önemini ortaya koymuştur (Theodoridis and Koutroumbas, 2003).

Öznitelik seçim işlemi iki bileşene sahiptir: Bunlardan ilki, özniteliklerin ayırdediciliklerini belirlemede kullanılan değerlendirme ölçütü, ikincisi ise arama stratejisidir. Çok sayıda özneliğin bulunduğu uygulamalarda tam kapsamlı arama uygun olmayabilir. Örneğin, 250 öznitelik arasından 10 tanesini seçmek için

$\binom{10}{250} = 2.10^{17}$ farklı altkümenin değerlendirilmesi gerekir. Bu gibi durumlarda, en iyi sonuç veren ancak işlem süresi tam kapsamlı aramaya göre çok daha kısa olan ileri yada geri yönde ilerleme prensibine dayalı arama stratejileri tercih edilir. İleri yönde arama yapan ardışık ileri yönde seçim yöntemi (SFS), değerlendirme ölçütüne göre en iyi öznelikle başlayıp her adımda en yüksek başarıyı sağlayan özneliği kümeye ekleyerek devam eder. Bu işlem, istenilen sayıda öznelik ve en yüksek başarı elde edilinceye kadar sürer. Bir diğer yöntem ise ardışık geri yönde seçim (SBS) dir (Duin and Tax, 2006). SFS'nin aksine SBS'de seçim işlemine tüm öznelikler ile başlanır. Her adımda, mevcut öznelik sayısının bir eksiği kadar öznelik kullanılarak değerlendirme ölçütüne göre başarılar elde edilir. En yüksek başarıyı sağlayan durumda, dışarıda kalan öznelik elenerek sonraki aşamaya geçilir.

Çizelge 1.1 ve 1.2'de dört öznelikten oluşan örnek bir veri kümesi üzerinde SFS ve SBS öznelik seçimi uygulaması adım adım gösterilmektedir.

Çizelge 1.1. SFS aşamaları

	Öznelikler	Ara Seçim	Sınıflandırma Oranı (%)	Seçilecek Öznelik Altkümesi
Adım1	Ö1		60	
	Ö2		40	
	Ö3	Ö3	80	
	Ö4		70	
Adım2	Ö3,Ö1	Ö3,Ö1	90	Ö3,Ö1
	Ö3,Ö2		70	
	Ö3,Ö4		50	
Adım3	Ö3,Ö1,Ö2		50	
	Ö3,Ö1,Ö4	Ö3,Ö1,Ö4	70	
Adım4	Ö3,Ö1,Ö4,Ö2		30	

Çizelge 1.2. SBS aşamaları

	Öznitelikler	Seçim	Sınıflandırma Oranı (%)	Elenecek öznitelik	Seçilecek Öznitelik Altkümesi
Adım1	Ö1,Ö2,Ö3,Ö4		30		
		Ö1,Ö2,Ö3,Ö4			
Adım2	Ö2,Ö3,Ö4		50		
	Ö1,Ö3,Ö4		70	Ö2	
	Ö1,Ö2,Ö3		50		
		Ö1,Ö3,Ö4			
Adım3	Ö1,Ö4		85		
	Ö1,Ö3		90	Ö4	Ö1,Ö3
	Ö3,Ö4		50		
		Ö1,Ö3			
Adım4	Ö1		60		
	Ö3	Ö3	80	Ö1	

Sınıflandırma aşamasında algoritma karmaşıklığını düşürmesi açısından, daha az öznitelik kullanılması bir avantajdır. Ancak bu alt kümeyi seçme işleminin maliyet gerektirmesi ise dezavantajdır (Duin and Tax, 2006). Uygulamalarda bu iki durumdan hangisinin daha önemli olduğu kararına varılarak işlem gerçekleştirilir

1.4 Sınıflandırma

Bilinmeyen bir örüntüyü tanıyabilmek için öznitelik çıkarımı ve öznitelik seçiminin ardından sınıflandırma işlemi yürütülür. Örüntü sınıflandırmanın amacı verilen bir örüntünün bir sınıf ile ilişkilendirilmesidir. Sınıflandırma işlemine bağlı olarak, görev alanı k farklı sınıfa ayrılır. Sınıflandırma algoritmaları sözdizimsel ve sayısal olmak üzere ikiye ayrılırlar. Örüntü öznitelikleri olarak gerçel sayılar, vektörler, kümeler veya bunlar gibi gerçel alandaki diğer yapılar kullanılıyorsa sınıflandırıcı sayısal sınıflandırıcı olarak isimlendirilir. Sayısal sınıflandırıcılarda istatistiksel prensipler kullanılır. Sayısal sınıflandırıcıların aksine sözdizimsel sınıflandırıcılar da ise konuşma dilinde kullanılan örüntülerin sözdizimsel dizimleri kullanılır (Paulus and Hornegger, 2003).

Sınıflandırma her gözlenen örüntüyü bu ayırmadaki tek bir sınıfa atar. Sınıflandırma için sınıflara ait belirli sayıdaki öznitelik vektörünün oluşturduğu “veri kümeleri” bir öğrenme (eğitim) sürecinden geçirilir. Bunun sonucunda, bilinmeyen örüntüyü uygun sınıfa atamakta kullanılan bir karar kuralı ya da mekanizması elde edilir. Bir eğitim kümesi ve bazı önsel olasılıklar temel alınarak gerçekleştirilen sınıflandırma yaklaşımı “güdümlü sınıflandırma” olarak adlandırılır. Herhangi bir önsel bilgi ve eğitim kümesi kullanılmadan gerçekleştirilen sınıflandırma ise “güdümsüz sınıflandırma”dır. Güdümsüz sınıflandırmada, örüntü sınıflarının sayısı ve sınıfların kendileri bilinmediğinden, sınıflar ve öznitelik uzayının işaret ettiği bölüm öğrenme aşamasında belirlenmelidir (Duda et al., 2001; Theodoridis and Koutroumbas, 2003; Paulus and Hornegger, 2003).

1.5 Tez Çalışması

Bu tez çalışmasında, Fraktal Boyut (FD) kavramı örüntü tanımanın önemli konuları olan öznitelik çıkarımı ve seçiminde kullanılmıştır.

Bölüm 2’de, başlangıç olarak FD hakkında temel bilgilere yer verilmiştir. FD’un gerçek hayattaki nesnelere tanımlamadaki başarımı açıklanmış ve klasik geometrideki boyutlarla karşılaştırılmıştır. Ardından, gri seviye görüntüler için 3-boyutlu düzlemde kullanılan FD hesaplama yöntemi açıklanmıştır. Ayrıca öznitelik seçiminde kullanılan fraktal temelli ilinti boyutu hesaplama yöntemi hakkında bilgi verilmiştir.

Bölüm 3’te, klasik hesaplama yöntemleriyle elde edilen FD bilgisi, video kesme geçişlerinin belirlenmesi uygulamasında öznitelik çıkarımı amacıyla kullanılmıştır. Literatürde, bu uygulamaya yönelik olarak kullanılan öznitelik çeşitleri açıklanmış ve FD temelli öznitelikler ile karşılaştırması yapılmıştır. Konu ile ilgili yapılan deneysel çalışmanın sonuçları, FD temelli özniteliklerin diğer öznitelikler kadar başarılı olduğunu göstermektedir. Sonraki adımda, FD temelli öznitelik çıkarımında iyileştirmeler yapılarak sadece kesme geçiş belirleme başarımını artırmakla kalmayıp

ayrıca FD hesaplamadaki işlem karmaşıklığı da azaltılmıştır. Ayrıca, farklı video kesme geçiş türlerinin belirlenebilmesi için klasik eşikleme yöntemine alternatif olabilecek örüntü sınıflandırıcı temelli bir yöntem önerilmiştir. Sonraki aşamada, HSV renk uzayında yapılan FD ölçümlerinin görüntü bölütlemeye kullanımı incelenmiştir. Bu amaçla, farklı bitki türlerini içeren görüntülerin HSV renk bileşen değerleri ile bunlardan elde edilen bölgesel FD bilgileri kullanılarak öznelik çıkarımı yapılmıştır. Bu öznelikler daha sonra Bayes sınıflandırıcıya verilerek ilgili bitki türleri sınıflandırılmıştır. Deneysel sonuçlar, HSV bileşenleri yardımıyla elde edilen FD temelli özneliklerin, yalnızca gri seviye değerleri kullanılarak çıkarılan öznelikler kadar iyi sonuç verdiğini göstermektedir. Tüm öznelikler birlikte kullanıldığında ise çok daha iyi bir başarıya ulaşıldığı gözlenmiştir.

Bölüm 4'te ise FD bilgisi ayırdedici öznelik seçiminde kullanılmıştır. Bu çalışmada, fraktal temelli ilinti boyutundan faydalanarak özneliklerin ayırdedicilik seviyelerinin belirlenmesi amaçlanmıştır. Çalışmanın uygulaması olarak beton gücünün belirlenmesinde beton bileşenlerinin katkısı tespit edilmiştir. Bu amaçla, bileşenlerdeki farklılıklar fraktal boyuttaki değişimlerle ilişkilendirilmiştir. Kapsamlı bir veritabanında yapılan deneysel çalışmalar, uygun bileşenleri kullanarak daha kuvvetli beton üretme ve dolayısıyla daha dayanıklı yapılar inşa etmede yol gösterici olabilecek sonuçlar vermiştir.

Bölüm 5, tez kapsamında yapılan tüm deneysel çalışmaları içermektedir. Her deneysel çalışma için, kullanılan veritabanı hakkında bilgi verilmiş, deney sonuçları çizelgeler ve şekiller yardımıyla açıklanmış ve sonuçların analizi yapılmıştır.

Bölüm 6, tez çalışması kapsamında yapılan araştırmalara ve geliştirilen yöntemlere dair genel sonuçları içermektedir.

BÖLÜM 2

FRAKTAL GEOMETRİ


Fraktallar adı verilen, fraktal nesnelerin özellikleri ile ilgilenen fraktal geometri, son yıllarda birçok bilim ve mühendislik dalında kullanılmasıyla birlikte oldukça hızlı ilerleme kaydetmiştir. Fraktallar doğada bulunabildikleri gibi, matematiksel yöntemlerle de oluşturulabilirler (Addison, 1997). Latince “düzensiz veya parçalanmış” anlamındaki “fractus” sıfatından gelen fraktal geometri, kıyı şeridi ve manzara gibi doğal oluşumların karmaşık yapılarının karakteristiklerini tanımlayan, ilk kez Mandelbrot (1977) tarafından geliştirilen bir yaklaşımdır (Sun, et al., 2006).

Mandelbrot’a (1983) göre, doğadaki insan yapımı olmayan çoğu nesne, standart geometrik şekillerle tanımlanamayacak derecede karmaşık yapıya sahiptir. Klasik geometri olarak kabul edilen Öklit geometrisi doğadaki bulutları, dağları, kıyı şeritlerini veya ağaç yapılarını tam anlamıyla tanımlayamaması nedeniyle sıklıkla “katı” ve “keskin” olarak tanımlanır. Çünkü, tam olarak bulutlar küre, dağlar koni, kıyı şeritleri yuvarlak, ağaç kabukları da pürüzsüz değildir. Mandelbrot, doğadaki çoğu örüntünün klasik Öklit yapıları ile kıyaslandığında, düzensiz ve parçalı yapılara sahip olduğunu belirtmiştir. Uygulamada, doğal örüntülerin farklı ölçeklerdeki uzunluklarının sayısı sonsuzdur. Bu şekildeki örüntülerde Öklit Geometrisinin “şekilsiz” olarak nitelendirdiği ve yetersiz kaldığı durumlarda, fraktal geometri oldukça iddialı sonuçlar elde etmiştir. Bu başarılı sonuçlar ile birlikte Mandelbrot doğanın geometrisi ile ilgili, çeşitli alanlarda kullanılabilen yeni bir geometri türü geliştirerek etrafımızdaki birçok düzensiz ve parçalanmış örüntüyü tanımlayabilen yapılara “fraktal” adını vermiştir. Çoğu fraktallar “olasılık” özelliği içerir ve “düzenli” veya “düzensiz” olmaları istatistikseldir. Burada bahsedilen yapılar ölçeklendirilebilir olup düzensizlik veya parçalanma dereceleri tüm ölçeklerde aynıdır. Bazı fraktal kümeler eğriler ve yüzeylerden oluşurken, bir kısmı bağlantısız “toz bulut” larından ve bilimsel veya sanatsal anlamda tam olarak düzgün bir tanımı olmayan, basit bir şekilde tanımlanması güç tuhaf şekillerden oluşabilmektedir.

Doğadaki nesnelerin veya süreçlerin karmaşıklığından yola çıkılarak geliştirilen fraktal geometrinin kapsamında yer alan fraktal boyut (FD), Bölüm 2.1’de klasik geometrideki standart boyut kavramları ile karşılaştırmalı olarak açıklanarak tanımlanmıştır.

2.1 Temel Boyut Kavramları ve Fraktal Boyut


Fraktal Boyut (FD) tanımından önce, temel boyutlardan iki tanesi, Öklit boyutu (D_E) ve Topolojik boyut (D_T) tanımlarını açıklamak yararlı olacaktır. Her iki boyut (D_E , D_T) tanımı da fraktal olmayan tamsayı boyutlarına karşılık gelmektedir. Öklit boyutu en basit şekilde, nesneyi belirtmek için gerekli koordinat sayısı olarak tanımlanır. Öklit geometrisine göre, insanlar çevrelerindeki nesnelere, Şekil 2.1 de gösterildiği gibi, 0-boyutlu (noktalar), 1-boyutlu (çizgiler, eğriler), 2-boyutlu (düzlem, kare), 3-boyutlu (katlar, küp, koni, silindir vb.) olarak algırlar. (Addison, 1997).




Şekil 2.1. Temel tamsayı boyutları (a) Nokta (0-boyut) (b) Çizgi (1-boyut) (c) Düzlem 2-boyut (d) Katı (3-boyut)

Matematikçilerin yüzyıllardır üzerinde çalıştıkları boyut kavramlarından bir diğeri, D_T ’un ise daha karmaşık bir yapısı vardır. Matematiğin bir branşı olan topoloji aslında nitelikli bir bakış açısıyla, şekilleri ve nesnelerin yapılarını içermektedir. Topoloji nesnelerin bir şekil ve yapıdan diğere temel özelliklerini kaybetmeden geçişindeki

durumlarla ilgilenmektedir. Diğer ifade ile, Şekil 2.2 de gösterildiği şekilde, düz bir çizgi, yuvarlak geçişli keskin olmayan bir eğriye dönüşebilir veya kırıklı eğri şeklinde bükülebilir. Topolojide belirli dönüşümler altında, kesin olan özellikler sabittir. Örneğin bir nesne içerisindeki delikler, nesne şekil değişirse de hala mevcut kalacaktır. Şekil 2.3 deki yüzeylerin herbirinde iki tane delik vardır, bu şekillerin hepsinin topolojik boyutları aynıdır (Addison, 1997).



Şekil 2.2. Topolojik eşdeğer eğriler (a) Düz çizgi (b) Eğri (c) 'Kırıklı Eğri'



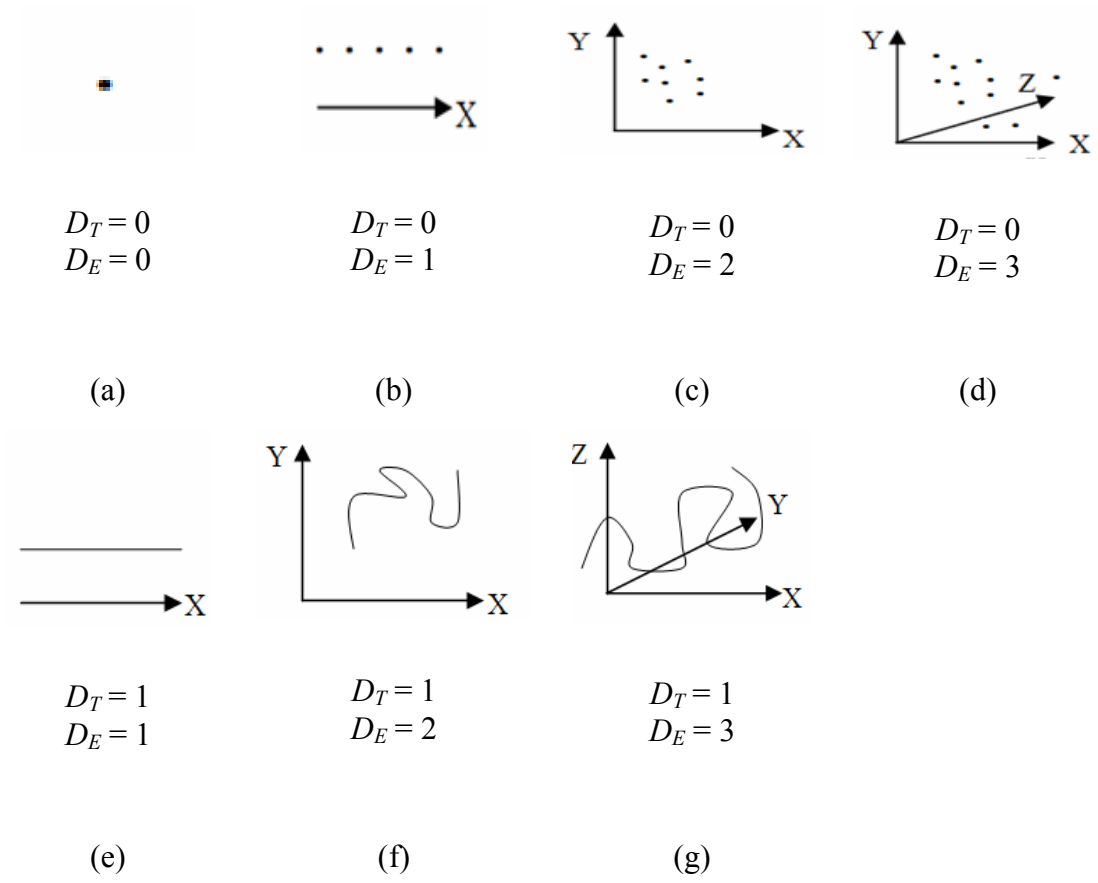
Şekil 2.3. Topolojik eşdeğer yapılar (iki delikli yüzeyler)

Şekil 2.4' de nokta, doğru parçası ve eğrilerin değişik durumlardaki D_E ve D_T değerleri karşılaştırmalı olarak verilmektedir (Addison, 1997). Bu şekle göre, her durumda noktanın D_T 'nin '0' olduğu görülmektedir. Ancak D_E 'nin içinde bulunduğu koordinat sayısına göre '0', '1', '2', '3' şeklinde değiştiği gözlenmektedir. Şekil 2.4 (e), (f) ve (g) deki, doğru parçaları ve eğri için ise, yine D_T sürekli '1' değerini verirken, D_E 'nin yine koordinat sayısına göre '1', '2' ve '3' olarak farklı değerler verdiği gözlenmektedir. Ayrıca doğru parçası ve eğri yapısal olarak farklı olmalarına rağmen, D_T değerleri aynı kalmakta ve topolojik boyut ayırdedici bir özellik


sağlayamamaktadır. Nokta ve eğri farklı yapısal özelliklere sahip olmalarına rağmen, aynı koordinat sayılarına sahip ortamlarda iken (Şekil 2.4 (c) ve (f)), aynı D_E değerine sahip olmaktadır. D_E değeri de ayırdedici bir özellik olarak kullanılamamaktadır. Oysa ki Mandelbrot'un da ifade ettiği gibi doğadaki nesnelere ve süreç sinyalleri Öklit geometrisi ile tanımlanamayacak kadar karmaşık ve düzensiz yapılara sahiptirler. Doğadaki bu örüntüleri daha hassas ve mümkün olduğunca kendilerine özgü karakteristikte ifade edebilecek bir boyut kavramı kullanılması gerekmektedir. Böyle durumlarda fraktal geometri yardımıyla hesaplanan FD ayırdedici bir çözüm sunmaktadır.

'Fraktal' en basit şekilde, değişik ölçeklerdeki oranlarda kendine-benzerlik özelliği taşıyan nesnelere olarak tanımlanabilir. Fraktal boyut (FD) ise, bir ölçekteki öznitelik sayısının bir diğer ölçekteki öznitelik sayısına oranını ifade eder (Albrechtsen, et al.,1992). Bu tanım aynı zamanda fraktalların kendine benzeşim özelliğini de açıklamaktadır. Fraktallar, boyutlarının kesirli olması yanında kendine benzerlik özelliğine de sahiptir. Fraktalların tamsayı olmayan ve topolojik boyuttan büyük, Öklit boyutundan küçük olan kendine özgü bir boyutu vardır.

Fraktal yapılarda, nesnenin her küçük parçası, tüm yapıda kendini tekrar etmektedir. Şekil 2.5' de kıyı şeridinde ve bir insana ait çizimler yer almaktadır. Kıyı şeridi çizimine yakından baktığımızda, engebeli yapısı değişik ölçeklerde tekrar etmektedir ve her yeni ölçeklendirmede bu olay devam etmektedir. Bu durum kıyı şeridi şeklinin fraktal bir eğri olduğunu göstermektedir. Diğer yandan bir insana ait çizim incelendiğinde, kendine benzer olmadığı anlaşılır. Çünkü insanın değişik bölgelerine görüntüyü yaklaştırdığımızda, değişik yapılar elde ederiz. Örneğin el tüm vücuda benzememektedir, parmaktaki tırnak, ele benzememektedir. Bu da insan vücudunun fraktal olmadığını göstermektedir. Ancak son yıllardaki çalışmalarda, insan vücudunun dışarıdan ana hatlarla incelendiğinde fraktal yapı göstermemesine rağmen, iç organlar incelendiğinde ciğerler, beyin hücreleri gibi bazı organların iç yapılarında fraktal yapı gösterdiği anlaşılmıştır (Addison, 1997).



Şekil 2.4. Temel şekillere ait Öklit ve Topolojik boyutlar (a) Tek nokta (b) Doğrudaş noktalar kümesi (c) Düzleme yayılmış noktalar kümesi (d) Uzaya yayılmış noktalar kümesi (e) Doğru parçası (f) Düzlemdeki eğri (g) Uzaydaki eğri



Şekil 2.5. (a) Fraktal nesne, (b) Fraktal olmayan nesne (Addison'dan, 1997)

Şekil 2.6'da bazı doğal fraktal yapılar yer almaktadır. Tüm durumlarda kendine benzerlik özelliği bulunmaktadır. Kendine benzer şekillerde, şekli oluşturan parçalar şeklin bütününe benzemektedir. Örneğin eğrelti otunun her yaprağı bitkinin tümünün minik birer kopyasıdır. Bitkinin uç kısmına gidildikçe daha küçük kopyalar gözlenmektedir. Doğadaki çoğu bitki yapıları da aynı karakteristik yapıya sahiptir. Bu şekiller 2-boyutlu bir düzlemde bulunmaktadır, ancak çoğu fraktal yapı 3-boyutlu bir ortam gerektirmektedir (Addison, 1997).

Benzerlik Boyutunu (D_s) daha iyi açıklamak için, Şekil 2.7 deki çizgi, kare ve küp şekilleri ele alınarak, r uzunluğunda alt-uzunluk, alt-alan ve alt-hacimlere bölünmektedir (Addison, 1997). İşlemleri basitleştirmek için, uzunluk (L), alan (A) ve hacim (V) değerlerinin hepsi birim uzunlukta kabul edilmektedir. Bu durumda,

$$Nr^{D_s} = 1 \Rightarrow D_s = \frac{\log(N)}{\log(1/r)} \quad (2.1)$$


denklemini elde edilir. Bu denklemde D_s benzerlik boyutunu, diğer bir ifade ile FD 'u göstermektedir.



(a)



(b)




(c)



(d)

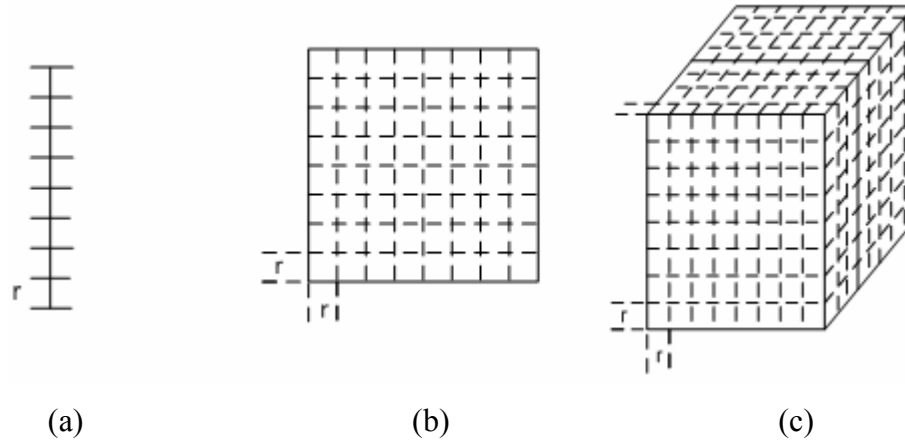


(e)



(f)


Şekil 2.6. Doğadaki bazı fraktal yapılar (Miqel, 2010) (a) Eğrelti otu, (b) Ağaç dalları, (c) Kıyı şeridi, (d) Bitki yaprağı, (e) Şimşek görüntüsü, (f) Bakteri (Bildirgeç, 2010)



Şekil 2.7. Temel geometrik nesnelere kendine benzer şekiller oluşturma (a) Doğru Parçası (uzunluk=L), (b) Kare (Alan=A), (c) Küp (Hacim = V)

Kendine benzer şekiller büyütüldükleri zaman yine aynı görünümlerini korurlar. Birçok matematiksel yapı fraktal olup, kendisine hemen hemen benzeyen parçalarının birleşiminden oluşur. Örneğin, Von Koch eğrisi, Cantor kümesi ve Sierpinski üçgeni bunlardan bazılarıdır.


Şekil 2.8’ de Von Koch eğrisine ait işlem aşamaları gösterilmektedir. İlk aşamada birim uzunluktaki doğru parçası alınarak, üç eşit parçaya ayrılır ve ortadaki kısmı atılır. Sonraki aşamada atılan doğru parçasını taban kabul eden eşkenar üçgen çizilir. Elde edilen bu şekilde bulunan her bir doğru parçasına aynı işlemler uygulanır. Aynı işlemler sonsuza kadar devam edildiğinde, teorik olarak limiti Von Koch eğrisini verecektir. Bu eğri için, denklem (2.1) deki eşitlik kullanılırsa, $FD_{\text{Von Koch}} = \log(4) / \log(3) = 1.26$ olarak elde edilir. Von Koch eğrisi için, diğer bütün eğrilerde olduğu gibi $D_T = '1'$ olarak elde edilirken, FD yardımıyla kendine özgü bir boyut değeri hesaplanabilmektedir.



Şekil 2.8. Von Koch eğrisinin kendine benzeşim yoluyla oluşturulması

Von Koch eğrisi örneğinde olduğu gibi, düz bir çizginin FD'u, düzensiz karakteristik gösteren bir başka doğrunun FD'undan daha düşüktür. Ancak tüm eğriler için D_T değerinin '1' kabul edilmesi, farklı şekiller ve kıvrımlarla oluşmuş eğriler arasındaki farkları çıkarmada yetersiz kalmaktadır. Oysa ki, FD değeri eğrinin kıvrımlarına göre değişeceği için ayırtedici bir öznelik olarak kullanılabilir. Aynı yaklaşım 3-boyutlu yüzeylerde de ayırtedici bir kolaylık sağlayacaktır. Bu tez kapsamında geliştirilen çalışmalarda da öznelik çıkarımında 3-boyutlu yüzeyler kullanılmıştır. Düz bir yüzeyin FD'u, pürüzlü yüzeyin FD'undan daha düşüktür. Düz yüzeyin FD'u 2.0 iken, pürüzlü yüzeyin FD'u 3.0 a yaklaşmaktadır. En uygun boyut yaklaşımı fraktal geometri kavramları ile elde edilir. Şekil 2.9'da farklı renk tonlarındaki görüntüler ve hesaplanmış FD ları verilmiştir. Şekil 2.9 (a) ve (b) de gri ve siyah renkteki düzlem görüntülerinin FD ları 2.0 olarak hesaplanırken, Şekil 2.9 (c) de grinin farklı renk tonlarına sahip, Lenna görüntüsünün fraktal boyutu 2.381 olarak elde edilmiştir. Tüm yüzeyin aynı renk tonuna sahip olması, görsel olarak pürüzlülüğün

bulunmaması anlamına gelmesinden dolayı, farklı renklerde olsalarda düz-gri ve düz-siyah yüzeylerin aynı FD değerini vermesini sağlamaktadır.



Şekil 2.9. (a) Gri renkli düzlem $FD_{gri} = 2.000$ (b) Siyah renkli düzlem $FD_{siyah} = 2.000$
(c) Lena görüntüsü $FD_{LENNA} = 2.381$

FD'un, benzerlik boyutu (D_S), bölen boyutu (D_D), Hausdorff boyutu (D_H), kutu sayma boyutu (D_B), ilinti boyutu (D_C), bilgi boyutu (D_I), nokta tabanlı boyut (D_P), ortalanmış nokta tabanlı boyut (D_A) ve Lyapunov boyutu (D_L) gibi tanımları içeren birçok tanımları bulunmaktadır (Addison, 1997). Fraktal Geometrinin değişik bilim dallarında kullanımının artışıyla birlikte, değişik FD hesaplama yöntemleri geliştirilmiştir. FD hesaplama yönteminin şekli, kullanım amacına ve algoritma karmaşıklığına bağlıdır. Bununla birlikte tüm bu yöntemler Hausdorff Boyutu ile aynı prensibe sahiptirler (Barnsley, 1988). Teorik olarak, A kümesi tarafından sınırlı Hausdorff- Besicovitch (D) boyutu, \mathbb{R}^n de, A nın geometrik karmaşıklığını karakterize etmek için kullanılan gerçel bir sayıdır. Burada bahsedilen A kümesinin D boyutu eğer D_T 'dan oldukça büyük ise, fraktal küme olarak adlandırılır (Sarkar and Chaudhuri, 1994). Öklit uzayının alt kümesi olan X 'in Hausdorff boyutu olan D , X 'i kaplayan yuvarların minimum sayısı olarak tanımlanır.

A kümesinin kutu sayma boyutu D_B şu şekilde tanımlanır:

$$D_B = \lim_{r \rightarrow 0} \frac{\log(v(r))}{\log(1/r)} \quad (2.2)$$

Denklemdaki $v(r)$ A kümesini kaplayan r büyüklüğündeki kutuların sayısıdır (Mandelbrot, 1977). Kutu sayma yönteminin algoritmik karmaşıklığı veri kümesinin uzunluğuna bağlı olarak üstel olarak artmaktadır.

Gerçek uygulamalarda FD hesaplanmasında, teorik tanımlara bağlı kalarak, genellikle “Kutu Sayma Yöntemi” gibi yaklaşım sağlayan yöntemler kullanılır (Barnsley, 1988). Her r ölçeği için elde edilen $v(r)$ değerleri, tanımlı aralıkta hesaplanır. Daha sonra x eksenine $\log(v(r))$, y eksenine $\log(1/r)$ değerleri gelecek şekilde eğri çizilir. Bu eğriye “Doğrusal En Küçük Kareler Yaklaşımı” yöntemi (Yazıcı, A., Selbes C.F., 1989) ile doğru uydurulur. Bu doğrunun eğimi FD’ u verir.

2.2 Görüntülerde Fraktal Boyut Hesaplama Yöntemi

FD görüntü içerisindeki pürüzlülük ve kendine-benzeşim gibi özniteliklerin çıkarılmasında kullanılan önemli bir yöntemdir. Bu özellik, medikal ve uydu görüntüleri gibi alanlarda doku bölütlenmesinde, sınıflandırmada, şekil analizinde ve benzeri problemlerin çözümünde kullanılmaktadır. Görüntülerden öznitelik çıkarılmasında ve bölütlemeye, insan gözünün algılaması ile fraktal boyut kullanılarak hesaplama arasında kuvvetli bir ilinti olduğu gözlemlerle anlaşılmıştır (Liu and Li, 1997). FD, fraktal-tabanlı bölütleme, sınıflandırma ve şekil analizi gibi örüntü tanıma yöntemlerinde öznitelik olarak kullanılabilir. Fraktal öznitelikler görüntü sıkıştırma, bölütleme gibi alanlarda da kullanılmaktadır (Feng, et al., 1996).


(Sarkar and Chaudri, 1994) çalışmasına göre görüntünün FD'ünü hesaplamak için, gri seviye değerleri 3-boyutlu yüzey olarak kabul edilir. Şekil 2.10-a' daki gri seviye görüntüye ait 3-boyutlu görüntüsü Şekil 2.10-b'de yer almaktadır. Gri seviye görüntülerde FD, "battaniye" yöntemi olarak da adlandırılan ve çok bilinen Farka Dayalı Kutu sayma (DBC) yöntemi ile hesaplanmaktadır.

Ölçekleme oranı (r) için ve s bir tamsayı iken,


$$r = (s / M) ; 1 < s \leq (M / 2) \quad (2.3)$$

denklemleri kullanılarak, $M \times M$ ölçülerindeki görüntü, Şekil 2.11'de gösterildiği gibi $s \times s$ boyundaki alt bölgelere ölçeklendirilmektedir.

Görüntü yüzeyi (x, y, z) eksenleri kullanılarak 3-boyutlu modellenmektedir. x ve y 2-boyuttaki koordinatları, z eksenini ise gri seviye değerini göstermektedir. (x, y) düzlemi $s \times s$ boyunda ızgaralara bölündükten sonra, her ızgara $s \times s \times h$ ölçülerindeki kutu kolonlarından oluşur. Toplam gri seviye sayısı G olmak üzere, $(G / h) = (M / s)$ dir.



(a)



(b)

Şekil 2.10. (a) 100×100 boyunda gri seviye görüntü. (b) (a) daki görüntünün 0-255 arası gri renkte 3-boyuttaki da yeğinlik yüzeyi

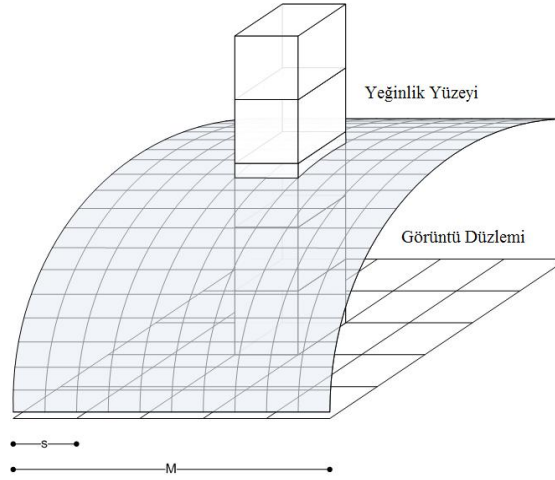
(i, j) ninci ızgaradaki minimum ve maksimum gri seviye değeri sırasıyla k ve l olarak kabul edilir. Her (i, j). ızgara için $n_r(i, j)$,

$$n_r(i, j) = l - k + 1 \quad (2.4)$$

olarak hesaplanır. Tüm ızgaraların katkısı ile N_r ,

$$N_r = \sum_{i,j} n_r(i, j) \quad (2.5)$$

denklemleri ile hesaplanır.




Şekil 2.11. $M \times M$ ölçülerinde $s \times s$ boyundaki alt bölgelere ölçeklendirilen görüntü yeğinlik yüzeyi

r ve s nin farklı deęerleri için N_r deęerleri elde edilir. FD, denklem (2.2) de yeralan yaklařım kullanılarak, grnt yzeyi iin kutu sayma boyutu D_{B_image} ,

$$D_{B_image} = \lim_{r \rightarrow 0} \frac{\log(N_r)}{\log(1/r)} \quad (2.6)$$

řeklinde elde edilir. $\log(N_r) - \log(1/r)$ grafięindeki deęerlere ‘‘Doęrusal En Kk Kareler Yaklařımı’’ yntemi (Yazıcı, A., Selbes C.F., 1989) kullanılarak, belirlenen doęrunun eęiminden FD elde edilir (řekil 2.12).



řekil 2.12. En kk kareler yaklařımı yntemi ile FD hesaplama

2.3 Fraktal Temelli İlinti Boyutu Hesaplama Yntemi

Hem yapay hem de gerek bilgiyi ieren veri kmelerinin gerek boyutlarını tahmin etmede fraktal teknikler kullanılabilir (Camastra and Vinciarelli A, 2002). rnt tanıma, sınıflandırma, kmeleme gibi alanlarda kullanılan veri tabanlarındaki znelikler vektrler halinde \mathbb{R}^d uzayında gmldrler. Fazla boyut daha fazla

depolama ortamı gerektirecektir ve algoritma karmaşıklığı da artacaktır. Bu nedenle Bölüm 1.3 de açıklandığı gibi öznitelik seçimi örüntü tanıma için gerekli bir ara işlemdir.

Bilgi kaybı olmaksızın, veriyi ifade edebilen minimum serbest değişken sayısı gerçek (intrinsic) boyutu verir (Camastra and Vinciarelli, 2002). Veri kümesinin gerçek boyutunun belirlenmesinde, hangi özniteliğin veri kümesi için önemli olduğu saptanmaktadır. Son yıllarda bir takım fraktal boyut tabanlı öznitelik seçim algoritmaları ve yöntemleri önerilmiştir (Traina, et al. 2000; Zhang, et al. 2002; Bhavani, et al., 2008). Bunlardan bir kısmı veri kümesindeki tüm özniteliklerin fraktal boyutunu kullanırken, bir kısmı ise her özniteliğin fraktal boyutunu ayrı ayrı bulmaktadır. Önceleri ilinti boyutu bir işlemin deterministik olup olmadığını belirlemek için kullanılmaktaydı (Islıker, 1992). Geniş veri kümelerinin FD'larını tahmin etmede kullanılan en kolay hesaplanabilen yöntem (Grassberger and Procaccia, 1983) tarafından önerilen ve GP algoritması olarak bilinen ilinti boyutudur (Camastra and Vinciarelli, 2002).

GP algoritmasına göre, ilinti boyutu (D_C),

$$D_C = \lim_{r \rightarrow 0} \frac{\log C(r)}{\log r} \quad (2.7)$$

denklemleri ile elde edilmektedir. Buradaki $C(r)$

$$C(r) = \lim_{N \rightarrow \infty} \frac{2}{N(N-1)} \sum_{i=1}^N \sum_{j=i+1}^N H(\|X_j - X_i\| \leq r) \quad (2.8)$$

denklemleri ile belirlenir.

Yukarıdaki denklemde, N veri dizisinin uzunluğunu, $\|X_j - X_i\|$ ise X_i ile geri kalan tüm diğer $(N-1)$ nokta arasındaki Öklit uzaklığını göstermektedir. $H(u)$ belirteç fonksiyonu (Heaviside fonksiyonu)

$$H(u) = \begin{cases} 0, & u < 0 \\ 1, & u \geq 0 \end{cases} \quad (2.9)$$

şeklinde tanımlanır.

Elde edilen $\log C(r) - \log r$ grafiğinin doğrusal bölümüne, önceki bölümlerde anlatılan FD belirleme işlemlerinde olduğu gibi, “Doğrusal En Küçük Kareler Yaklaşımı” yöntemi (Yazıcı, A., Selbes C.F., 1989) uygulanarak elde edilen doğrunun eğimi, ilinti boyutunu verecektir (Camastra and Vinciarelli, 2002; Jiang, et. al, 1999)

BÖLÜM 3

FRAKTAL BOYUT YARDIMIYLA ÖZNETELİK ÇIKARIMI

Bu bölümde, tez çalışması kapsamında FD un öznitelik olarak kullanıldığı video kesme geçişleri ve bitki sınıflandırması ile ilgili bilgiler yer almaktadır.

Bölüm 3.1 de, FD temelli öznitelik çıkarımı yönteminin öncesinde, literatürdeki temel video kesme geçişi amaçlı öznitelik çıkarım yöntemlerinden ve bunlarla elde edilen öznitelikleri değerlendirmede kullanılan Dinamik Eşikleme Yönteminden (DTM) bahsedilmiştir. Daha sonra, tez kapsamında geliştirilen, başarımlarına ait deneysel çalışmaları Bölüm 5.1 de verilecek olan, FD temelli video kesme geçişlerinin belirlenmesi ile ilgili yöntem açıklanmıştır. Ayrıca FD temelli öznitelik çıkarımı yönteminin başarımlarını ölçme aşamasında, DTM yöntemine alternatif olarak, eğitim aşamasından sonra otomatik karar verebilen Bayes sınıflandırıcısı kullanım yöntemi açıklanmıştır.


Bölüm 3.2 de ise, bitkilerin sınıflandırılması ile ilgili genel bilgiler verilmiş olup, başarımlarına ait deneysel çalışmaları Bölüm 5.2 de verilecek olan FD temelli öznitelik çıkarım yöntemi açıklanmıştır.

3.1 VİDEOLARDA KESME GEÇİŞLERİNİN BELİRLENMESİ

Video, bilginin ses ve görüntü olarak bir arada bulunan şekli olarak tanımlanabilir. İletişim teknolojileri, bilgisayar performansı ve depolama araçlarındaki hızlı gelişme ile birlikte, videonun internet konferansı, çoklu ortam sistemleri, e-öğrenme ve video tabanlı istek sistemleri gibi değişik alanlarda kullanımı artmıştır. Videonun kullanım alanlarının genişlemesiyle birlikte, büyük veri tabanlarındaki video

sahnelerinin düzenlenmesi ve çağrılması gereksinimi de ön plana çıkmıştır. Böylece, videolardaki sahne analiz işlemleri önemli bir araştırma konusu haline gelmiştir (Fernando, et al., 2000, 2001).

Sahneler, durgun veya değişken kamera hareketleri ile elde edilen video çerçeve dizilerinin kesintisiz parçalarının anlamsal olarak teker teker ilişkilendirilmesi ile oluşur (Marques and Furht, 2002). Bu yüzden, sahne analizi için, video içeriklerinin anlamlı bölümler halinde düzenlenmesinde, kesme geçişlerinin doğru bir şekilde belirlenmesi önemli bir rol oynamaktadır. Kesme geçişleri ani veya dereceli olabilmektedir. Ani kesme geçişinde, videodaki değişim tek bir çerçevede oluşmaktadır. Dereceli geçişlerde ise, değişim kısa bir çerçeve dizisi boyunca oluşmaktadır (Şekil 3.1). Dereceli geçişler kendi içerisinde ise karararma, çözülme, süpürme, gürültü ve kamera hareketleri(yatay hareket, dikey hareket, zumlama) gibi alt gruplara ayrılmaktadır (Lu and Tan, 2005). Dereceli geçişlere ait video çerçeve örnekleri Şekil 3.2-3.7 arasında yer almaktadır.



Şekil 3.1. Video sahnesindeki kesme geçiş tipleri



(a)




(b)

Şekil 3.2. Ardışık çerçevelerdeki ani kesme geçişi (a) k. Çerçeve (b) (k+1). Çerçeve



Şekil 3.3. Çözülme (dissolve) tipi kesme geçişine örnek ardışık video çerçeveleri



(a)

(b)

(c)

(d)

Şekil 3.4. Gürültü içeren ardışık video çerçeveleri



(a)

(b)

(c)



(d)

(e)

(f)

Şekil 3.5. Yatay kayma hareketine(panning) örnek ardışık video çerçeveleri



Şekil 3.6. Süpürme tipi (wipe) kesme geçişine örnek ardışık video çerçeveleri



Şekil 3.7. Zumlama(zooming) tipi kesme geçişine örnek ardışık video çerçeveleri

3.1.1 Mevcut Video Kesme Geçişi Belirleme Yöntemleri

Kesme geçişlerinin bulunmasında kullanılan yöntemin başarımı, video içeriğini temsil eden özneliklere bağlıdır. Mevcut kesme geçiş belirleme yöntemleri genellikle ardışık video çerçevelerinin farklarını kullanmaktadır. En temel ve sık kullanılan yöntemler piksel ve histogram farklarına dayalı çalışan yöntemlerdir (Boreczky and Rowe, 1996; Ekin, 2003; Zhang, et al., 1993).

En temel piksel farkına dayalı yöntemlerden birisi, mutlak değer farklar toplamıdır. Bu yöntemde, ardışık çerçevelerdeki görüntülerin piksel yeğinliklerindeki genel değişimi yansıtacak şekilde piksel renk değerlerinin farkları alınmaktadır (Korpi-Anttila, 2002; Boreczky and Rowe, 1996). f_1 ve f_2 değerleri ilgili çerçevelerin yeğinlik renk fonksiyonlarını, X ve Y çerçevelerin yükseklik ve genişliklerini, x ve y ise çerçevedeki piksel koordinatlarını belirtmek üzere, iki ardışık çerçeve arasındaki SAD değeri,

$$SAD(f_1, f_2) = \frac{1}{X \times Y} \sum_{x=0}^{X-1} \sum_{y=0}^{Y-1} |f_1(x, y) - f_2(x, y)| \quad (3.1)$$

şeklinde elde edilmektedir. Ancak piksel farkına dayalı yöntemlerin tümünün gürültü ve kamera hareketlerine duyarlı olmaları gibi dezavantajları bulunmaktadır (Korpi-Anttila, 2002).

Kesme geçişi belirlenmesinde, sıkça kullanılan yöntemlerinden biri de histogram farkı yöntemidir. Bir görüntünün histogramı, piksel renk değerlerin dağılımını göstermektedir. Gri seviye ve renkli videoların histogramları ardışık çerçeveler arasındaki farkı ölçmede oldukça yararlı bir araçtır (Korpi-Anttila, 2002; Zhang, et al., 1993; Nagasaka and Tanaka, 1992; Tonomura, 1991). Histogram eğrisindeki her değere karşılık gelen histogram değerini ayrı ayrı birbirinden çıkararak bulunan fark

(B2B) ve histogram kesişimi farkı (INT) gibi değişik histogram yöntemleri bulunmaktadır (Gargi, et al., 2000; Swain and Ballard, 1993).

Ardışık çerçevelere ait histogram değerleri h_1 , h_2 ve piksel sayısı N olmak üzere, B2B farkı,

$$B2B(h_1, h_2) = \frac{1}{2N} \sum_i |h_1[i] - h_2[i]| \quad (3.2)$$

denklemleri ile hesaplanır.

Ardışık iki çerçeveye ait histogram kesişimi (HI),

$$HI = \frac{\sum_i \min(h_1[i], h_2[i])}{N} \quad (3.3)$$

şeklinde hesaplanarak, histogram farkı (INT) ise

$$INT = 1 - HI(h_1, h_2) \quad (3.4)$$

denklemleri ile elde edilir.

(Boreczky and Rowe, 1996; Zhang, et al., 1993) deki çalışmalarda değişik piksel ve histogram tabanlı yöntemler karşılaştırılmış olup, hız ve başarımları açısından en iyi sonuçların histogram tabanlı yöntemlerle elde edilmiş olduğu belirtilmiştir. Ancak bu yöntemlerin gürültülere, kamera, ani ve büyük nesne hareketlerine duyarlı olması dereceli geçişlerin belirlenmesini zorlaştırmaktadır.

Kesme geçişlerini belirlemede, özneliklerin elde edilmesinden sonra ayırdedici bir eşikleme yöntemi yardımıyla değişimin olduğu noktaların belirlenmesi gerekmektedir. Değişik eşikleme yöntemleri (Gunsel and Tekalp, 1998; Meng, et al, 1995; Wang and Weng, 2000) arasında en belirgin yaklaşım sabit eşik değeri

kullanmaktır. Ancak bu yaklaşım, her video için başarılı sonuçlar vermeyebilir. Eşik değerinin yüksek kullanılması, eksik tanıma sayısı artırırken, düşük eşik değeri yanlış tanıma sayısını arttıracaktır.

(Youm and Kim, 2003) kaynağında açıklanan, dinamik eşikleme yöntemindeki (DTM) eşik değeri, kesme geçişinin olma ihtimaline ve çerçeve içeriklerinin değişimine göre hesaplanmaktadır. DTM sabit ve dinamik olmak üzere iki farklı aşamadan oluşmaktadır. Başlangıçta sabit bir eşik değeri kullanılır. İlk kesme geçişi oluştuğundan sonra dinamik eşik değeri devreye girer. Dinamik değer, T_{low} değeri sabit eşik değerini, T_{high} da dinamik değişen eşik değerini göstermek üzere,

$$T_{dyn} = T_{low} + (T_{high} - T_{low}) \cdot f(t) \quad (T_{high} \geq T_{low}) \quad (3.5)$$

denkleminde verildiği şekilde hesaplanır.

Değişken zaman fonksiyonu $f(t)$ doğrusal olarak,

$$f(t) = 1 - \frac{t}{t_{max}} \quad (0 \leq t \leq t_{max}) \quad (3.6)$$

şeklinde hesaplanır. t_{max} değeri ise

$$t_{max}^n = \frac{\sum_{k=0}^{n-1} t_{max}^k}{n-1} \quad (3.7)$$

eşitliği yardımıyla elde edilir.

3.1.2 Video Kesme Geçişlerinin FD Temelli Öznitelikler ve Eşikleme Yöntemi ile Belirlenmesi


Bu bölümde tez çalışması kapsamında, FD bilgisini kullanan yeni bir kesme geçişi belirleme yöntemi geliştirilmiştir. İlk kez Mandelbrot (1977) tarafından önerilen FD,

görüntülerin yüzey karmaşıklığını ve dokusal özniteliklerini ölçmek için önemli bir araçtır. Gerçek dünyadaki bir çok nesne öklit geometrisinde tanımlı küp, koni ve silindir gibi ideal matematiksel şekillerle tanımlanamayacak şekilde karmaşık ve düzensiz yapıya sahiptir. Bu gibi nesnelere FD'ları ile nitelemek daha kolaydır. FD'un görüntünün bozulmasına hassas olduğu kadar, yüzey pürüzlülüğünü ve karmaşıklığını algılamada insan gözü ile kuvvetli bir ilintiye sahip olması, FD'un görüntülerden öznitelik çıkarılmasında ve bölütlemeye kullanılmasına neden olmuştur (Liu and Li, 1997). FD önceleri görüntü işleme ve örüntü tanımanın değişik konularında kullanılmıştır. Gri seviye görüntülerin FD'ları örüntü tanımada bir öznitelik olarak kullanılabilir (Sarkar and Chaudri., 1994). Dokusal bölütleme, sınıflandırma, şekil analizi gibi çalışma alanları, FD'un uydu, medikal ve doğa görüntülerindeki çalışma alanlarından (Véhel and Mignot, 1994; Sato, et al., 1996). Görüntü zumlama (Revathy, et al., 2000), video kodlama (Hufnagl and Uhl, 2000) ve sıkıştırma (Drakopoulos, et al., 2006; Fisher, Y., 1994) da FD'un öznitelik olarak kullanıldığı araştırma konularındandır. (Bach, et al, 2006) çalışması, FD'un sahne analizinde kullanıldığı az sayıdaki çalışmadan birisidir. Bahsedilen bu çalışmada, FD kesme geçişlerinden ziyade sahne çıkarma işlemlerinde kullanılmıştır. Bahsedilen bu çalışmada, kesme geçişleri temel piksel fark temelli olan hareket yeğinlik yöntemiyle gerçekleştirilmiş olup, basit bir eşikleme algoritması kullanılmıştır. Çalışma sonuçlarında da kesme geçişlerinin piksel tabanlı yöntem kullanıldığında, özellikle dereceli geçişlerde başarısız olduğu belirtilmiştir.


Bu tez çalışmasında, kesme geçişi için geliştirdiğimiz yöntemimizde, ardışık çerçeveler için FD farkları elde edilmiştir. FD'un kullanılması, piksel veya histogram bilgisine oranla, görüntü yeğinlik yüzeyinin karmaşıklığını ve video çerçevelerinin dokusal bilgisini daha iyi tanımlayabilmektedir. Böylece kesme geçişi bulunan çerçeveler daha yüksek hassasiyette bulunabilmektedir (Şora Günel, et al., 2009). Kesme geçişlerini belirlemede video çerçevelerinin FD bilgisinin kullanımının yanısıra, geliştirilen yöntemimizde bir diğer yenilik ise alt bölgelerin kullanılmasıdır. Bölgesel olarak FD'ların kullanılması kesme geçişlerinin olduğu çerçeveleri daha iyi vurgulamıştır. Diğer bir yenilik ise FD'un hesaplanması aşamasında geliştirilmiştir. Standart FD hesaplama yöntemi basitleştirilerek hesaplama karmaşıklığı azaltılmıştır.

Geliştirdiğimiz yöntem, spor videolarında test edilmiş olup, literatürde iyi bilinen piksel ve histogram tabanlı yöntemlerle (SAD, B2B, INT) karşılaştırılmıştır. Deneysel sonuçlar, geliştirilen yöntemin mevcut yöntemlerle karşılaştırılabilir başarımlar elde etmesinin yanısıra dereceli geçişlerde mevcut yöntemleri geride bıraktığını göstermiştir.

Geliştirilen yöntemde, “kesme”lere ayrılacak olan video çerçeveleri FD hesaplama aşamasından önce gri seviye görüntülere dönüştürülmektedir. Gri seviye görüntüler Bölüm 2.2 de açıklanan standart DBC yönteminde olduğu gibi 3-boyutlu bir yüzey olarak kabul edilmektedir. Şekil 3.8’ de gösterildiği gibi, video çerçevesinden FD hesaplanırken tüm çerçevedeki renk değerlerini kullanmak yerine eşit dört parçaya bölünerek, bölgesel FD hesaplanmıştır.



(a)



(b)

Şekil 3.8. Ardışık çerçevelerdeki bölgeler (a) Kesme geçişi içermeyen futbol videosu (b) Kesme geçişi içeren tenis videosu

Çerçevelerin kesme geçişlerinin belirlenmesinde kullanılacak olan öznelilikler ise,

$$FDD = \frac{|FD_{a_{k+1}} - FD_{a_k}| + |FD_{b_{k+1}} - FD_{b_k}| + |FD_{c_{k+1}} - FD_{c_k}| + |FD_{d_{k+1}} - FD_{d_k}|}{4} \quad (3.8)$$



denkleminde verildiği şekilde, bölgesel olarak elde edilen FD farklarının ortalaması alınarak elde edilmektedir.

Ardışık çerçeveler arasındaki yüksek miktardaki FD farkı ani geçişi göstermektedir. Oysa ki dereceli geçişler oluş şekilleri açısından kısa zaman penceresinde yavaş yavaş düşük değerde değişim gösterirler. Bu nedenle, FD farklarının tüm çerçeve yerine bölgesel olarak hesaplanması daha verimli sonuçlar verecektir. Şekil 3.9’ da bir test videosuna ait FD öznelilik farkları ile gerçek kesme geçişlerinin grafikleri yer almaktadır. Şekil 3.9-(a)’da örnek bir videoya ait, herbir çerçeveden yalnızca bir adet FD hesaplanarak elde edilmiş fark öznelilikleri, Şekil 3.9-(b)’de ise bölgesel dört adet FD’un farklarının ortalamaları alınarak elde edilmiş fark özneliliklerinin grafiği yer almaktadır. İşaretli noktalar gerçek kesme geçişlerini göstermek üzere, dörde bölünerek bölgesel FD hesaplanması yöntemi diğerine göre geçiş olan noktaları daha iyi vurgulamakta ve fark özneliliklerindeki gürültüyü azaltmaktadır. Bu nedenle FDD hesaplanması aşamasında video çerçevelerinde bölgesel hesaplama yapılmıştır.

Bölgesel FD hesaplama aşamasında Bölüm 2.2 de anlatılan standart DBC yöntemi kullanıldığında, iki ölçek arasındaki mümkün olabilen tüm noktaları hesaplamayı gerektirmektedir. Geliştirilen yöntemde ise seçilen yalnızca iki $\{N_r, r\}$ noktasında FD’u hesaplayarak karmaşıklık azaltılmıştır.

$$FD = \frac{p_2(\log(N_{r_2})) - p_1(\log(N_{r_1}))}{p_2(\log(\frac{1}{r_2})) - p_1(\log(\frac{1}{r_1}))} \quad (3.9)$$

Denkleminde verildiği üzere, ilgili (p_1, p_2) noktaları birlikte bir doğru denklemi oluşturabilirler. Bu doğrunun eğimi de FD'u gösterir. Bu işlem basitleştirilmiş DBC (SDBC) olarak adlandırılmıştır.




Şekil 3.9. FDD öznitelikleri (a) Her çerçeve için tek FD (b) Her çerçeve için dört FD (İşaretli noktalar kesme geçişlerinin olduğu noktaları göstermektedir)

Şekil 3.10-(a)'da örnek bir video çerçevesine ait $(2 \leq s \leq \frac{M}{2})$ aralığında çizilmiş $\log(N_r) - \log(1/r)$ grafiği yer almaktadır. Şekil 3.10-(b)'de ise SDBC yöntemi kullanılarak p_1 ve p_2 noktalarından geçen doğru gösterilmektedir.


Standart DBC yönteminde, $M \times M$ ölçülerindeki bir görüntünün FD'ünü hesaplamada kullanılan N_r nin hesaplama karmaşıklığı $O(M^2)$ dir. $(\frac{M}{2}-1)$ adet r değeri için denklem (2.6) daki yaklaşım kullanılarak, N_r ler elde edilir. Tüm $\{N_r, r\}$ değerlerini kullanarak LSF ile doğru elde etme işleminin karmaşıklığı ise $O(M)$ dir. Böylece DBC algoritmasının tüm karmaşıklığı $O(M^3)$ olacaktır. Oysa ki SDBC yöntemi denklem (3.9) daki yalnızca iki adet $\{N_r, r\}$ çiftini kullandığı için karmaşıklığı $O(M^2)$ olacaktır.

SDBC kullanılarak elde edilen FD fark değerleri standart DBC kullanılarak elde edilenlere oldukça yakındır. Ayrıca, kesme geçişlerinin belirlenmesi aşamasında ardışık çerçevelerin FD farkları kullanılmasından dolayı, FD'un hassas olarak elde edilmesinden daha çok, az zamanda elde edilmesi önem taşımaktadır.

Şekil 3.11 de bir test videosuna ait standart DBC ve SDBC ile elde edilen öznitelikler gösterilmektedir. Şekil 3.11-(a) ve (b) özniteliklerin yanısıra kesme geçişlerin olduğu yerler de açıkça gösterilmektedir. Şekil 3.11-(c)'de iki yöntem arasındaki mutlak fark grafiği de SDBC yönteminin DBC yöntemine oldukça yakın sonuçlar verdiğini göstermektedir.

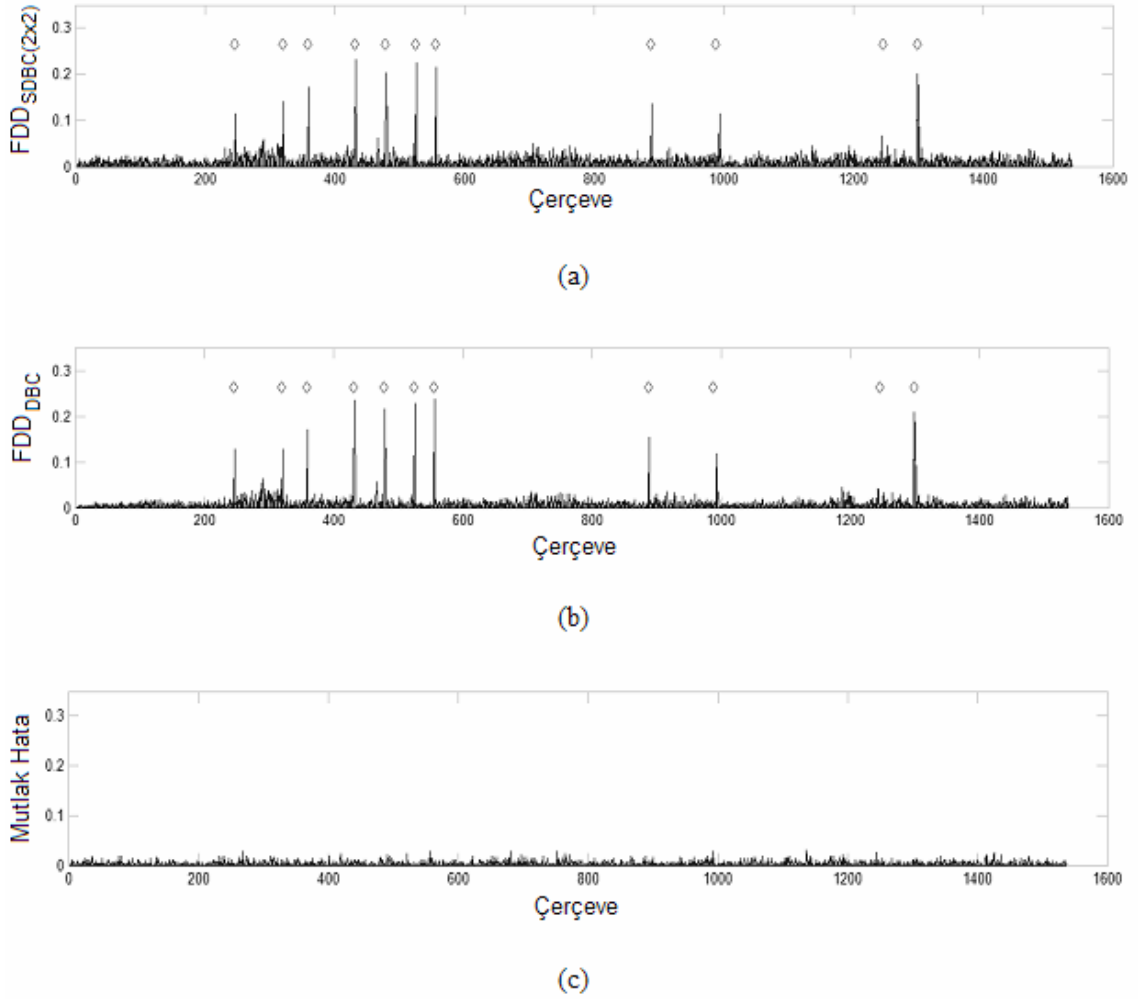


(a)



(b)

Şekil 3.10. Test videosuna ait tek bir video çerçevesi için elde edilen $\log(N_r)$ - $\log(1/r)$ grafikleri (a) $2 \leq s \leq (M/2)$ aralığında DBC yöntemi ile elde edilmiş, (b) DBC yöntemi ile elde edilmiş $\log(N_r)$ - $\log(1/r)$ ve SDBC yöntemi kullanılarak, elde edilen doğru parçası.



Şekil 3.11. Test videosuna ait FDD öznelik değerleri (a) SDBC yöntemi (b) DBC yöntemi (c) DBC ve SDBC arasındaki mutlak hata farkı ($r_{p_1} = 1/4, r_{p_2} = 1/40$). (Grafiklerdeki işaretli noktalar gerçek kesme geçişi olan çerçeveleri göstermektedir)

Daha önce açıklandığı gibi, DBC yönteminde FD hesaplanması için görüntüler $1 < s \leq \frac{M}{2}$ aralığında ($s \times s$) boyunda ızgaralara bölünmüştür. s nin küçük değerleri için ızgaralar az sayıda piksel içereceğinden dolayı, n_r 1 e yakın bir değer olacaktır. Bu nedenle N_r , $1/r^2$ ye eşit olacaktır. s nin küçük değerlerinde doğrunun eğimi değişmektedir (Bkz. Şekil 3.10). Bu problemi gidermek için, s nin minimum değeri 6 olarak seçilmiştir. p_2 noktasındaki r nin alt limiti denklem (2.3) yardımıyla $1/40$ olarak belirlenmiştir. DBC yönteminde N_r $1/r^2$ ile $1/r^3$ arasında değer alacaktır. $s = M/2$ için, N_r (4, 8) aralığında değer alırken $s = M/4$ için, N_r (16, 64) arasında 49 farklı değer alılabilecektir. Bu nedenle p_1 noktasında yeralan, r nin üst limiti ise $1/4$ olarak belirlenmiştir. Böylece N_r hesaplanması daha hassas ve doğru olarak yapılmaktadır. Ayrıca SDBC yöntemi değişik (p_1 , p_2) değerlerinde denenerek, standart DBC yöntemi ile karşılaştırılmıştır. Bu deneyler sonucunda minimum ortalama mutlak hatanın r nin ($1/40$, $1/4$) değerleri için elde edildiği test edilmiştir.

3.1.3 Video Kesme Geçişlerinin FD Temelli Öznitelikler ve Örüntü Sınıflandırıcı ile Belirlenmesi

Eşikleme yöntemlerinin video kesme geçişlerini belirlemedeki başarımı uygun eşik değerlerinin belirlenmesine bağlıdır. Eşik değerlerinin doğru tespit edilemediği durumlarda başarımın düşmesi kaçınılmazdır. Ayrıca, eşikleme yöntemi yalnızca “kesme geçişi vardır” ve “kesme geçişi yoktur” şeklinde ikili sınıflandırma yapabilmekte, tespit edilen kesme geçişinin türü (ani / dereceli) hakkında bilgi vermemektedir. Eşikleme yönteminin bahsi geçen zayıflıkları göz önüne alınarak, tez çalışmasının bu bölümünde FD temelli öznitelikler ve örüntü sınıflandırıcı yardımıyla video kesme geçişlerini belirleyen alternatif bir yöntem geliştirilmiştir.

Geliştirilen yöntemde ilk olarak, video çerçevelerine ait FD fark değerlerinin oluşturduğu değer dizisi belirli uzunluktaki pencerelere bölünür ve her pencereyi temsil eden öznitelik kümesi çıkarılır. Öznitelik kümesi, ilgili pencere içindeki FD fark

değerlerinin değişimi (variance), basıklık (kurtosis) ve yamukluk (skewness) bilgisinden oluşmaktadır. Literatürdeki çeşitli örüntü tanıma çalışmalarında, yüksek dereceli istatistiklerin öznitelik çıkarımında kullanılmasının sınıflandırma başarımını artırdığı gözlenmiştir (Murino, et al.,1998, Gerek et al., 2006). Kullanılan özniteliklerin matematiksel ifadeleri ise şu şekilde tanımlanmaktadır:

İlk öznitelik olan değişimi,

$$\text{Ö1} = \sigma_x^2 \quad (3.10)$$

eşitliği yardımıyla hesaplanır. Yamukluk özniteliği,

$$\text{Ö2} = \frac{\sum_{i=1}^N (x_i - m_x)^3}{(N-1)\sigma_x^3} \quad (3.11)$$

eşitliği ile, basıklık özniteliği ise

$$\text{Ö3} = \frac{\sum_{i=1}^N (x_i - m_x)^4}{(N-1)\sigma_x^4} - 3 \quad (3.12)$$

eşitliği kullanılarak hesaplanır. Eşitliklerdeki m_x ve σ_x değerleri pencere içindeki örneklerin sırasıyla ortalamasını ve standart sapmasını ifade etmektedir. Bu şekilde hesaplanan üç ayrı öznitelik, ilgili çerçeveyi temsil eden 3-boyutlu bir öznitelik vektörü oluşturur.

Elde edilen öznitelik vektörleri sonraki aşamada sınıflandırmaya tabi tutulur. Bu amaçla, video kesme geçişlerini belirleme işlemi ilk olarak “ani geçiş” ve “geçiş yok” şeklinde 2-sınıflı bir örüntü tanıma uygulaması olarak ele alınmıştır. Sonraki aşamada ise, üçüncü sınıf olarak “dereceli geçiş” uygulamaya dahil edilmiştir.

Uygulamada, örüntü sınıflandırma amacıyla, pek çok çalışmada verimliliği kanıtlanmış olan Bayes sınıflandırıcı kullanılmıştır. Bayes sınıflandırıcı, sınıflandırma hatası olasılığını enküçükleyen karar kuralına (Duda et al., 2001) göre çalışır. Bir öznitelik vektörü x ,

$$p(x | c_i)p(c_i) > p(x | c_j)p(c_j), \quad j = 1, \dots, N, \quad j \neq i \quad (3.13)$$

ifadesiyle belirtilen durum sağlandığı takdirde $\{c_1, c_2, \dots, c_N\}$ sınıfları arasından c_i sınıfına atanır. Bayes sınıflandırma sürecinde olasılık yoğunluk fonksiyonu için dağılım türünün, Normal (Gauss) dağılım olduğu kabul edilmiştir. Bu durumda, n -boyutlu x vektörünün olasılık yoğunluk fonksiyonu,

$$p(x) = \frac{1}{(2\pi)^{n/2} |C_x|^{1/2}} e^{\left[-\frac{1}{2}(x-m_x)^T C_x^{-1}(x-m_x) \right]} \quad (3.14)$$

şeklinde hesaplanır. Bu eşitlikte, m_x ve C_x parametreleri sırasıyla ortalama vektörü ve ortak değişinti (kovaryans) matrisini ifade etmektedir.

3.2 BİTKİLERİN SINIFLANDIRILMASI

Bu çalışmada, HSV (RÖ, D, P) renk uzayında yapılan fraktal boyut ölçümlerinin görüntü bölütlemeye kullanımı incelenmiştir. Uygulama olarak farklı bitki türlerinin, özellikle zararlı otlar ve diğerlerinin bulunduğu bölgeler incelenmiştir. Bu amaçla farklı ot türlerinin bulunduğu görüntülerin HSV renk bileşen değerleri ile bunlardan elde edilen bölgesel fraktal boyutlar kullanarak öznitelik değerleri çıkarılmıştır. Özel olarak ekilip yetiştirilmesi düşünülen bitkilerin bulunduğu alanlarda, diğer bitki türlerinden mümkün olduğunca az sayıda olması istenir. İstenmeyen bitki türü, yetiştirilen bitkinin büyümesi ve gelişmesi için zararlı ise bunlarla mücadele edilmesi gerekir. Bu durum daha çok tarımsal alanlarda önem kazanmaktadır. Ancak golf, spor alanları gibi özel bir amaç için oluşturulan yeşil alanlarda da zararlı otlardan kurtulmak önem kazanmaktadır.

Zararlı otlarla savaşmada, genellikle istenmeyen otların yanında yetiştirilen bitkiler de ilaçlanır. Tüm bölgede bu şekilde gereğinden fazla kimyasal ilaç kullanılması, çevresel kirliliğe yol açmakta ve ekonomik açıdan maliyeti de arttırmaktadır. Yalnızca ilgili alanın ilaçlanması amacıyla işçilerin kullanılması bir çözüm gibi gözükse de, bu yöntem fazla zaman ve insan gücü gerektirmektedir (Watchareeruetai, et al., 2006).

Bilgisayarlı görüş teknolojisinde sağlanan gelişmeler, zararlı otların otomatik olarak kontrol edilmesinde alternatif çözümler sağlamaktadır. Genel olarak bu sistemlerde, kuşbakışı kameralarla elde edilen bölgesel görüntülerdeki tüm bitkilerin öznitelikleri çıkarılarak, bunlar üzerinde çalışılarak, zararlı otların yeri belirlenip, tüm alanın kimyasal ilaçlanması yerine sadece zararlı ot olan yerler ilaçlanır. Arka planla yetiştirilen bitkinin ve zararlı otların renklerinin kolaylıkla ayırdedilebilir olduğu durumlarda, zararlı otların belirlenmesi daha kolaydır. Örneğin, kabak, havuç (Hemming and Rath, 2001) ve domates ekili alanlar (Lee, et al., 1996, 1999) üzerinde bu tür çalışmalar başarıyla gerçekleştirilmiştir.


Bu çalışmada, farklı ot türlerinin bulunduğu görüntülerden HSV renk bileşen değerleri ile bunlardan elde edilen bölgesel fraktal boyutlar kullanarak öznitelikler çıkarılmıştır. Bu öznitelikler ile yapılan Bayes sınıflandırma sonucunda, görüntülerin yalnızca gri seviye değerleri kullanılarak çıkarılan özniteliklerin sağladığı başarı kadar iyi tanıma başarımı elde edilmiştir (Şora Günel vd., 2008).

Bitki sınıflandırmada görüntü içindeki bitkilerin dağılımı önem kazanmaktadır. Bitkilerin çoğunun benzer renge ya da yaprak desenine sahip olması belirleme işlemini zorlaştırmaktadır. Bu gibi durumlarda ayırdedici ek özniteliklerin çıkarılması gerekmektedir. Bu çalışmada, görüntü HSV renk uzayında incelenmiştir. HSV (Hue, Saturation, Value) renk uzayı renkleri sırasıyla renk özü, doygunluk ve parlaklık olarak tanımlanır. RÖ değişik ışık dalga boyları arasındaki baskın dalga boyunu belirtir. Ayrıca gözlemci tarafından algılanan baskın rengi ifade eder. Bir nesnenin kırmızı, turuncu veya sarı olduğu RÖ değeri ile tarif edilir. D ise bağıl saflığı veya RÖ değerine karışan beyaz ışık miktarını ifade eder. Saf spektrum renkleri tam doygundur. Pembe (kırmızı ve beyaz), lavanta rengi (mor ve beyaz) gibi renkler ise ilave edilen beyaz

miktarı ile ters orantılı olacak şekilde az doygundur. P değeri ise renk yoğunluğunu göstermektedir. Pe değerinin artması parlaklığın artmasına sebep olacaktır. HSV uzayının, insanların renk algılamasına yakın bir yapısı vardır (Gonzales and Woods, 2008).

Çalışmada, görüntülere ait RÖ ile D ve P bileşenlerinin fraktal boyutları kullanılmıştır. Gerçek uygulamalarda RGB veya gri seviye renk değerleri ortamın ışık şiddetine ve mevsimsel değişikliklere göre değişebilmektedir. Ana renk bileşeniyle çalışmak, ortam koşullarından daha az etkilenmeyi sağlamaktadır.

Şekil 3.12 (a) da belirlenmek istenen bitki türünün yakından çekilmiş görüntüsü gösterilmektedir. Öznitelik çıkarılması aşamasında, görüntü 64×64 piksel boyundaki



Şekil 3.12. Sınıflandırmada kullanılan bitki görüntüleri (a) Aranan bitki türünün detaylı görüntüsü (b) Bitki türüne göre elle sınıflandırma

parçalara bölünmüş ve bu parçaların her biri bağımsız olarak incelenmiştir. Görüntüdeki her alt parçada aranan bitkinin varlığı, parça yüzeyinin %50 sinden fazlasını kaplayıp kaplamamasına göre belirlenmektedir. Aranan bitki türünün elle

belirlenmiş dağılımı detaylı olarak Şekil 3.12 (b) de gösterilmektedir. ‘X’ ile gösterilen yerler aranan bitki türünü içeren bölgeleri, ‘O’ ile gösterilen yerler içermeyen yerleri belirtmektedir.

Bu şekilde elde edilen bitkilere ait görüntüler sınıflandırılarak, veri kümesi oluşturulmuş olup, renk uzayı bileşenlerine ait FD değerleri bitki sınıflandırılmasında kullanılmıştır. Çalışmaya ait deneysel çalışmalar ve sonuçları Bölüm 5.2 de yer almaktadır.

BÖLÜM 4

FRAKTAL BOYUT YARDIMIYLA ÖZNİTELİK SEÇİMİ

Tez kapsamındaki bu çalışmada, yüksek performanstaki beton imalatında bileşenlerin değerlendirilmesi işlemi için Bölüm 2.3 de anlatılan, fraktal boyut bilgisini kullanan bir yöntem önerilmiştir. Bunun için, beton bileşenleri fraktal boyut değişimi cinsinden karakterize edilmektedir. Böylece, her ayrı bileşenin etkisi belirlenebilmekte ve karışımdaki bileşenlerin miktarından betonun sağlamlığı tahmin edilebilmektedir.

Yapıların güçlü ve dayanıklılığında hayati bir rol oynayan beton, değişik bileşenlerden oluşmasından dolayı kalitesi de bu bileşenlere bağlıdır. En iyi bilinen beton bileşenleri çimento, su ve agrega (kum, çakıl vs.) olmakla birlikte, ince kül, yüksek fırın cürufu ve süper akışkanlaştırıcı gibi malzemeler yüksek performanslı beton imalatında kullanılmaktadırlar (Yeh, 1998; Domone and Soutsos, 1994).

Diğer taraftan, karışımdaki malzeme sayısının artışı ile birlikte, beton içeriğinin dayanıklılıktaki etkisinin belirlenmesi gittikçe zorlaşmaktadır. Bu durumda, düşük değerde olması betonun daha dayanıklı olduğunu gösteren, klasik su-çimento (S/Ç) oranı sağlamlığı ölçmek için yeterli olamamaktadır (Abrams, 1918). Literatürdeki önceki çalışmalar bu durumu doğrulamaktadır (Oluokun, 1994; Siddique, 2003). Bu nedenle betondaki her bileşenin etkisi dikkatli bir şekilde analiz edilmelidir.

Betondaki her bileşen bir özneliğe karşılık gelir. Daha önceki çalışmalarda (Yeh, 1998) da kullanılmış olan veri kümesindeki beton bileşenleri tez kapsamındaki çalışmada, FD temelli olarak değerlendirilmiştir. Çizelge 4.1'de, beton basınç dayanıklılığını belirlemede kullanılan bileşenler listelenmiştir.

Kesitsel birim alandaki güç olarak tanımlanan basınç dayanıklılığı, betonun eksensel basınç yüküne karşı göstermiş olduğu maksimum dirençtir. Bu nedenle, basınç dayanıklılığındaki artış, yapılardaki kiriş ve kolon gibi destek birimlerinin küçülmesine;

dolayısıyla, kullanılabilir alanların genişlemesine imkan tanıyacaktır (Roadmap 2030, 2002). Bu çalışmada, dayanıklılık ölçümleri Çizelge 4.2’de listelendiği şekilde “düşük”, “orta” ve “yüksek” olmak üzere üç sınıfta gruplanmıştır.

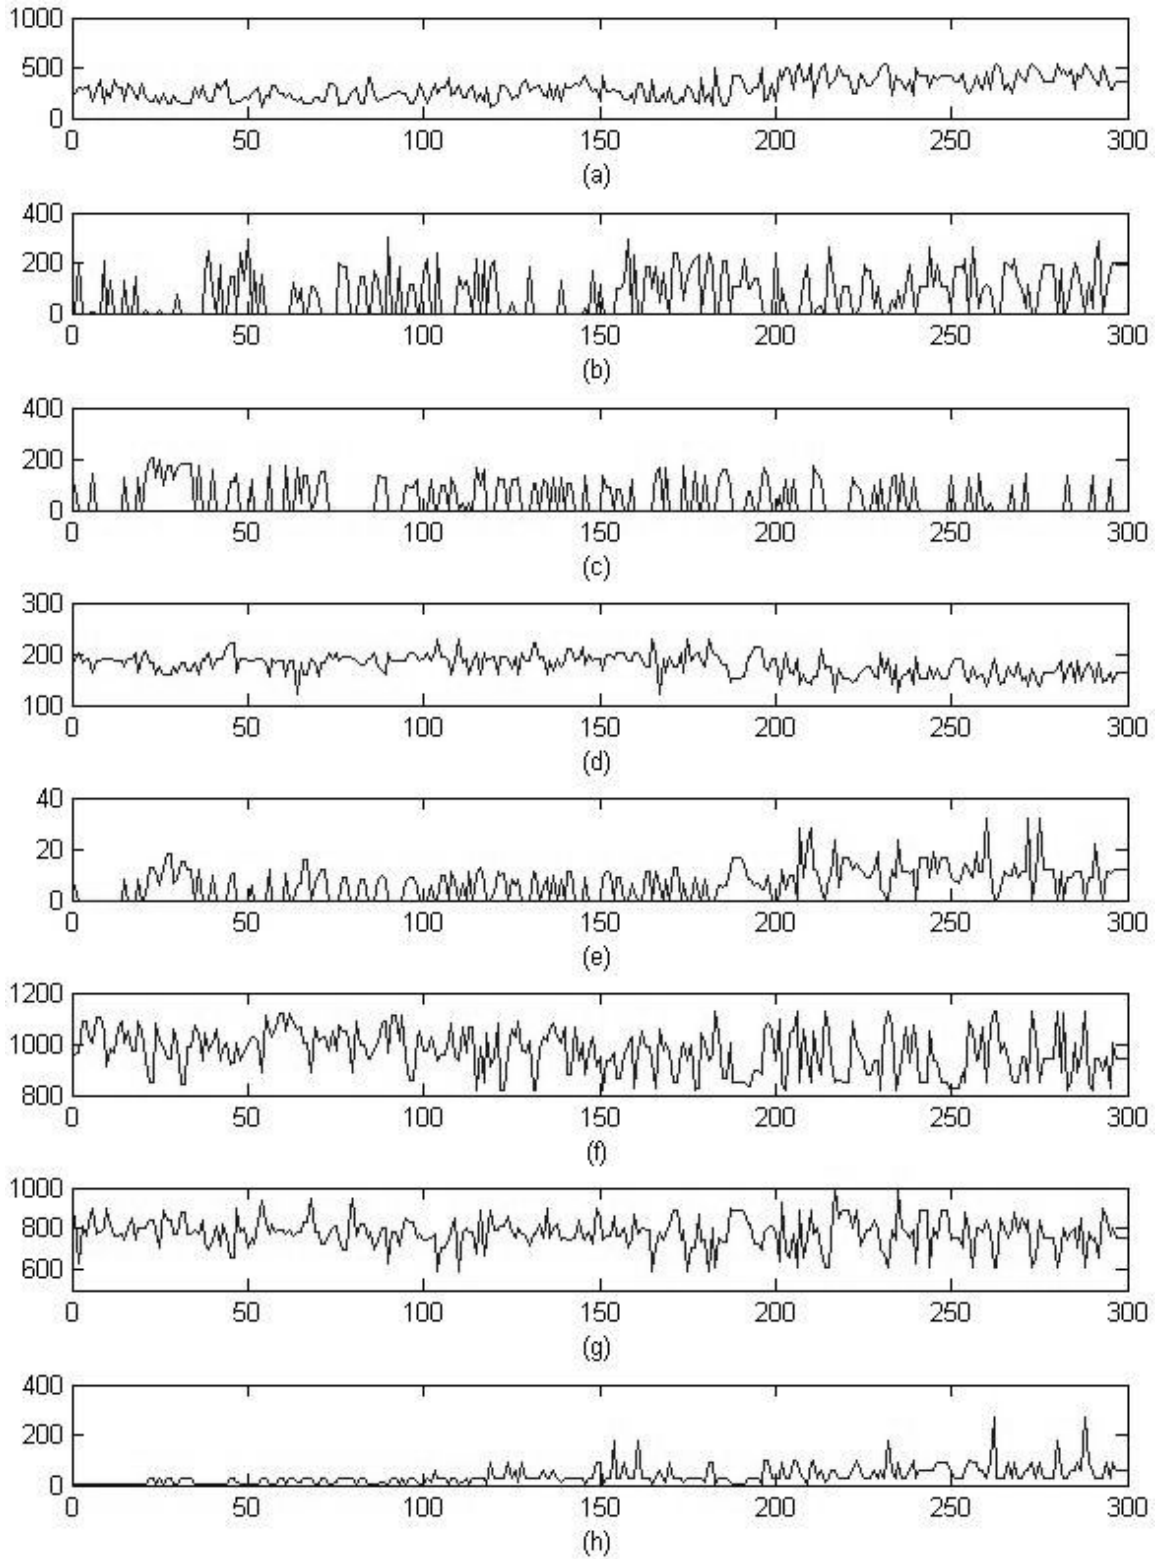
Çizelge 4.1. Veri kümesindeki beton bileşenlerinin listesi

Bileşen	Tanım
1	Çimento
2	Yüksek fırın cürufu
3	İnce kül
4	Su
5	Süper akışkanlaştırıcı
6	Kaba Agregası
7	İnce Agregası
8	Yaş

Çizelge 4.2. Dayanıklılık sınıfları

Sınıf	Tanım
1	Düşük dayanıklılıktaki beton (< 25 MPa)
2	Orta dayanıklılıktaki beton (25 – 50 MPa)
3	Yüksek dayanıklılıktaki beton (>50 MPa)

İlgili veri kümesindeki beton bileşenlerine ait grafikler Şekil 4.1’de yer almaktadır. Bu grafiklerde dayanıklılığın 3 sınıfına ait bileşenler gösterilmektedir. Her bileşen için, 0-100 arası 1. sınıfa, 101-200 arası 2. sınıfa, 201-300 arası da 3. sınıfa ait örnek değerleri göstermektedir.



Şekil 4.1. Beton öznitelik değeri grafikleri (1-100 arası: Sınıf 1, 101-200 arası: Sınıf 2, 201-300 arası: Sınıf 3): (a) Çimento (b) Yüksek Fırın Cürufu (c) İnce Kül (d) Su (e) Süperakışkanlaştırıcı (f) Kaba Agrega (g) İnce Agrega (h) Yaş

Özniteliklerin deęişimi bu dalga şekillerinin fraktal veya ilinti boyutlarındaki deęişim cinsinden karakterize edilmektedir. Bir öznitelik farklı sınıflarda, oldukça farklı deęerler elde ediyorsa, bu öznitelik, daha düşük deęişimli dięer öznitelięe göre daha ayırdedici. Bu sonuç, ayırdetme işleminde, özniteliklerin dalga şekillerinin fraktal boyutlarının bir ölçüm yöntemi olarak kullanılabilceğini göstermektedir. Özniteliklerin fraktal boyutları $(C(r))$, denklem (2.7) - (2.9) kullanılarak bir kez hesaplandıktan sonra, bu deęerler azalan sırada sıralanmaktadır. Beton dayanıklılığını düzgün olarak belirlemede, bu elde edilen sıralama sonuçları, özniteliklerin ayırdedici güçleri ile aynı sıralamaya sahiptir. Bir sonraki aşamada, test kümesindeki öznitelikler Bayes sınıflandırıcıya uygulanmıştır (Şora Günel, et al., 2008). Geliştirilen yöntemle ait deney sonuçları Bölüm 5.3'te ayrıntılı bir biçimde açıklanmıştır.

BÖLÜM 5

DENEYSEL ÇALIŞMALAR

Bu bölüm, tez kapsamında gerçekleştirilen deneysel çalışmaları ve bu çalışmaların sonuçlarını içermektedir. İlk olarak video kesme geçişlerinin belirlenmesi ile ilgili deneyler, daha sonra sırasıyla bitkilerin sınıflandırılması (Bölüm 5.2) ve FD temelli öznitelik seçimi (Bölüm 5.3) deneylerine yer verilmiştir.

5.1 Video Kesme Geçişlerinin FD Temelli Öznitelikler ile Belirlenmesi Deneyleri

Deneysel çalışmada, geliştirilen yöntemi doğrulamak için, değişik türdeki kesme geçişlerini içeren videolar kullanılmıştır. Deneysel çalışmalarda farklı türdeki nesne hareketlerini ve kesme geçişlerini içermesi açısından spor videoları kullanılmıştır. Futbol videolarında Beşiktaş Jimnastik Kulübü futbol takımının, tenis videolarında ise Roger Federer'in maç görüntülerinden yararlanılmıştır. Çalışmada, kesme geçişleri ani ve dereceli olmak üzere iki farklı gruba ayrılmıştır. Çözülme, yatay kayma, süpürme, zumlama, gürültü gibi geçişler dereceli olarak kabul edilmiştir.

Yöntemlerin başarımları, denklem (5.1) – (5.3) arasında verilen geri getirme oranı, kesinlik oranı ve bu iki değeri kullanan F1 değerleri ile ölçülmektedir. Bu formüllerdeki N_m , N_C and N_F değerleri sırasıyla eksik, doğru ve yanlış elde edilen sayıları göstermektedir.

Geri getirme oranı (recall), doğru olarak belirlenen kesme geçişi sayısının (N_C) olması gereken geçiş sayısına ($N_C + N_m$) oranıdır. Kesinlik oranı (precision), doğru olarak tespit edilen sayının (N_C) doğru ve yanlış olarak tespit edilen sayısına ($N_C + N_F$) oranını vermektedir. Bu değerlerin 1.0'e yaklaşması yöntemin başarılı olduğunu göstermektedir.

$$GERİ GETİRME ORANI = \frac{N_c}{N_c + N_m} \quad (5.1)$$

$$KESİNLİK ORANI = \frac{N_c}{N_c + N_F} \quad (5.2)$$

$$F1 = \frac{2 \times GERİ GETİRME ORANI \times KESİNLİK ORANI}{GERİ GETİRME ORANI + KESİNLİK ORANI} \quad (5.3)$$

Geri getirme ve kesinlik oranlarına ek olarak, performans ölçümünde uygulanan bir diğer metrik ise, bu iki oranı birlikte kullanan F1 oranıdır. F1 metrik değeri denklem (5.3) de gösterildiği gibi hesaplanmaktadır (Cotsaces, et al., 2005).

5.1.1 Geçişlerin Eşikleme Yöntemi ile Belirlenmesi Deneyleri


Herhangi bir spor videosunda başarımlar ölçümleri yapıldığında, test videosunun herbiri değişik türdeki geçişleri içerebileceğinden dolayı, yanlış tanıma sayısının (N_F) tam olarak hangi türe ait olduğu kesin olarak belirlenmemektedir. Bunun sonucunda yalnızca geri getirme oranları elde edilebilir. Oysaki kesme geçişlerinde geri getirme oranı kadar, kesinlik oranı da önemlidir. Bu nedenle, bu bölümdeki deneysel çalışmalarda, öncelikle önışlem olarak, değişik spor videolarındaki kesme geçiş türleri elle tespit edilerek işaretlenmiştir. Daha sonra özel bir video düzenleme yazılımı kullanılarak aynı türe ait değişimler ardarda eklenerek test videoları oluşturulmuştur.

Böylece ani geçişe ait ve dereceli geçiş türlerinden her birine ait (çözülme, yatay kamera hareketi, süpürme, zumlama vb.) ayrı ayrı test videoları elde edilmiştir. Bu test videoları kullanılarak, literatürdeki mevcut yöntemler ile geliştirilen yöntem arasında daha hassas bir şekilde karşılaştırma yapılabilmektedir.


Şekil 5.1’ de mevcut yöntemlerle ve önerdiğimiz FDD ile elde edilen öznelilik farklarının grafiği yer almaktadır. İşaretli noktalar gerçek değişimlerin olduğu çerçeveleri göstermektedir. Grafikler incelendiğinde geliştirilen FDD yönteminin kesme geçişi bulunan noktalarda, diğer yöntemler kadar belirleyici olduğu gözlenmektedir.

DeneySEL çalışmada, video düzenleme yazılımı ile ardarda eklenme yöntemiyle, ani geçiş içeren 8637, dereceli geçiş içeren 9348 çerçeveli videolar oluşturulmuştur. Videolardaki her çerçevenin ölçüleri 240 x 320 pikseldir. Öncelikle video kesme geçişlerinde FD temelli yaklaşımın başarımını ölçmek için Bölüm 2.2 de anlatılan DBC yöntemi kullanılarak her bir çerçeveden yalnızca bir FD değeri elde edilip, ardışık çerçevelerin FD farkları alınarak öznelilikler oluşturulmuştur. Bu yöntem mevcut SAD, B2B ve INT yöntemleri ile karşılaştırılmıştır. Bu karşılaştırma sonucu Çizelge 5.1 (a)’da yer almaktadır. Dereceli geçiş test sonuçlarına göre, geri getirme oranı açısından en iyi sonucu FDD_{DBC} yöntemiyle elde edilmiştir. Kesinlik oranı açısından en iyi sonucu INT yöntemi ile elde edilmiş olsada F1 oranları arasında en başarılı sonucu FDD_{DBC} vermektedir.


Çizelge 5.1 (b) deki ani geçişlere ait test sonuçlarına göre, en başarılı geri getirme yüzdesi 0,895 olarak B2B ile elde edilmiş olsa da, FDD_{DBC} yöntemi de 0,726 değeri ile B2B’ e yakın bir performans göstermiştir. Ancak kesinlik oranları açısından, FDD_{DBC} düşük performans sergilemektedir. Dereceli ve ani geçişleri birlikte ele alan Çizelge 5.1 (c) deki sonuçlar da, Çizelge 5.1-(b) ile yaklaşık olarak benzer sonuçlar vermektedir. Bu iki çizelgedeki sonuçlara göre, FD temelli kullanılan yöntemde iyileştirme sağlanarak kesinlik oranı yükseltilebilir. Elde edilen bu sonuçlar, videolardaki kesme geçişlerinin tespitinde FD’ un öznelilik olarak kullanılabilceğini göstermektedir.




(a)



(b)



(c)



(d)

Şekil 5.1. (a) FDD, (b) SAD, (c) B2B, (d) INT. (Grafiklerdeki işaretli noktalar gerçek kesme geçişi olan çerçeveleri göstermektedir.)

Çizelge 5.1. FDD_{DBC}, SAD, B2B, INT sonuçları (a) Dereceli geçişler (b) Ani geçişler (c) Tüm geçişler

Yöntem	Nc	Nf	Nm	Toplam		Kesinlik Oranı	F1
				Dereceli Geçiş Sayısı	Geri Getirme Oranı		
FDD _{DBC}	49	64	40	89	0,551	0,434	0,485
SAD	9	15	80	89	0,101	0,375	0,159
B2B	35	49	54	89	0,393	0,417	0,405
INT	10	7	79	89	0,112	0,588	0,189

(a)

Yöntem	Nc	Nf	Nm	Toplam		Kesinlik Oranı	F1
				Ani Geçiş Sayısı	Geri Getirme Oranı		
FDD _{DBC}	69	139	26	95	0,726	0,332	0,455
SAD	53	33	42	95	0,558	0,616	0,586
B2B	85	81	10	95	0,895	0,512	0,651
INT	61	5	34	95	0,642	0,924	0,758

(b)

Yöntem	Nc	Nf	Nm	Toplam		Kesinlik Oranı	F1
				Geçiş Sayısı	Geri Getirme Oranı		
FDD _{DBC}	118	203	66	184	0,641	0,368	0,467
SAD	62	48	122	184	0,337	0,564	0,422
B2B	120	130	64	184	0,652	0,480	0,553
INT	71	12	113	184	0,386	0,855	0,532

(c)

Yukarıda sonuçların elde edilmesiyle birlikte, FD temelli yöntemde Bölüm 3.1.2’de açıklandığı şekilde iyileştirme sağlanmıştır. Geliştirilen yöntemlere (FDD_{DBC}, FDD_{SDBC(1x1)}, FDD_{SDBC(2x2)}) ait sonuçlar, Çizelge 5.2-(a), (b), (c) de yer almaktadır. FDD_{DBC} yönteminde klasik DBC kullanılmıştır. FDD_{SDBC(1x1)} yönteminde ise FD hesaplanmasında LSF yerine, tez çalışması kapsamında geliştirilen, Bölüm 3.1.2’de açıklanan, denklem (3.9) da verilen “2 noktaya göre doğru denklemi” hesaplama

yöntemi kullanılmıştır. 1×1 ifadesi herbir video çerçevesi için tek FD hesaplandığını göstermektedir. $FDD_{SDBC(2 \times 2)}$ yönteminde ise herbir video çerçevesi, enine ve boyuna iki parça olacak şekilde, toplamda dört eşit parçaya bölünerek, dört farklı bölgesel FD değeri hesaplanmaktadır (Bkz. Şekil 3.8). 2×2 ifadesi bu bölme işlemi sembolize etmektedir. Herbir video çerçevesi için elde edilen bu FD değerleri, ardışık çerçeveler için denklem (3.8) de verildiği şekilde farkların ortalamaları alınarak FDD öznitelikleri elde edilmesinde kullanılmıştır. Tüm geçişler için elde edilen sonuçlar incelendiğinde Çizelge 5.2-(c) ye göre geri getirme, kesinlik ve F1 oranlarının hepsi için en başarılı sonuç $FDD_{SDBC(2 \times 2)}$ yöntemi ile elde edilmiştir. Bu nedenle bu bölümdeki ve bundan sonraki deneysel çalışmalarda FDD yöntemi olarak bahsedilen yöntem $FDD_{SDBC(2 \times 2)}$ yöntemini göstermektedir.

Elde edilen bu sonuç, tez kapsamında geliştirilen yöntemin Bölüm 3.1.2’de grafiksel olarak elde edilmiş sonuçlarını gösteren Şekil 3.9 ve Şekil 3.11’i de desteklemektedir. Çizelge 5.2-(c)’ de, özellikle kesinlik oranları incelendiğinde $FDD_{SDBC(2 \times 2)}$ yöntemi ile en iyi sonuç elde edildiği gösterilmektedir. Kesinlik oranının yüksek çıkması, yanlış tanıma sayısının (N_F) dolayısıyla öznitelik grafiklerindeki gürültünün azaldığını doğrulamaktadır.

Çizelge 5.3’deki deneysel çalışmada video kesme geçişlerini belirlemede literatürdeki mevcut yöntemler ile geliştirilen FDD yöntemi karşılaştırılmıştır. Karşılaştırmalar dereceli, ani ve tüm geçişler için ayrı çizelgelerde gösterilmiştir. Bu çizelgelerdeki sonuçlara göre, geri getirme oranı açısından özellikle dereceli geçişlerde FDD yöntemi diğer yöntemlerden daha iyi başarımlar göstermiştir. Kesinlik oranı açısından en iyi sonuç INT yöntemi ile elde edilmiş olsa da, FDD yöntemi ile ikinci sırada INT yöntemine yakın kesinlik oranı elde edilmiştir. F1 oranı açısından da FDD en iyi sonucu vermektedir. Ani geçiş sonuçlarına göre, FDD geri getirme oranlarında ikinci sırada yer almaktadır. Tüm geçişlerin ele alındığı Çizelge 5.3 (c) de ise, F1 oranı açısından en iyi sonuç FDD yöntemi ile elde edilmektedir. FDD yönteminin dereceli geçişlerdeki SAD, B2B ve INT yöntemlerine göre oldukça yüksek başarımlar göstermesi nedeniyle bir sonraki deneysel çalışmada ise dereceli geçiş türlerinin başarımları ayrı ayrı elde edilerek, mevcut yöntemlerle kıyaslanmıştır.

Çizelge 5.2. FDD_{DBC} , $FDD_{SDBC(1x1)}$, $FDD_{SDBC(2x2)}$ sonuçları (a) Dereceli geçişler (b) Ani geçişler (c) Tüm geçişler

Yöntem	Nc	Nf	Nm	Toplam Dereceli Geçiş		Kesinlik Oranı	F1
				Sayısı	Geri Getirme Oranı		
FDD_{DBC}	49	64	40	89	0,551	0,434	0,485
$FDD_{SDBC(1x1)}$	49	48	40	89	0,551	0,505	0,527
$FDD_{SDBC(2x2)}$	41	45	48	89	0,461	0,477	0,469

(a)

Yöntem	Nc	Nf	Nm	Toplam Ani Geçiş		Kesinlik Oranı	F1
				Sayısı	Geri Getirme Oranı		
FDD_{DBC}	69	139	26	95	0,726	0,332	0,455
$FDD_{SDBC(1x1)}$	64	102	31	95	0,674	0,386	0,490
$FDD_{SDBC(2x2)}$	75	69	20	95	0,789	0,521	0,628

(b)

Yöntem	Nc	Nf	Nm	Toplam Geçiş		Kesinlik Oranı	F1
				Sayısı	Geri Getirme Oranı		
FDD_{DBC}	118	203	66	184	0,641	0,368	0,467
$FDD_{SDBC(1x1)}$	113	150	71	184	0,614	0,430	0,506
$FDD_{SDBC(2x2)}$	116	114	68	184	0,630	0,504	0,560

(c)

Çizelge 5.3. FDD, SAD ,B2B, INT sonuçları (a) Dereceli geçişler (b) Ani geçişler (c) Tüm geçişler

Yöntem	Nc	Nf	Nm	Toplam		Kesinlik Oranı	F1
				Dereceli Geçiş Sayısı	Geri Getirme Oranı		
FDD	41	45	48	89	0,461	0,477	0,469
SAD	9	15	80	89	0,101	0,375	0,159
B2B	35	49	54	89	0,393	0,417	0,405
INT	10	7	79	89	0,112	0,588	0,189

(a)

Yöntem	Nc	Nf	Nm	Toplam		Kesinlik Oranı	F1
				Ani Geçiş Sayısı	Geri Getirme Oranı		
FDD	75	69	20	95	0,789	0,521	0,628
SAD	53	33	42	95	0,558	0,616	0,586
B2B	85	81	10	95	0,895	0,512	0,651
INT	61	5	34	95	0,642	0,924	0,758

(b)

Yöntem	Nc	Nf	Nm	Toplam		Kesinlik Oranı	F1
				Geçiş Sayısı	Geri Getirme Oranı		
FDD	116	114	68	184	0,630	0,504	0,560
SAD	62	48	122	184	0,337	0,564	0,422
B2B	120	130	64	184	0,652	0,480	0,553
INT	71	12	113	184	0,386	0,855	0,532

(c)

Tez kapsamında geliştirilen FDD yöntemi, Çizelge 5.4 -5.7 arasında, çözülme, yatay kayma, süpürme, zumlama türlerindeki dereceli geçişlerin herbiri için test edilmiştir. Çizelge 5.4'e göre FDD yöntemi ile kesinlik oranı ve F1 oranları açısından en iyi sonuç elde edilirken, geri getirme oranı açısından ise SAD ve INT yöntemlerine göre oldukça yüksek değer elde edilmektedir. Çizelge 5.5 de yer alan yatay kayma

geçiş sonuçlarına göre, FDD yöntemi B2B yöntemine yakın başarımlar elde ederken, SAD ve INT yöntemlerine göre oldukça yüksek değerler vermektedir. Çizelge 5.6 ve Çizelge 5.7 deki, süpürme ve zumlama geçiş sonuçlarına göre ise en iyi sonuçların geliştirilen FDD yöntemi ile elde edildiği belirgin bir şekilde gözlenmektedir.

Çizelge 5.4. Çözülme (dissolve) geçiş sonuçları

Yöntem	Nc	Nf	Nm	Toplam Geçiş Sayısı	Geri Getirme Oranı	Kesinlik Oranı	F1
FDD	5	1	5	10	0,500	0,833	0,625
SAD	1	5	9	10	0,100	0,167	0,125
B2B	7	11	3	10	0,700	0,389	0,500
INT	2	3	8	10	0,200	0,400	0,267

Çizelge 5.5. Yatay kayma (panning) geçiş sonuçları

Yöntem	Nc	Nf	Nm	Toplam Geçiş Sayısı	Geri Getirme Oranı	Kesinlik Oranı	F1
FDD	5	5	15	20	0,250	0,500	0,333
SAD	1	1	19	20	0,050	0,500	0,091
B2B	6	3	14	20	0,300	0,667	0,414
INT	2	1	18	20	0,100	0,667	0,174

Çizelge 5.6. Süpürme (wipe) geçiş sonuçları

Yöntem	Nc	Nf	Nm	Toplam Geçiş Sayısı	Geri Getirme Oranı	Kesinlik Oranı	F1
FDD	23	31	8	31	0,742	0,426	0,541
SAD	4	3	27	31	0,129	0,571	0,211
B2B	19	29	12	31	0,613	0,396	0,481
INT	3	1	28	31	0,097	0,750	0,171

Çizelge 5.7. Zumlama (zoom) geçiş sonuçları

Yöntem	Nc	Nf	Nm	Toplam Geçiş Sayısı	Geri Getirme Oranı	Kesinlik Oranı	F1
FDD	8	8	20	28	0,286	0,500	0,364
SAD	3	6	25	28	0,107	0,333	0,162
B2B	3	6	25	28	0,107	0,333	0,162
INT	3	2	25	28	0,107	0,600	0,182

Bir diğer deneysel çalışmada ise, geliştirilen yöntemi doğrulamak için, aynı video içerisinde değişik türdeki kesme geçişlerini içeren herhangi bir önışlem yapılmamış gerçek futbol ve tenis maçı videoları kullanılmıştır. Bu videoların herbiri değişik türde geçişler içermektedir. Toplamda 8005 çerçeve içeren yedi farklı sıkıştırılmamış videolar kullanılmıştır. Her çerçevenin ölçüleri 240 x 320 pikseldir.

Çalışmada, kesme geçişleri ani ve dereceli olmak üzere iki farklı gruba ayrılmıştır. Süpürme, gürültü, ve kamera hareketi gibi geçişler dereceli olarak kabul edilmiştir. 49 farklı ani, 18 farklı da dereceli geçiş tespit edilmiştir. Test videolarındaki kesme geçişlerinin manuel olarak belirlenmesinin ardından önerdiğimiz yöntem ve literatürdeki mevcut temel yöntemler (SAD, B2B, INT) aracılığıyla fark öznelikleri elde edilmiştir.

Çizelge 5.8 sırasıyla dereceli, ani ve tüm değişimler için tanıma oranlarını göstermektedir. Dereceli kesme geçişleri (süpürme, gürültü ve yatay kamera hareketi) için elde edilen sonuçlarda, tez çalışmasında önerilen FD tabanlı yöntem ile elde edilen sonuçlar en iyi sonucu vermektedir. Ani kesme geçişlerin değerlendirme tablosunda B2B en iyi sonucu vermesine karşılık, FDD ve INT yöntemlerine ait tanıma oranları B2B yöntemine oldukça yakın elde edilmiştir. SAD ise en düşük geri getirme oranına sahiptir. Tüm geçişleri içeren Çizelge 5.8-c'deki sonuçlar değerlendirildiğinde ise, önerilen yöntemin geri getirme, kesinlik ve F1 oranları açısından, SAD ve INT

yöntemlerini geride bırakırken, B2B yöntemine yakın bir başarıma sahip olduğu görülmektedir.

Çizelge 5.8. FDD, SAD, B2B, INT sonuçları (a) Dereceli geçişler (b) Ani geçişler (c) Tüm geçişler

Yöntem	N_C	N_m	Toplam Dereceli Geçiş Sayısı	Geri Getirme Oranı
FDD	14	4	18	0.778
SAD	8	10	18	0.444
B2B	10	8	18	0.556
INT	6	12	18	0.333

(a)

Yöntem	N_C	N_m	Toplam Ani Geçiş Sayısı	Geri Getirme Oranı
FDD	35	14	49	0.714
SAD	29	20	49	0.592
B2B	46	3	49	0.939
INT	37	12	49	0.755

(b)

Yöntem	N_C	N_F	N_m	Toplam Geçiş Sayısı	Geri Getirme Oranı	Kesinlik Oranı	F1
FDD	49	14	18	67	0.731	0.778	0,754
SAD	37	14	30	67	0.552	0.725	0,627
B2B	56	14	11	67	0.836	0.800	0,818
INT	43	14	24	67	0.642	0.754	0,694

(c)

Bu bölümde iki farklı test video kümeleri ile yapılan deneysel çalışmalardaki başarımların analizlerinde, FDD yönteminin mevcut yöntemlerin yanında oldukça umut vadeci sonuçlar verdiğini ispatlamaktadır. Bununla birlikte FDD yöntemi tespit edilmesi daha zor olan dereceli geçişlerde diğer yöntemleri geride bırakmaktadır.

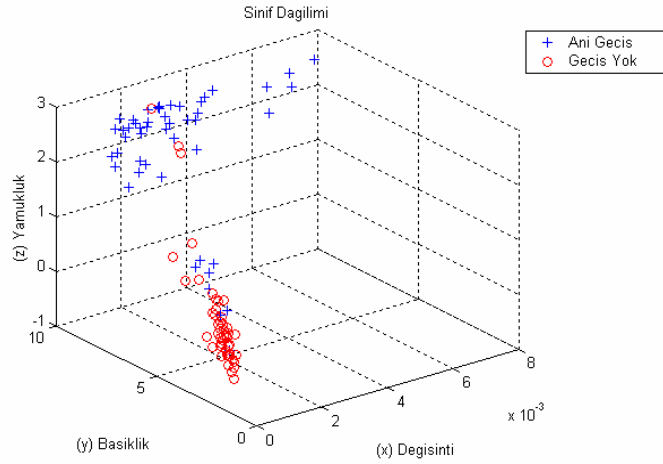
5.1.2 Geçişlerin Örüntü Sınıflandırıcı ile Belirlenmesi Deneyleri

Video kesme geçişlerinin belirlenmesinde eşikleme yöntemine alternatif olarak geliştirilen örüntü sınıflandırıcı temelli yöntemin deneysel çalışmaları için öncelikle uygun veri kümesi hazırlanmıştır. Bu amaçla, ilgili video görüntüleri Bölüm 3.1.3'te anlatıldığı şekilde her biri 10 çerçeve içeren pencerele bölünmüş ve her çerçeveye ait öznitelik vektörleri hesaplanmıştır.

Bu işlem sonucunda ilk olarak “ani geçiş” ve “geçiş yok” şeklinde 2 sınıftan oluşan ve her sınıfın 50 öznitelik vektörü içerdiği bir veri kümesi elde edilmiştir. FDD ile elde edilen öznitelik veri kümesinin dağılımı Şekil 5.2’de görülmektedir. Şekilden anlaşılacağı üzere her iki sınıf birbirinden ayrı halde gruplanma eğilimi göstermektedir. Veriler sonraki adımda, birini-dışarıda-bırak (leave-1-out) yaklaşımı ile Bayes örüntü sınıflandırıcıya uygulanmıştır. Sınıflandırma işlemine ait tanıma oranları ve karışım matrisi sırasıyla Çizelge 5.9 ve 5.10’da verilmiştir. Sonuçlardan anlaşıldığı üzere her iki video kesme geçiş sınıfı için yaklaşık %90 tanıma oranı elde edilmiştir.

İkinci aşamada, “ani geçiş” ve “geçiş yok” sınıflarına yine 50 öznitelik vektörü içeren “dereceli geçiş” sınıfı eklenerek 3 sınıflı yeni bir veri kümesi oluşturulmuş ve tekrar Bayes sınıflandırma işlemine tabi tutulmuştur. Ayrıca, karşılaştırma yapabilmek amacıyla, B2B, SAD ve INT temelli öznitelik kümeleriyle de aynı şekilde veri kümeleri hazırlanmıştır. İlgili veri kümelerine ait dağılımlar Şekil 5.3’te yer almaktadır. Şekiller incelendiğinde genel itibarıyla “ani geçiş” ve “geçiş yok” sınıfları birbirlerinden ayrı

olarak gruplanmışken “dereceli geçiş” sınıfı “geçiş yok” sınıfına karışma eğilimi göstermektedir.



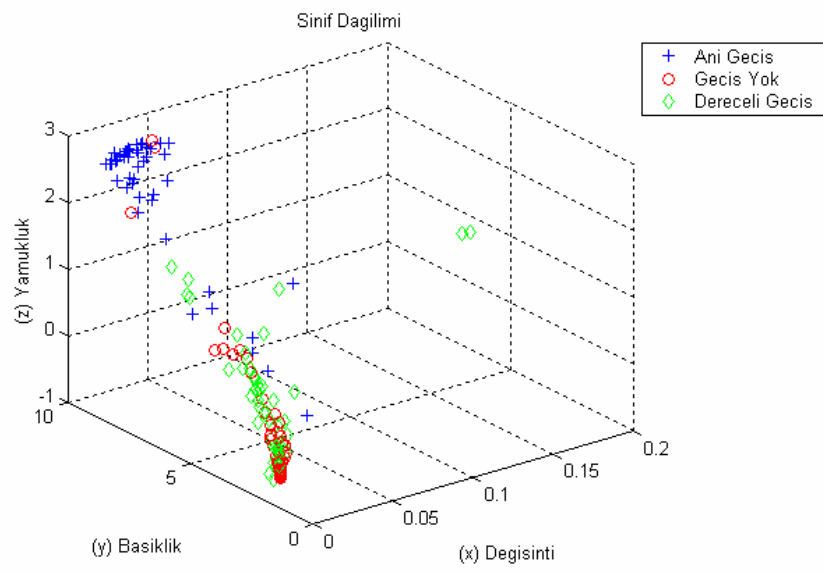

Şekil 5.2. 2-sınıf için dağılım grafiği


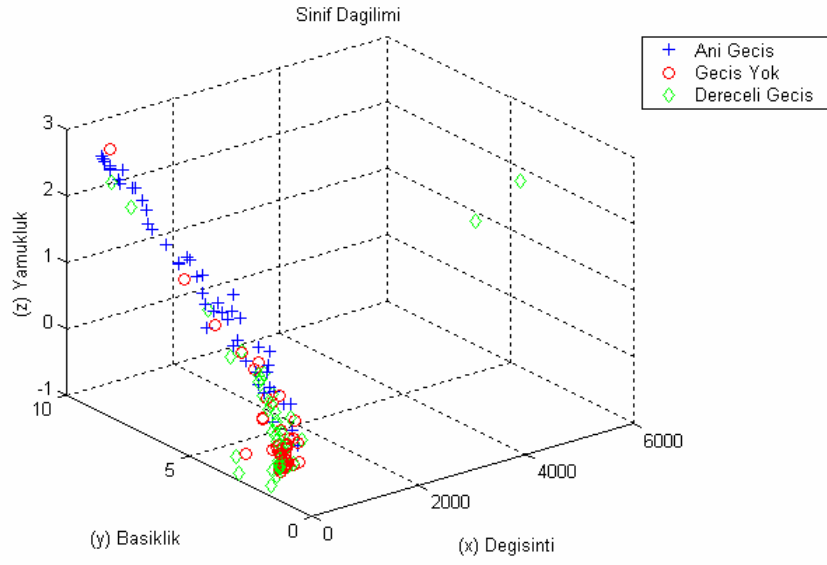
Çizelge 5.9. 2-sınıf için tanıma oranları

	Tanıma Oranı (%)	Standart Sapma (σ)
Ani Geçiş	84.00	37.03
Geçiş Yok	90.00	30.30
Ortalama	87.00	22.15

Çizelge 5.10. 2-sınıf için karışım matrisi

		Tahmin	
		Ani Geçiş	Geçiş Yok
Gerçek	Ani Geçiş	42	8
	Geçiş Yok	5	45





Şekil 5.3. 3-sınıf için dağılım grafikleri (a) FDD, (b) B2B, (c) SAD, (d) INT

3-sınıflı veri kümelerinin Bayes sınıflandırma işlemi sonucunda elde edilen tanıma oranları, standart sapma değerleri ve karışım matrisleri Çizelge 5.11-16’da verilmiştir. “Ani geçiş” ve “geçiş yok” sınıfları için tanıma oranları 2-sınıflı duruma göre fazla değişmezken, “dereceli geçiş” sınıfının “geçiş yok” sınıfına yakın gruplanması tanıma oranının nispeten düşük olmasına yol açmıştır.

Sonuç olarak, örüntü sınıflandırıcı temelli video kesme geçişi belirleme yöntemiyle “ani geçiş” ve “geçiş yok” sınıfları oldukça başarılı bir şekilde belirlenebilmekte; bununla birlikte, dereceli geçişlerde diğer iki sınıfa nazaran başarımlar düşmektedir. Ancak, eşikleme yönteminin farklı geçiş türlerini belirleme imkanının olmaması, başarımların seçilen eşik değerine karşı hassas oluşu gibi yönleri göz önüne alındığında örüntü sınıflandırıcı temelli belirleme yöntemi önemli bir alternatif olarak görülmektedir. Öznitelik kümesinin geliştirilerek dereceli geçişlerde de daha yüksek başarımlar elde edilebileceği düşünülmektedir.

Çizelge 5.11. 3-sınıf için Bayes Sınıflandırıcı ile Tanıma Oranları (%)

	FDD	B2B	SAD	INT
Ani Geçiş	84.00	84.00	84.00	84.00
Geçiş Yok	80.00	94.00	80.00	94.00
Dereceli Geçiş	10.00	16.00	10.00	16.00
Ortalama	58.00	64.67	58.00	64.67

Çizelge 5.12. 3-sınıf için Bayes Sınıflandırıcı ile Standart Sapma (σ) değerleri

	FDD	B2B	SAD	INT
Ani Geçiş	37.03	37.03	37.03	37.03
Geçiş Yok	40.41	23.99	40.41	23.99
Dereceli Geçiş	30.30	37.03	30.30	37.03
Ortalama	17.57	19.53	22.14	19.53

Çizelge 5.13. 3-sınıf için karışım matrisi (FDD)

		Tahmin		
		Ani Geçiş	Geçiş Yok	Dereceli Geçiş
Gerçek	Ani Geçiş	42	5	3
	Geçiş Yok	4	40	6
	Dereceli Geçiş	5	40	5

Çizelge 5.14. 3-sınıf için karışım matrisi (B2B)

		Tahmin		
		Ani Geçiş	Geçiş Yok	Dereceli Geçiş
Gerçek	Ani Geçiş	42	3	5
	Geçiş Yok	3	47	0
	Dereceli Geçiş	4	38	8

Çizelge 5.15. 3-sınıf için karışım matrisi (SAD)

		Tahmin		
		Ani Geçiş	Geçiş Yok	Dereceli Geçiş
Gerçek	Ani Geçiş	42	6	2
	Geçiş Yok	7	40	3
	Dereceli Geçiş	6	39	5

Çizelge 5.16. 3-sınıf için karışım matrisi (INT)

		Tahmin		
		Ani Geçiş	Geçiş Yok	Dereceli Geçiş
Gerçek	Ani Geçiş	42	3	5
	Geçiş Yok	3	47	0
	Dereceli Geçiş	4	38	8

5.2 Bitkilerin Sınıflandırılması Deneyleri

Bitkilere ait görüntü parçalarından değişik öznitelikler çıkarılmıştır. Ön işlem olarak, görüntü parçasının ortalama renk özü bileşeni ($R\ddot{O}_{ORT}$) incelenerek yeşil alan dışındaki görüntü parçaları baştan elenmektedir. Böylece yalnızca yeşil alanlarda bitki türü incelemesi yapılmaktadır. Yol, nehir veya bunun gibi ilgisiz alanlarda işlem yapılmayarak işlem yükü azaltılmaktadır. Her küçük görüntü parçasından $R\ddot{O}_{ORT}$, D_{FD} , P_{FD} bileşenleri elde edilmektedir. Bu özniteliklerden $R\ddot{O}_{ORT}$ hem ön işlem için hem de sınıflandırma işleminde kullanılan bir özniteliktir. Her 64×64 piksellik görüntü parçasından, sırasıyla D_{FD} ve P_{FD} elde edilirken, D ve P renk bileşen değerlerini bir yüzey fonksiyonu olarak kabul edip, Bölüm 2.2 de anlatılan FD hesaplama yöntemi (DBC) kullanılmıştır. $R\ddot{O}_{FD}$ değeri bu çalışmada ayırdedici bir öznitelik olarak kullanılmamaktadır. Çünkü bitki içeren bölgede $R\ddot{O}_{FD}$ değerleri 2.0 civarında elde edilmektedir. Bu nedenle, bu çalışma için $R\ddot{O}$ bileşeni FD hesaplanmasında yararlı bilgi verememektedir.

Özniteliklerin elde edilmesinin ardından, aranan bitki türünün bulunduğu ve bulunmadığı yerler elle belirlenerek veritabanı oluşturulmuştur (Şekil 3.5 (b)). Veritabanındaki görüntü sayısı çok yüksek miktarda olmadığı için test aşamasında “bir tanesini dışarıda bırak” (leave-one-out) yöntemi uygulanarak, veritabanındaki her bir görüntünün eğitim kümesinden bağımsız olarak test edilmesi sağlanmıştır.

Çizelge 5.17, farklı öznitelik kümelerinin kullanımıyla elde edilen Bayes bitki sınıflandırma oranlarını içermektedir. Öznitelik olarak yalnızca I_{ORT} , I_{VAR} kullanıldığı durumda, geri getirme yüzdesi diğer özniteliklerin de eklendiği uygulamalara göre daha düşük çıkmaktadır. $R\ddot{O}_{ORT}$, D_{FD} , P_{FD} öznitelikleri kendi başlarına neredeyse önceki duruma yakın geri getirme yüzdesi sağlasa da, en iyi sonuç $R\ddot{O}_{ORT}$, D_{FD} , P_{FD} , I_{ORT} , I_{VAR} özniteliklerinin hepsinin birden kullanıldığı durumda elde edilmiştir.

Çizelge 5.17. Bayes bitki sınıflandırma oranları (%)

Öznitelik Vektörleri	Diğer Bitkiler	Zararlı Ot	Ortalama
I_{ORT}, I_{VAR}	92,68	85,37	89,02
$R\ddot{O}_{ORT}, D_{FD}, P_{FD},$	91,46	81,71	86,59
$R\ddot{O}_{ORT}, D_{FD}, P_{FD}, I_{ORT}, I_{VAR}$	92,68	89,02	90,85

D_{FD} sınıflandırmada kullanılan bir öznitelik bileşeni olarak iyi bir seçimdir. Tek başına I_{ORT} ve I_{VAR} nın kullanımına göre D bileşeninin kullanılması geri getirme yüzdesini arttırmıştır. Değişik öznitelik çıkarımları ve seçilmesi işlemleri ardından en iyi sonuç veren özniteliklerin $R\ddot{O}_{ORT}, D_{FD}, P_{FD}, I_{ORT}, I_{VAR}$ olduğu belirlenmiştir. Gri seviye değerinin yalnızca bölgesel ortalama ve varyans değerleri (I_{ORT}, I_{VAR}) kullanılarak yapılan sınıflandırma işleminde geri getirme yüzdesi düşük çıkmıştır.

5.3 Öznitelik Seçimi Deneyleri

Bu çalışmada, beton veri kümesine (Asuncion and Newman, 2007; Yeh, 1998) ait her 3 sınıf için ilgili bileşenleri (çimento, yüksek fırın cürufu, ince kül, su, süperakışkanlaştırıcı, kaba agrega, ince agrega, yağ) içeren 100 farklı ölçüm ile eğitim kümesi oluşturulmuştur. Aynı zamanda doğrulamak için yine 100 farklı ölçümden oluşan bir test veri kümesi oluşturulmuştur.

8 bileşenin (özniteliğin) FD tabanlı değerlendirilmesi için eğitim kümesinde, 3 sınıfın her birinden her öznitelik için 100 farklı değer birleştirilmiştir. Böylece tüm sınıfların toplamında 300 farklı değer elde edilmiştir. Bu değerler, daha düzgün bir hesaplama için “sıfır ortalama ve birim varyansa” göre normalleştirilmiştir.

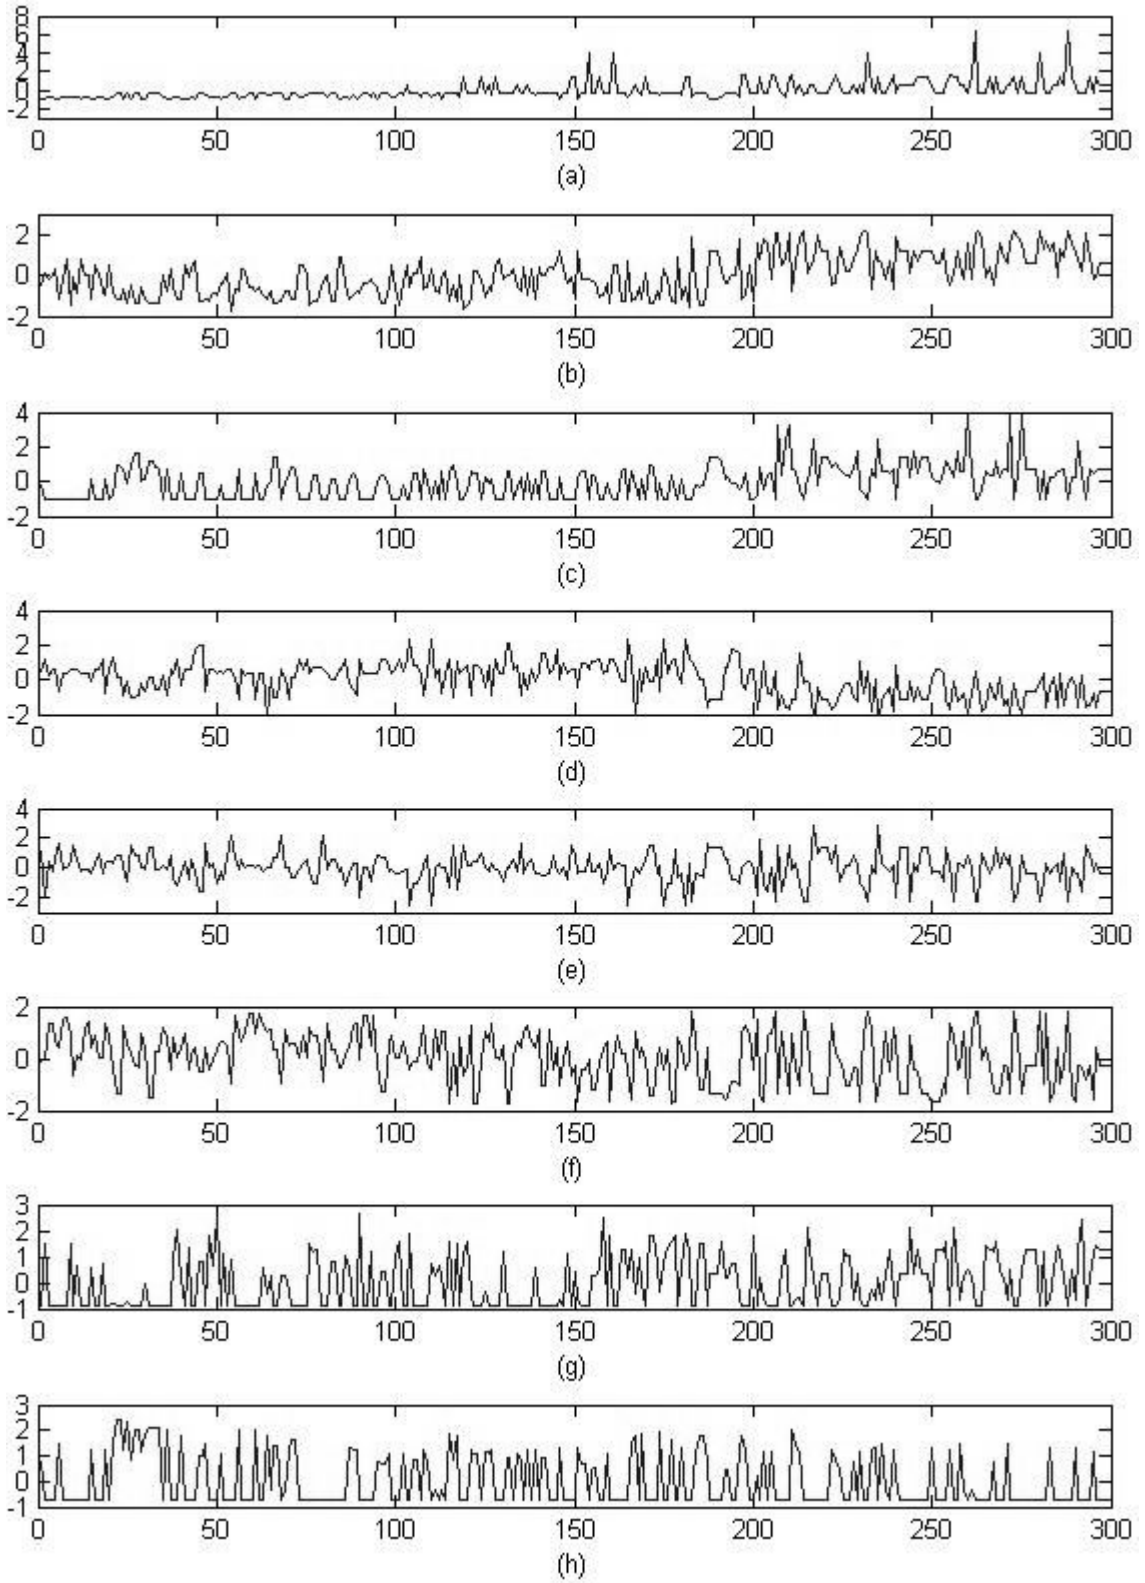
Bölüm 2.3’ de anlatıldığı şekilde 8 özniteliğe ait ayrı ayrı FD(ilinti boyutu) hesaplanmıştır. Bu değerler azalan sırada Çizelge 5.18’de verilmiştir. Bu sıraya göre, betonun yaşı dayanıklılığı hassas bir şekilde belirlemede en önemli faktördür. Yaşı takiben, umulduğu üzere çimento bir diğer önemli faktördür. Bir sonraki ise daha önce de anlatıldığı gibi özellikle yüksek performanslı betonlarda kullanılan tamamlayıcı malzeme olan süperakışkanlaştırıcıdır. Liste; su, agrega ve diğer tamamlayıcı malzemeler ile devam etmektedir.

Sınıflardaki her öznitelik için “sıfır ortalama ve birim varyansa” göre normalleştirilen değişimler Çizelge 5.18’deki FD azalış sırasına göre Şekil 5.4’te gösterilmektedir. 0-100 arası değerler 1. sınıfa, 101-200 arası değerler 2. sınıfa, 201-300 arası değerler 3. sınıfa aittir.

Öznitelikler için FD değerleri elde edildikten sonra, farklı sayıdaki öznitelikler için sınıflandırma başarımları elde edilmiştir. Bu amaçla, beton bileşenleri Çizelge 5.18’deki sırayla seçilmiştir. Sonraki adımda, daha önce eğitim kümesinden bağımsız olarak elde edilen test kümesi ile Bayes sınıflandırma başarımları ölçülmüştür.

Çizelge 5.18. Beton özniteliklerine ait azalan sıradaki FD değerleri

No	Öznitelik	Fraktal Boyut
8	Yaş	1.9742
1	Çimento	1.9235
5	Süperakışkanlaştırıcı	1.9206
4	Su	1.9187
7	İnce Agrega	1.9154
6	Kaba Agrega	1.9065
2	Yüksek Fırın Cürufu	1.9046
3	İnce Kül	1.8997



Şekil 5.4. Normalize edilmiş ve FD değerlerine göre büyükten küçüğe sıralanmış beton öznelilik değeri grafikleri (1-100 arası: Sınıf 1, 101-200 arası: Sınıf 2, 201-300 arası: Sınıf 3) : (a) Yaş (b) Çimento (c) Süperakışkanlaştırıcı (d) Su (e) İnce Agrega (f) Kaba Agrega (g) Yüksek Fırın Cürufu (h) İnce Kül

FD temelli değerlerle seçilen öznitelikler için sınıflandırma işlemi tamamlandığında, Bölüm 1.3’de açıklanan SFS ve SBS algoritmaları gibi klasik öznitelik seçme yöntemleri de uygulanmış ve sınıflandırma işlemi aynı şekilde tekrar edilmiştir. SFS ve SBS yöntemleri için kriter fonksiyonu, doğru sınıflandırma oranıdır. Her öznitelik seçimi için sonuçlar, her yaklaşım için en iyi sınıflandırma oranlarını koyu renkte gösterilen Çizelge 5.19’da özetlenmiştir. Ek olarak, her yöntem için en yüksek sınıflandırma oranını sağlayan öznitelik altkümeleri Çizelge 5.20’de gösterilmektedir. FD yaklaşımı ile seçilen özniteliklerin SFS ve SBS yöntemleri ile seçilenlerle karşılaştırılabilir sınıflandırma başarımı gösterdiği açıkça görülmektedir.

Çizelge 5.19. FD, SFS, SBS yöntemleri yardımıyla farklı öznitelik alt kümeleri için sınıflandırma oranları(%)

Selection Method	Feature Size							
	1	2	3	4	5	6	7	8
FD	33.33	65.50	68.50	68.33	71.00	72.83	72.17	70.67
SFS	45.83	59.50	68.50	72.00	73.00	72.83	71.17	70.67
SBS	33.67	62.67	64.33	67.67	72.17	73.17	73.00	70.67

Çizelge 5.20. (a) FD (b) SFS (c) SBS yöntemlerine göre en iyi öznitelik kümeleri

Selection Method	Feature Set
FD	1, 4, 5, 6, 7, 8
SFS	1, 2, 3, 5, 8
SBS	3, 4, 5, 6, 7, 8

FD yaklaşımı sonuçlarına göre, betonun basınç dayanıklılığını belirlemede {yaş, çimento, süperakışkanlaştırıcı, su, ince agrega, kaba agrega} beton bileşenleri daha yüksek kesinlik (72.83%) sağlarken, {yüksek fırın cürufu, uçucu kül} bileşenleri eklenerek kullanıldığında bu değer (70.67%) elde edilmiştir. Ayrıca FD, SFS ye göre

daha yüksek başarımları sağlayan SBS ile biri (öznitelik-3) haricinde aynı özniteliklerin seçimini sağlamıştır.

BÖLÜM 6

SONUÇLAR

Bu tez çalışmasında, Fraktal Boyut bilgisi örüntü tanımanın önemli konuları olan öznitelik çıkarımı ve seçiminde kullanılmıştır.

Tez çalışmasının ilk bölümü olan video kesme geçişlerinin FD temelli öznitelikler ile belirlenmesi aşamasında, literatürdeki klasik piksel ve histogram temelli yöntemlere alternatif olarak FD tabanlı kesme geçişlerini belirleme yöntemi önerilmiştir. Önerilen yöntemde, görüntü yeğlilik yüzey karmaşıklığı ve video çerçevelerinin dokusal bilgilerinin dikkate alındığı ardışık video çerçevelerindeki kesme geçişlerinin belirlenmesinde FD farkları kullanılmıştır. Ardışık çerçevelerdeki FD farkları çerçeve içeriklerinin değişimine bağlıdır. Bu değişimlerin kesme geçişleri esnasında daha fazla olması, FD'un bu geçişlerin belirlenmesinde yararlı bir araç olarak kullanılabilceğini göstermiştir. Bu çalışmada FD bilgisinin kullanımının yanısıra, diğer bazı yenilikler de yapılmıştır. Bunlardan ilki her çerçeve için tek bir FD kullanmak yerine, bölgesel olarak FD kullanılmasıdır. Bölgesel FD tabanlı öznitelik farklarının kullanılması, çerçevelerden elde edilen öznitelik farklarındaki gürültüyü azaltmaktadır. Bu durumda, kesme geçişlerini belirleme aşamasındaki yanlış tespitlerin azalması, kesinlik oranını arttırmaktadır. Böylece, kesme geçişi olan noktalar daha belirgin ortaya çıkmaktadır. Bunun sonucunda da tanıma başarımı yükselmektedir. Çalışmadaki bir diğer yenilik ise FD değerlerinin hesaplanması için kullanılan standart DBC yönteminin karmaşıklığını azaltan SDBC yönteminin geliştirilmesidir. DBC algoritmasının yüksek miktardaki işlem yükünden dolayı FD bilgisinin kesme geçişi belirleme işlemlerinde kullanımı uygun olmayabilir. Çalışmamızda, FD hesaplama karmaşıklığı belirgin bir şekilde azaltıldığı için FD'nin kesme geçişlerini belirlemede kullanılmasına imkan tanınmıştır. Bu yenilik, kesme geçişlerini belirlemenin yanısıra FD bilgisinin kullanıldığı başka çalışma alanlarında da fayda sağlayacaktır. Önerilen yöntem, futbol ve tenis maçlarını içeren spor videolarında test edilmiş, klasik piksel ve histogram tabanlı yöntemlerle karşılaştırılmıştır. Deneysel çalışmalar, önerilen yöntemin mevcut geçiş belirleme

yöntemleriyle karşılaştırılabilir başarıma sahip olduğunu, hatta dereceli geçişlerde bu yöntemleri geride bıraktığını doğrulamaktadır. Ayrıca, farklı video kesme geçiş türlerinin belirlenebilmesi için klasik eşikleme yöntemine alternatif olabilecek örüntü sınıflandırıcı temelli bir yöntem önerilmiştir. Örüntü sınıflandırıcı ile “ani geçiş” ve “geçiş yok/dereceli geçiş” belirgin bir şekilde ayrılabilir. “geçiş yok” ve “dereceli geçiş” değerleri ise kısmen birbirinden ayırt edilebilmektedir.

Bitki sınıflandırma çalışmasında, görüntünün doygunluk bileşeni ayırdedici bir öznelik olarak kullanılmış ve farklı bitki türlerinin bölütlemesinde I_{ORT}, I_{VAR} yöntemi kadar yüksek başarımlar göstermiştir. En yüksek başarımlar I_{ORT}, I_{VAR} ve FD kullanılarak elde edilen özneliklerin birlikte kullanılması sonucu elde edilmiştir. Başarımların artmasında, yaprak desenlerindeki ton değişimlerinin bir anlamda ölçüsünü veren D_{FD} özneliği en önemli katkıyı sağlamaktadır. Eğitim kümesindeki görüntü sayısının daha fazla artırılmasıyla değişik durumlara ait veriler elde edilebileceğinden tanıma oranlarının yükselmesi beklenmektedir. Çalışmanın, zararlı otla savaşmada, uydu görüntülerinden tarım rekoltesinin ya da kaçak ekimlerin belirlenmesinde başarıyla kullanılacağı düşünülmektedir.

FD tabanlı öznelik seçimi çalışmasında ise, beton üretimindeki bileşenlerin önemi ve betonun dayanıklılık basıncını belirlemedeki etkileri fraktal temelli yaklaşımla değerlendirilmiştir. Beton bileşenlerinin değişim ve ilintileri, yüksek karmaşık şekilleri tanımlamada kullanılan fraktal boyut değişimi cinsinden karakterize edilmiştir. Bu çalışmada, ilgili dalga şekillerine karşılık gelen karmaşık şekiller “düşük”, “orta” ve “yüksek” dayanıklılıkta tanımlanan 3 beton sınıfı üzerinden bileşen değerlerinin değişimini belirtmektedir. Elde edilen bileşenlerin FD değerleri, beton dayanıklılığını belirlemedeki etkilerini göstermektedir. Deneysel çalışmada FD yaklaşımının başarımlarını, ardışık ileri ve geri yönde seçim yöntemleri ile karşılaştırılmış ve ümit verici sonuçlar elde edilmiştir. Bu çalışmanın sonuçları, en uygun bileşenleri kullanarak daha dayanıklı beton imalatını dolayısıyla daha güçlü yapılar inşa etmeyi destekleyecek niteliktedir.

KAYNAKLAR DİZİNİ

- Abrams, D.A., 1918, Design of concrete mixtures, Structural Materials Research Laboratory, Lewis Institute.
- Addison, P.S., 1997, Fractals and chaos an illustrated course, Institute of Physics Publishing, Bristol and Philadelphia, 256 p.
- Albreqtsen F., Nielsen B. and Yogesan K., 1992, Fractal Dimension. only a fraction of the Truth?;, Proc. of 11th IAPR International Conference on Pattern Recognition, Conference C: Image. Speech and Signal Analysis, Netherlands, 3,733-736.
- Asuncion, A. and Newman, D.J., 2007, UCI Machine Learning Repository. Irvine, CA: University of California, School of Information and Computer Science.
- Bach, N.H., Shinoda, K. and Furui, S., 2006, Robust scene extraction using multi-stream HMMs for baseball broadcast, IEICE Transactions on Information and Systems, E89-D n.9, 2553-2561.
- Barnsley, M.F., 1988, Fractals everywhere, Academic Press, Boston, USA.
- Bellman, R., 1961, Adaptive control processes: A guided tour, Princeton University Press, 255 p.
- Bhavani, S.D., Rani, T.S. and Bapi, R.S., 2008, Feature Selection using Correlation Fractal Dimension: Issues and applications in binary classification problems, Applied Soft Computing, 8, 555-563.
- Bildirgeç, 2010, (23/03/2010), www.google.com.tr,
<http://www.bildirgec.org/yazi/dogadaki-inanilmaz-fraktal-yapilar-doganin>

KAYNAKLAR DİZİNİ (devam)

- Boreczky, J.S. and Rowe, L.A., 1996, A comparison of video shot boundary detection techniques, *Journal of Electronic Imaging*, 5, 2, 122-128.
- Camstra, F. and Vinciarelli, A., 2002, Estimating the Intrinsic Dimension of data with a Fractal-Based method, *IEEE Transactions on Pattern Analysis and Machine Intelligence.*, 24, 10, 1404-1407.
- Chaudhuri, B.B. and Sarkar, N., 1995, Texture segmentation using fractal dimension, *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 17, 1, 72-77.
- Cotsaces, C., Gavrielides, M. and Pitas I., 2005, A Survey of Recent Work in Video Shot Boundary Detections, in *Proc. of 2005 Workshop on Audio-Visual Content and Information Visualization in Digital Libraries (AVIVDiLib '05)*, Cortona, Italy, 4-6 June.
- Domone, P.L. J. and Soutsos, M. N., 1994, An approach to the proportioning of high strength concrete mixes, *Concrete International*, 6, 10, 26-31.
- Drakopoulos, V., Bouboulis, P. and Theodoridis, S., 2006, Image compression using affine fractal interpolation on rectangular lattices, *Fractals*, 14, 4, 259-269.
- Duda, R.O., Hart, P.E. and Stork, D.G., 2001, *Pattern classification*, John Wiley & Sons Inc., USA, 654 p.
- Duin R.P.W., Tax D.M.J., 2006, Statistical Pattern Recognition, *Handbook of Pattern Recognition and Computer Vision*, C. H. Chen, P.S.P Wang (Eds), worldscientific, 639, 3-24.

KAYNAKLAR DİZİNİ (devam)

- Eckmann, J.P. and Ruelle, D.,1992, Fundamental limitations for estimating dimensions and Lyapounov Exponents in dynamical systems, *Physica D: Nonlinear Phenomena*, 56, 2-3, 185-187.
- Ekin, A, 2003, Sports video processing for description, summarization and search, PhD Thesis, Department of Electrical and Computer Engineering, University of Rochester, Rochester NY.
- Feng J., Lin W. and Chen C., 1996, Fractional Box-Counting Approach to Fractal Dimension Estimation, *Proc. of IEEE International Conference on Pattern Recognition*, 854-858.
- Fernando, W.A.C, Canagarajah C. N and Bull D.R., 2000, A Unified approach to scene change detection in uncompressed and compressed video, *IEEE Transaction on Consumer Electronics*, 46, 3, 769-779.
- Fernando, W.A.C, Canagarajah C. N and Bull D.R., 2001, Scene change detection algorithms for content based video indexing and retrieval, *Electronics & Communication Engineering Journal*, 13, 3, 117-126.
- Fisher, Y., 1994, Fractal image compression, *Fractals*, 2, 3, 347-361.
- Gargi, U., Kasturi, R. and Strayer, S.H., 2000, Performance characterization of video-shot- change detection methods, *IEEE Transaction on Circuits and Systems for Video Technology*, 10, 1, 1-13.
- Gerek, Ö.N., Ece D.G., Barkana, A., 2006, Covariance analysis of voltage waveform signature for power-quality event classification, *IEEE Transactions on Power Delivery*, 21, 4, 2022–2031.

KAYNAKLAR DİZİNİ (devam)

- Gonzalez, R. and Woods R. E., 2008, Digital Image Processing, Pearson Prentice Hall Press, 954 p.
- Grassberger, P. and Procaccia I., 1983, Measuring the strangeness of strange Attractors, Physica D: Nonlinear Phenomena, 9, 189-208.
- Gunsel, B. and Tekalp, A.M., 1998, Content-based video abstraction, Proc. of International Conference on Image Processing, 128-122.
- Hemming, J. and Rath, T., 2001, Computer-vision-based weed identification under field conditions using controlled lighting, Journal of Agricultural Engineering Research, 78, 3, 233-243.
- Hufnagl, C. and Uhl, A., 2000, Fractal block-matching in motion-compensated video coding, Fractals, 8, 1, 35-48.
- Islaker, H., 1992, A scaling test for correlation dimensions, Physics Letters A, 169, 313-322.
- Jain, A.K. and Zongker, D., 1997, Feature selection: evaluation, application, and small sample performance, IEEE Transactions on Pattern Analysis and Machine Intelligence, 19, 2, 153–158.
- Jiang J.D., Chen J. and Qu L. S., 1999, The application of correlation dimension in gearbox condition monitoring, Journal of Sound and Vibration, 223, 4 , 529-541.
- Korpi-Anttila, J., 2002, Automatic color enhancement and scene change detection of digital video, Licentiate thesis, Helsinki University of Technology, Espoo, Finland, 72 p.

KAYNAKLAR DİZİNİ (devam)

- Lee, W.S., Slaughter, D.C., and Giles, D.K., 1996, Development of a machine vision system for weed control using precision chemical application, Proceedings of ICAME-96, 3, 802-811.
- Lee, W.S., Slaughter, D.C., and Giles, D.K., 1999, Robotic weed control system for tomatoes, Precision Agriculture, 1, 1, 95-113.
- Liu, Y. and Li, Y., 1997, Image feature extraction and segmentation using Fractal Dimension, International Conference on Information, Communication and Signal Processing, 2, 975-979.
- Lu, H. and Tan, Y.P., 2005, An effective post-refinement method for shot boundary detection, IEEE Trans. on Circuits and Systems for Video Technology 15, 11, 1407-1421.
- Mandelbrot, B., 1977, Fractals: Form Change. an Dimension. San Francisco, Freeman.
- Mandelbrot, B., 1983, The fractal geometry of nature, W.H. Freeman and Company, NewYork, 468 p.
- Marques, O and Furht, B., 2002, Content-based image and video retrieval. Kluwer Academic Publishers, Boston / Dordrecht / London, 182 p.
- Meng, J., Juan, Y. and Chang, S.F., 1995, Scene change detection in a MPEG compressed video sequence, Proc. of IS&T/SPIE Symposium, California, 2419.
- Miqel, 2010, (23/03/2010), www.google.com.tr,
http://www.miqel.com/fractals_math_patterns/visual-math-natural-fractals.html,

KAYNAKLAR DİZİNİ (devam)

- Murino, V., Ottonello C. and Pagnan S., 1998, Noisy texture classification: A higher-order statistics approach, *Pattern Recognition*, 31, 4, 383–393.
- Nagasaka, A. and Tanaka, Y., 1992, Automatic video indexing and full-video search for object appearances, *Visual Database Systems, II*, Elsevier Science Publishers, 113-127.
- Oluokun, F.A., 1994, Fly Ash Concrete mix design and the water–cement ratio law., *ACI Mater. J.*, 91, 4, 362–371.
- Paulus, D.W.R and Hornegger, J., 2003, *Applied Pattern Recognition*, Wieweg, Germany, 372 p.
- Revathy, K., Raju, G. and Nayar, S.R.P., 2000, Image zooming by wavelets, *Fractals*, 8, 3, 247-253.
- Roadmap 2030, 2002, *The U.S. Concrete Industry Technology Roadmap*, Strategic Development Council.
- Sarkar, N. and Chaudri, B.B., 1994, An efficient differential box-counting approach to compute fractal dimension of image, *IEEE Transactions on Systems, Man, and Cybernetics*, 24, 1, 115-120.
- Sato, T., Matsuoka, M. and Takayasu, H., 1996, Fractal image analysis of natural scenes and medical images, *Fractals*, 4, 4, 463-468.
- Siddique R., 2003, Effect of fine aggregate replacement with Class F fly ash on the mechanical properties of concrete, *Cement and Concrete Research*, 33, 4, 539-547.

KAYNAKLAR DİZİNİ (devam)

- Şora Günal, E., Canbek, S. and Adar, N., 2008, Evaluation of components in concrete manufacturing using fractal dimension, Proceedings of 6th International Symposium on Intelligent and Manufacturing Systems, Sakarya, Türkiye, 247-256.
- Şora Günal, E., Canbek, S., Adar, N. and Göktogan, A.H., 2008, HSV renk uzayında fraktal boyut kullanılarak bitkilerin sınıflandırılması, 16. Sinyal İşleme, İletişim ve Uygulama Kurultayı, 20-22 Nisan, Didim, Türkiye.
- Şora Günal, E., Canbek, S. and Adar, N., 2009, Gradual shot change detection in soccer videos via fractals, Proceedings of 6th International Conference on Electrical and Electronics Engineering (ELECO 2009), Bursa, Türkiye, 2, 125-128.
- Sun, W., XU, G., Gong, P. and Liang, S., 2006, Fractal analysis of remotely sensed images: A review of methods and applications, International Journal of Remote Sensing, 27, 22, 4963-4990.
- Swain, M.J. and Ballard, D.H., 1993, Color indexing, International Journal of Computer Vision, 26, 4, 461-470.
- Theodoridis, S. and Koutroumbas, K., 2003, Pattern Recognition, Academic Press, USA, 689 p.
- Tonomura, Y., 1991, Video handling based on structured information for hypermedia systems, Proc. of International Conference on Multimedia Information Systems '91; Singapore (16-18 Jan), 333-344.
- Traina, Jr. C., Traina, A., Wu, L. and Faloutsos, C., 2000, Fast feature selection using fractal dimension, Proceedings of XV Brazilian Symposium on Databases (SBBD), Paraiba, Brazil, 158-171.

KAYNAKLAR DİZİNİ (devam)

- Véhel, J.L. and Mignot, P., 1994, Multifractal segmentation of images, *Fractals*, 2, 3, 371-377.
- Wang, X. and Weng, Z., 2000, Scene abrupt change detection, *Canadian Conference on Electrical and Computer Engineering*, 2, 880-883.
- Watchareeruetai, U., Tokeuchi, Y., Matsumoto, T., Kudo, H., and Ohnishi, N., 2006, Computer vision based methods for detecting weeds in lawns, *Machine Vision and Applications*, 17, 5, 287-296.
- Yazıcı, A., Selbes C.F., 1989, *Numerical Analysis*, METU, 243 s.
- Yeh, I.-C., 1998, Modeling of Strength of High Performance Concrete using Artificial Neural Networks, *Cement and Concrete Research.*, 28, 12, 1797-1808.
- Youm, S. and Kim, W., 2003, Dynamic threshold method for scene change detection, *Proc. of International Conference on Multimedia and Expo.*, 337-340.
- Zhang, H., Perng, C. S. and Cai Q., 2002, An improved algorithm for feature selection using Fractal Dimension, *Proc. of 2nd International Workshop on Databases, Documents and Information Fusion*, 124.
- Zhang, H.J., Kankanhalli, A. and Smoliar, S.W., 1993, Automatic partitioning of full-motion video, *Multimedia Systems*, 1, 1, 10-28.

ÖZGEÇMİŞ

Efnan Şora Günel, 1978 yılında Eskişehir’de doğdu. İlk, orta ve lise öğrenimini aynı ilde tamamladı. Daha sonra, sırasıyla 2000 ve 2004 yıllarında Eskişehir Osmangazi Üniversitesi, Elektrik - Elektronik Mühendisliği Anabilim dalında lisans ve yüksek lisans derecelerini aldı. Halen aynı bölümde öğretim elemanı olarak görev yapmaktadır. Başlıca akademik çalışma alanları, örüntü tanıma, sayısal sinyal işleme ve fraktal boyut temelli uygulamalardır.